

Universidade de Trás-os-Montes e Alto Douro

Deteção e Monitorização Automática de Castanheiros com base em Imagens Aéreas de Alta Resolução

Dissertação de Mestrado em Engenharia Informática

Por

Pedro Miguel Mota Marques

Orientação: Professor Doutor António Manuel Ribeiro de Sousa

Professor Doutor Joaquim João Moreira de Sousa



Vila Real, 2018

Universidade de Trás-os-Montes e Alto Douro

Deteção e Monitorização Automática de Castanheiros com base em Imagens Aéreas de Alta Resolução

Dissertação de Mestrado em Engenharia Informática

Por

Pedro Miguel Mota Marques

Orientação

Professor Doutor António Manuel Ribeiro de Sousa

Professor Doutor Joaquim João Moreira de Sousa

Composição do júri:

Presidente: Professor Doutor Hugo Paredes, Escola de Ciências e Tecnologia, Universidade de Trás-os-Montes e Alto Douro

Arguente: Professor Doutor Luís Magalhães, Escola de Engenharia, Universidade do Minho

Vogal: Professor Doutor António Sousa, Escola de Ciências e Tecnologia, Universidade de Trás-os-Montes e Alto Douro

Vila Real, 2018

Resumo

Os veículos aéreos não tripulados (VANT) estão a tornar-se uma ferramenta muito popular para monitorização remota, nomeadamente de culturas agrícolas. Os VANT são mais fáceis de operar, mais baratos e permitem obter imagens com maior resolução espacial, comparativamente com os satélites. Embora existam vários métodos para deteção de vegetação, através do processamento de imagens aéreas, ainda existe um número reduzido de métodos para a extração de parâmetros de vegetação, *e.g.*, deteção individual de árvores e avaliação da área da copa. É, ainda, pouco frequente, a análise multi-espectral de culturas agrícolas, usando imagens aéreas de elevada resolução temporal e espacial. Como resultado deste trabalho, apresenta-se, precisamente, um método, baseado na utilização de índices de vegetação (VI) e de modelos digitais de superfície, para extrair parâmetros individuais de castanheiro, assim como monitorizar, ao longo do tempo um souto. Este tipo de análise é muito importante e pertinente para o agricultor, ou associação de agricultores, pois permitirá uma gestão da parcela com base no conhecimento do estado de cada planta individual. Será possível a deteção de árvores afetadas com determinada doença, deteção de novas plantações e aumento/declínio da vegetação. Este ultimo caso é especialmente relevante para a deteção de árvores afetadas, no seu desenvolvimento, por fatores bióticos ou abióticos, permitindo uma ação atempada com vista à definição da melhor estratégia a seguir. O método proposto é composto por três etapas: (1) segmentação e primeiro *clustering* (agrupamento de regiões); (2) isolamento de *clusters*; e (3) extração de parâmetros. Os resultados obtidos com a aplicação do método a várias áreas-teste, demonstram que os parâmetros extraídos, nomeadamente, o número de castanheiros presentes numa parcela, área de cobertura vegetal, altura individual e diâmetro individual foram extraídos e validados com sucesso. Neste trabalho, foi possível concluir que os resultados obtidos pela aplicação deste método a imagens aéreas de elevada resolução, obtidas por VANT, para monitorização de castanheiros, são bastante satisfatórios quando comparados com as metodologias correntes, baseadas em métodos manuais.

Palavras-chave: VANT; imagem aérea, processamento digital de imagem; monitorização multi-temporal; declínio do castanheiro.

Abstract

Unmanned aerial vehicles (UAV) are becoming a very popular tool for remote sensing and crop monitoring, namely agricultural crops. UAV are easier to deploy, cheaper and allows to obtain images with higher spatial-resolution when compared to satellites. Although there are several methods to detect vegetation, through aerial images processing, there are still few methods for the extraction of parameters, e.g. individual tree detection and canopy area evaluation. It is still infrequent, the multi-spectral analysis of agricultural crops, using aerial images of high temporal and spatial resolution. As a result of this work, a method, based on the use of vegetation indices and digital surface models, is presented to extract individual parameters of chestnut tree, as well as monitor a chestnut plot over the time. This is a very important and pertinent type of analysis to the farmer, or farmers association, as it will allow a plot management based on the knowledge of the status of each individual plant. It will be possible to detect affected trees with disease, detection of new plantations and increase/decline of vegetation. This later case is especially relevant for the detection of affected trees in their development, caused by biotic or abiotic factors, allowing a timely action with the purpose to define the best strategy to follow. The proposed method is composed by three steps: (1) segmentation and first clustering (grouping of regions), (2) cluster isolation, and (3) feature extraction. The results obtained with the proposed method, applied to several field tests, show that the extracted parameters, namely, the number of chestnut trees present in a plot, vegetation coverage area, individual height and individual diameter were extracted and successfully validated. In this work, it was possible to conclude that the results obtained by the application of this method to high resolution aerial images obtained by UAV, for monitoring chestnut trees, are quite satisfactory when compared to current methodologies, based on manual method.

Keywords: UAV; aerial image; digital image processing; time series monitoring; chestnut tree decline

Agradecimentos

A realização desta dissertação foi uma etapa que só foi possível de concretizar com o apoio de várias pessoas. A todas as pessoas que me motivaram e ajudaram a ultrapassar as dificuldades encontradas neste percurso ajudando-me a concluir esta etapa. Agradeço então:

À equipa de orientação, composta pelo Professor Doutor António Manuel Ribeiro de Sousa, Professor Auxiliar do Departamento de Engenharias da Universidade de Trás-os-Montes e Alto Douro, orientador deste trabalho, pela sua orientação e auxílio prestado durante a realização do trabalho e sua disponibilidade demonstrada ao longo desta dissertação. E pelo Professor Doutor Joaquim João Moreira de Sousa, Professor Auxiliar com Agregação do Departamento de Engenharias da Universidade de Trás-os-Montes e Alto Douro, coorientador deste trabalho, pelo apoio, disponibilidade, pelas sugestões e correções que em muito enriqueceram esta dissertação.

A todos os meus colegas que comigo se cruzaram no curso de Engenharia Informática da UTAD, pelo companheirismo e amizade demonstrados ao longo destes anos de estudo. Agradeço especialmente a Luís Pádua, por todo o seu apoio, disponibilidade e auxílio durante a elaboração da presente dissertação.

À minha família, pais e irmãos, pelo esforço, união e honestidade, estando a meu lado em todos os momentos deste meu percurso.

À minha companheira Raquel Diogo, pelo seu carinho, ajuda, apoio e compreensão durante este caminho.

A todos os que direta ou indiretamente contribuíram para o meu sucesso académico.

A todos eles os meus sinceros agradecimentos!

Pedro Marques

UTAD, Vila Real, 21 de novembro de 2017

Índice

Resumo.....	v
Abstract	vii
Agradecimentos.....	ix
Índice de figuras	xiii
Índice de tabelas	xvii
Glossário, acrónimos e abreviaturas.....	xix
1 Introdução.....	1
1.1 Objetivos.....	3
1.2 Metodologia.....	4
1.3 Organização da dissertação	4
2 Estado da arte	7
2.1 <i>Castanea sativa</i>	7
2.1.1 Breve história	8
2.1.2 Características	9
2.1.3 Principais usos.....	10
2.1.4 Importância económica da <i>Castanea sativa</i> em Portugal	11
2.2 VANT	13
2.2.1 VANT e outras tecnologias de deteção remota.....	14
2.2.2 Sensores RGB	18
2.2.3 Sensores infravermelho	19
2.2.4 Sensores LIDAR	20
2.2.5 Tipos de dados obtidos por VANT	21
2.2.6 Aplicação dos VANT na monitorização automática.....	23
2.3 Segmentação de imagens.....	26

2.3.1	Técnicas de segmentação	26
2.3.2	Técnicas de segmentação na área agroflorestal.....	32
3	Método proposto	39
3.1	Etapa 1: Segmentação e primeiro <i>clustering</i>	41
3.1.1	Testes de segmentação	43
3.1.2	Síntese	55
3.2	Etapa 2: Isolamento de <i>clusters</i>	57
3.2.1	Testes para isolamento de <i>clusters</i>	58
3.2.2	Síntese	62
3.3	Etapa 3: Extração de parâmetros	63
4	Materiais e validação do método proposto.....	65
4.1	Descrição das áreas de estudo e aquisição de dados	65
4.2	Plataformas de detecção remota e descrição dos dados	66
4.3	Validação do número de árvores detetadas	69
4.4	Validação da estimativa da altura das árvores.....	70
4.5	Validação da estimativa do diâmetro da copa das árvores	71
4.6	Análise Multi-Temporal ao nível do Souto	72
4.7	Análise Multi-Temporal ao nível da árvore	75
5	Conclusões e trabalho futuro.....	77
5.1	Conclusões.....	77
5.2	Trabalho futuro	78
	Bibliografia.....	81
	Anexos.....	101
	Anexo A – Resultados dos índices de vegetação testados	102

Índice de figuras

Figura 1 Distribuição de <i>Castanea sativa</i> na Europa	9
Figura 2 Técnicas e plataformas para fins de registo em 3D, de acordo com as dimensões e complexidade da cena	15
Figura 3 Exemplos de tecnologias de deteção remota	17
Figura 4 Exemplos de sensores RGB.....	18
Figura 5 Exemplos de sensores RE.....	20
Figura 6 Exemplos de sensores LIDAR	20
Figura 7 Exemplo de geração de um ortomosaico.	22
Figura 8 Métodos de segmentação com base na deteção de contornos.	28
Figura 9 Métodos de <i>threshold</i>	29
Figura 10 Método de segmentação com base na região.....	30
Figura 11 Método de segmentação com base em <i>clustering</i>	31
Figura 13 Segmentação de vegetação com aplicação de ExG e Método de <i>Otsu</i>	33
Figura 14 Cálculo do CHM através do DTM e DSM.	40
Figura 15 Diagrama do método proposto.....	41
Figura 16 Segmentação e primeiro <i>clustering</i>	42
Figura 17 Centroides representados na imagem RGB	43
Figura 18 Imagem de referência para avaliação dos métodos de segmentação	44
Figura 19 Aplicação do método <i>k-means</i> nas imagens RGB e RE.	45
Figura 20 Comparação das máscaras binárias geradas pelo <i>k-means</i> com a máscara binária manual	46
Figura 21 Comparação das máscaras binárias geradas pelo método de <i>Otsu</i> com a máscara binária manual	47
Figura 22 Comparação das máscaras binárias geradas pelo <i>threshold</i> adaptativo com a máscara binária manual.	49

Figura 23 Representação do espaço de cor HSV	50
Figura 24 Imagens convertidas para o espaço de cor HSV.....	51
Figura 25 Comparação das máscaras binárias geradas pelo espaço de cor HSV com a máscara binária manual.	51
Figura 26 Sete áreas seleccionadas para identificar o VI com maior percentagem de acerto na identificação de castanheiros.....	53
Figura 27 Comparação das máscaras binárias criadas pelos índices de vegetação com a máscara binária manual.	55
Figura 28 Isolamento dos <i>clusters</i>	58
Figura 29 Operação de isolamento de <i>clusters</i> aplicada a toda a parcela	58
Figura 30 <i>Clusters</i> com árvores conectadas e sua respetiva binarização.	59
Figura 31 Resultados da aplicação da transformada de <i>Hough</i>	60
Figura 32 Resultados da aplicação o método <i>Watershed</i>	61
Figura 33 Resultados da aplicação de operações morfológicas	62
Figura 34 Áreas de cultivo de castanha no norte de Portugal	66
Figura 35 VANT utilizados para aquisição de dados.....	66
Figura 36 Plano de voo da região da Padrela	67
Figura 37 Câmaras utilizadas para aquisição das imagens	67
Figura 38 Mosaicos gerados pelo VANT <i>senseFly eBee</i> na região da Padrela	68
Figura 39 Mosaicos gerados pelo drone DJI Phantom 4 na região de Souto de Escarão	68
Figura 40 Validação do numero de árvores detetadas.....	69
Figura 41 Validação da estimativa da altura das árvores. Comparação entre as alturas obtidas através do método proposto e medidas manuais dendrométricas.	71
Figura 42 Imagem RGB representante do grupo composto por 28 castanheiros. GSD ~3 cm; Altitude do voo: 100 m; Equipamento: DJI Phantom 4.	71
Figura 43 Validação do diâmetro dos castanheiros: comparação entre os valores obtidos pelo método proposto com o diâmetro medido manualmente no terreno	72

Figura 44 Análise multi-temporal entre os diferentes períodos.	73
Figura 45 Análise multi-temporal.	75
Figura 46 Análise multi-temporal ao nível individual da árvore.	75

Índice de tabelas

Tabela 1 Principais características de <i>Castanea sativa</i>	10
Tabela 2 Vantagens e desvantagens das diferentes técnicas de detecção remota	15
Tabela 3 Exemplos de aplicações e casos de estudo de monitorização de vegetação com uso de VANT.....	23
Tabela 4 Lista de VI mais comuns para detecção de vegetação	34
Tabela 7 Resultados da avaliação do método <i>K-Means</i> aplicado às imagens RGB	46
Tabela 8 Resultados da avaliação do método de <i>Otsu</i> aplicado às imagens RGB e RE	48
Tabela 9 Resultados da avaliação do <i>threshold</i> adaptativo aplicado às imagens RGB e RE ..	49
Tabela 10 Resultados da avaliação das imagens RGB e RE convertidas para o espaço de cor HSV	52
Tabela 11 Índices RGB e RE com melhor performance.	53
Tabela 12 Erro dos Índices RE e RGB com melhor performance	54
Tabela 13 Resultados da avaliação dos índices de vegetação aplicados às imagens RGB e RE	55
Tabela 14 Resultados da avaliação dos vários métodos de segmentação e métodos baseados em HSV e VI aplicados às imagens RGB e RE	56
Tabela 15 Resultados dos vários métodos para isolamento de <i>clusters</i>	63
Tabela 16 Validação do número de árvores detetadas: comparação entre a contagem manual e automática	70
Tabela 17 Caracterização da parcela estudada com análise multi-temporal em relação ao numero de árvores detetadas.	74
Tabela 18 Crescimento e declínio da vegetação da parcela estudada ao longo do período de tempo que abrangeu as três campanhas.....	74
Tabela 19 Análise multi-temporal ao nível individual da árvore: estimativa da área de cobertura e do diâmetro da copa e estimativa da altura de cada árvore presente na amostra estudada. ..	76

Glossário, acrónimos e abreviaturas

Glossário de termos

Off-the-shelf – Termo usado para descrever um produto que está disponível imediatamente e não precisa ser especialmente feito para se adequar a um propósito específico.

Cluster – Grupo de dados que foram agrupados automaticamente de acordo com o seu grau de semelhança.

Threshold – Método de limiar que substitui cada pixel de uma imagem com um pixel preto se a intensidade da imagem $I_{i,j}$ for inferior a uma constante fixa T (isto é, $I_{i,j} < T$), ou um pixel branco se a intensidade da imagem for superior a constante T .

Lista de Siglas e de Acrónimos

Sigla/Acrónimo	Expansão
ALSM	<i>Airborne Laser Swath Mapping</i>
CHM	<i>Canopy Height Model</i>
CIR	<i>Color InfraRed</i>
DEM	<i>Digital Elevation Model</i>
DSM	<i>Digital Surface Model</i>
DTM	<i>Digital Terrain Model</i>
FIR	<i>Far InfraRed</i>
GCP	<i>Ground Control Point</i>
GNSS	<i>Global Positioning Systems</i>
GPS	<i>Global Positioning System</i>
GSD	<i>Ground Sample Distance</i>
HSI	<i>Hue, Saturation, Intensity</i>
IMU	<i>Inertial Measurement Unit</i>
LAI	<i>Leaf Area Index</i>
LIDAR	<i>Light Detection And Ranging</i>
LOG	<i>LaPLace Gaussiano</i>
NIR	<i>Near InfraRed</i>
PA	<i>Precision Agriculture</i>
RE	<i>RedEdge</i>

Sigla/Acrónimo	Expansão
RGB	<i>Red, Green, Blue</i>
SFM	<i>Structure From Motion</i>
UAS	<i>Unmanned Aerial Systems</i>
UAV	<i>Unmanned Aerial Vehicle</i>
VI	<i>Vegetation Index</i>

Abreviaturas

Abreviatura	Significado
e. g.	por exemplo
et. al.	e outros (autores)
etc.	etecetera, outros

1 Introdução

No início da década de 80, do século passado, o Castanheiro Europeu (*Castanea sativa*, Mill.) começou a assumir um papel, cada vez mais importante na economia portuguesa (Martins et al., 2015). No entanto, problemas fitossanitários - tais como a doença da tinta (*Phytophthora cinnamomi*) (Vettraino et al., 2005; Valverde et al., 2017) e o cancro do castanheiro (*Cryphonectria parasitica*) (Rigling & Prospero, 2017; Valverde et al., 2017) - juntamente com outras ameaças, como a vespa da castanha (Battisti et al., 2014) e deficiências nutricionais (Portela et al., 2003) – fizeram diminuir o número de castanheiros, com consequente impacto na produção da castanha (Martins et al., 2014). Considerando estes fatores, existe a necessidade de existência de técnicas de deteção eficazes para controlar e mitigar o risco de ocorrência destes problemas, e, assim, assegurar a sustentabilidade do seu cultivo. Geralmente, a avaliação deste tipo de problemas é realizada manualmente, através de observação no terreno sobre uma amostra limitada de indivíduos. Trata-se de uma tarefa bastante árdua e morosa, não correspondendo à forma mais eficaz de combater os problemas descritos, devido à sua morosidade e custos associados à deslocação ao local. Alternativamente, a utilização de plataformas de deteção remota está a tornar-se cada vez mais corrente para executar tarefas relacionadas com operações de monitorização de terreno (Getzin et al., 2012; Toth & Józków, 2016), incluindo o diagnóstico baseado em características da vegetação, as quais não implicam a deslocação ao terreno e podem ser executadas num curto espaço de tempo.

Entre as diferentes plataformas aéreas de deteção remota disponíveis, os veículos aéreos não tripulados (VANT) ou *Unmanned Aerial Vehicle* (UAV), são capazes de fornecer imagens de alta resolução temporal e espacial, recolhidas a partir de diferentes sensores, com uma versatilidade notável, de fácil uso e baixo custo (Getzin et al., 2012; Pajares, 2015; Toth & Józków, 2016). O processamento das imagens obtidas por VANT, permite a obtenção de vários produtos, tais como, Modelos Digitais de Elevação (MDE – DEM na terminologia anglo-saxónica) e imagens (normalmente mosaicos) ortorretificadas. Estes produtos são de grande utilidade para tarefas de monitorização de vegetação, pois, este tipo de dados, permite a deteção e a determinação de características da vegetação, tais como a altura e a área coberta. É, também, possível identificar plantas individuais, o que possibilita contagens, por exemplo, de árvores. Para além da elevada resolução das imagens e da diversidade dos dados fornecidos, os VANT destacam-se, também, pela dimensão da área coberta, num período de

tempo curto, tornando-os numa ferramenta muito flexível e económica (Berni et al., 2009; Colomina & Molina, 2014), quando comparados com outras plataformas de deteção remota, tais como satélites ou aeronaves tripuladas (Matese et al., 2015). A aplicação de técnicas de processamento digital de imagem, a imagens obtidas com os VANT, permite a determinação de diferentes características relacionadas com a vegetação, tais como: área ocupada por vegetação numa determinada parcela de terreno, avaliação do vigor vegetativo para fins de otimização da sementeira ou para deteção de doenças e/ou pragas, entre outras tarefas que promovem a sustentabilidade agroflorestal, numa dada época, mas também numa perspetiva multi-temporal (Pádua et al., 2017). Assim, os VANT, apresentam-se como uma ferramenta muito promissora para aplicações que visam a avaliação do estado fitossanitário dos castanheiros. As imagens adquiridas pelos VANT permitem detetar problemas bióticos e abióticos, em estados iniciais de desenvolvimento o que, por sua vez, permitirá prevenir danos graves, como a perda das colheitas, com fortes impactos financeiros.

A Universidade de Trás-os-Montes e Alto Douro (UTAD), nomeadamente, através do seu grupo, referência a nível nacional no estudo do castanheiro e das respetivas doenças, realizou um estudo na região da Padrela, concelho de Valpaços (Martins et al., 2014). Esta área corresponde a uma das maiores zonas de produção de castanha a nível nacional. As imagens aéreas de elevada resolução foram adquiridas em julho de 2014, com o objetivo de comparar o desenvolvimento da cultura com dados obtidos em 2006. Concluiu-se que em 56% da área analisada, o desenvolvimento da copa foi caracterizado por um crescimento de apenas 5% e uma recessão grave. No entanto, o processo de análise, no estudo de Martins et al., (2014), foi realizado manualmente, sendo uma tarefa demorada e que exige a seleção de áreas de amostragem.

De modo a superar as desvantagens do processo anteriormente apresentado, pretende-se, no âmbito deste trabalho, estudar e desenvolver uma metodologia automática para deteção de castanheiros e avaliação do seu desenvolvimento. Assim, este estudo foi realizado analisando a mesma região considerada em Martins et al., (2014), recorrendo, não só às imagens de julho de 2014, mas também às imagens mais recentes, adquiridas em setembro de 2015 e em julho de 2017. As várias campanhas realizadas proporcionaram a obtenção de imagens no espaço de cor *red-green-blue* (RGB) e infravermelho próximo (*Near-infrared*, NIR). A contagem do número de árvores e a extração individual de dados como altura, diâmetro da copa e características da área da copa, estão no cerne desta metodologia, que visa melhorar o tempo de manipulação e processamento de dados, assegurando, assim, a

eficácia para atingir o objetivo descrito. Para além da extração das características individuais das árvores, a metodologia desenvolvida no âmbito deste trabalho inclui, também, a análise multi-temporal, que correlaciona características extraídas a partir de imagens aéreas da mesma área em períodos distintos, permitindo, desta forma, extrair diferenças de características ao longo do tempo e, assim, possibilitar a monitorização através da observação de progresso/regressão nas culturas do castanheiro, de forma mais fácil e mais rápida.

1.1 Objetivos

Na sequência do anteriormente apresentado, nomeadamente da importância que o setor do castanheiro veio a assumir ao longo dos últimos anos, tornando-se, em algumas regiões transmontanas, numa monocultura e da qual dependem muitas famílias, é imperativo automatizar os processos de monitorização desta espécie. Assim, o objetivo principal deste trabalho consiste no desenvolvimento de um método capaz de auxiliar os produtores na gestão de soutos, recorrendo à manipulação de imagens aéreas de grande resolução, obtidas por VANT. Deste objetivo principal, emanam vários objetivos específicos:

- Realizar um estudo sobre as diversas soluções, existentes na bibliografia, para aferir a melhor metodologia a desenvolver;
- Aplicar e analisar os resultados providenciados pelas várias metodologias estudadas;
- Desenvolver um algoritmo de gestão de soutos capaz de obter informações como:
 - Número de castanheiros presentes na parcela;
 - Área de coberto dos castanheiros, a nível individual e a nível da parcela;
 - Diâmetro individual da copa de cada castanheiro;
 - Altura individual de cada castanheiro;
 - Crescimento/regressão da copa e aumento/diminuição do número de castanheiros ao longo dos anos, através de análises multi-temporais.
- Realizar uma avaliação do desempenho do método proposto.

1.2 Metodologia

Os trabalhos que conduziram aos resultados e às conclusões refletidos neste documento, tendo por referência o problema e os objetivos definidos, foram desenvolvidos de acordo com o método científico que caracteriza a investigação nas ciências exatas, pelo que proporciona objetividade e detalhe, na forma como os resultados apresentados foram atingidos, mas também, a fiel reprodução, passo a passo, dos testes realizados.

Assim, para a realização deste trabalho começou-se por um levantamento bibliográfico sobre os vários métodos de aquisição de imagens aéreas e os mais utilizados na área agroflorestal, assim como as várias técnicas de processamento digital de imagem para extração de vegetação.

Numa segunda fase, foram testados os vários métodos de processamento digital de imagem estudados no levantamento bibliográfico, de modo a selecionar o melhor método no caso específico dos castanheiros.

Seguiu-se o desenvolvimento do algoritmo, os testes de desempenho, e a comparação entre os diversos métodos testados.

Por fim, foram realizadas experiências de avaliação do método proposto, por comparação dos resultados obtidos com dados de campo, obtidos por métodos manuais, para validar o método proposto.

1.3 Organização da dissertação

Este documento está dividido em cinco capítulos, os quais abordam os assuntos e os temas identificados na definição dos objetivos apresentados anteriormente. Depois deste capítulo introdutório, no Capítulo 2 apresenta-se uma descrição detalhada da espécie de castanheiro mais comum em Portugal e na Europa (*Castanea sativa*), abordando a sua importância económica, sobretudo para a região norte do país, identificando, também, as principais ameaças à espécie. É, ainda, no Capítulo 2 que são introduzidos os conceitos mais relevantes sobre os VANT, através de uma breve revisão do estado da arte. O capítulo termina com uma abordagem às técnicas de processamento digital de imagem, onde são analisados e descritos os principais conceitos sobre os mesmos.

O Capítulo 3 aborda o método proposto na execução deste trabalho, onde é descrito o seu funcionamento por etapas, sendo apresentados os vários métodos testados em cada uma.

No capítulo 4 são apresentados os materiais utilizados de uma forma mais detalhada, nomeadamente as plataformas aéreas utilizadas na recolha das imagens, sendo descritos os dados obtidos pelas mesmas. Estas áreas de estudos foram utilizadas para efetuar validações do método proposto no capítulo 3, sendo estes comparados com dados de campo, obtidos por métodos manuais. Neste mesmo capítulo são apresentadas e discutidas análises multi-temporais.

Finalmente, no Capítulo 5, apresentam-se as conclusões assim como uma reflexão sobre as perspetivas de futuro e dos principais desafios que se colocam, perspetivando, também, qual poderá ser a contribuição do candidato para esses cenários.

2 Estado da arte

Neste capítulo é apresentado uma breve história do castanheiro mais comum em Portugal, *Castanea sativa*, onde também é apresentado as suas principais características e usos do seu fruto e madeira, sendo também demonstrado a sua distribuição na Europa e a sua importância na economia portuguesa.

Em relação aos VANT, são apresentados os vários tipos existentes e os tipos de dados que é possível obter com estes, assim como outras tecnologias de deteção remota. Também são demonstrados os vários tipos de sensores que os VANT podem possuir e o tipo de informação que cada um oferece, sendo apresentado no final várias aplicações desenvolvidas para monitorização de vegetação através da combinação dos sensores apresentados com VANT.

Finalmente, é apresentada uma revisão bibliográfica de várias técnicas de segmentação de processamento digital de imagem, estando estas divididas em técnicas comuns aplicadas às mais diversas áreas e técnicas aplicadas mais especificamente na área agroflorestal.

2.1 *Castanea sativa*

Entre as várias espécies de castanheiros, a *Castanea sativa*, é a espécie que predomina em Portugal e também na Europa. Há registos e indícios que comprovam a existência desta espécie no território português há muitos séculos, pelo que é considerada como uma espécie indígena. Contudo, também existem alguns sinais de que possa ter sido introduzida na Península Ibérica durante a época dos romanos, vinda da Ásia Menor.

Existem dois tipos de castanheiro – o bravo e o manso –, consoante a forma de regeneração e o tipo de exploração que se pretende. A um povoamento de castanheiros mansos, vocacionados para produzir frutos (castanhas), dá-se o nome de “Souto” e a um povoamento cujo objetivo é produzir madeira, dá-se frequentemente o nome de “Castiçal”. O castanheiro bravo é cultivado em alto fuste ou talhadia, de forma a poder retirar-se peças de madeira de dimensões adequadas, cujo valor varia linearmente com a sua dimensão. Na produção de mobiliário, a madeira de castanho já é, muitas vezes, vendida ao peso, claro indicador do seu valor atual.

2.1.1 Breve história

A ampla difusão e a gestão ativa do castanheiro, por parte do Homem, resultaram no estabelecimento da espécie nos limites de seu nicho fundamental, o que torna hoje difícil traçar a sua origem e a sua ecologia. A ocupação natural mais provável desta espécie é delimitado por várias macrorregiões: a região Transcaucásica, noroeste da Anatólia, o interior do mar Tirreno, da Ligúria, ao sul da Itália, ao longo da cordilheira Alpina, da costa da Cantábrica, na Península Ibérica e, provavelmente, também da Península Grega (Peloponeso e da Tessália) e do nordeste da Itália (Colli Euganei, Monti Berici, Emilia-Romagna) (Kaltenrieder et al., 2010). As primeiras evidências inequívocas de cultivo de castanheiros são relatadas em dados epidemiológicos de várias regiões da península da Anatólia, do nordeste da Grécia e do sudeste da Bulgária e datam de cerca de 2100-2050 a.C., enquanto a evidência neolítica (4000 a.C.) de cultivo, juntamente com nozes e cereais, surge em Itália. No entanto, a produção de castanha só se tornou subsidiária na antiga civilização grega e no mundo latino pré-cristão. O papel do castanheiro, no território italiano, pode ter mudado no início da era cristã, quando as pessoas perceberam que a madeira produzida a partir do castanheiro era de muito boa qualidade e muito versátil. Os romanos podem, portanto, ter introduzido a ideia de cultivar a castanha e, em certos casos, a própria árvore, contudo não existe nenhuma evidência de plantação sistemática das árvores (Conedera et al., 2004).

Atualmente, a área de distribuição desta espécie de castanheiro varia desde o sul da Europa (Península Ibérica, Itália, Balcãs, Ilhas do Mediterrâneo) e África do Norte (Marrocos), para a Europa do Noroeste (Inglaterra, Bélgica) e para a Ásia Ocidental (Nordeste da Turquia, Arménia, Geórgia, Azerbaijão e Síria), em altitudes que variam entre os 200 metros e os 1800 metros (Avanzato, 2009). A Figura 1 apresenta a distribuição geográfica desta espécie. Na Europa, a castanha doce cobre uma área de mais de 2,5 milhões de hectares, sendo que a maior parte da área (89%) está concentrada em apenas alguns países (França, Itália, Espanha, Portugal e Suíça) com uma longa tradição na produção de castanha (Conedera et al., 2004). Os colonizadores europeus introduziram também a espécie noutros continentes, de tal modo que os castanheiros estão hoje em dia presentes em diferentes partes da América do Sul e do Norte, bem como na Austrália (Avanzato, 2009).

De acordo com os dados da FAO (*Food and Agriculture Organization*), em 2016, a produção mundial de castanha estima-se em 2,2 milhões de toneladas, distribuídas por uma superfície

que atinge os 602 mil hectares. A China é o maior produtor mundial, com um volume anual de cerca de 1,8 milhões de toneladas, o que representa aproximadamente 83% da produção total de castanha. A Europa é responsável por apenas 6,3% da produção mundial, destacando-se a Itália, Grécia e Portugal com um peso na produção mundial de 2,6%, 1,4% e 1,2%, respetivamente.




Figura 1 Distribuição de *Castanea sativa* na Europa. Adaptado de (Conedera et al., 2016)

2.1.2 Características

Castanea sativa, é uma árvore muito robusta, de folha caduca, com copa ampla e arredondada, que pode alcançar 20 ou 30 m de altura. Possui um tronco grosso e curto nos exemplares cultivados e mais esbelto e menos ramoso nos exemplares silvestres. A casca é cinzenta, quase lisa e algo verde nos ramos mais jovens, posteriormente castanha escura e gretada longitudinalmente (Conedera et al., 2016).

Em relação às folhas, estas são grandes, alternas, de contorno oblongo-lanceolados e bordo grosseiramente serrado, com os dentes agudos. Medem de 10 a 25 cm de largura por 3 a 7 cm de comprimento. A folha possui um pecíolo relativamente curto, até 2 cm, algo coriáceas e contêm numerosas nervuras laterais, quase paralelas e proeminentes na face inferior, caducas a marcescentes.

As flores nascem em compridas espigas pendentes, que brotam da axila das folhas, sendo estas muito estreitas, amarelas e quase todo o amentilho é ocupado por grupos de flores masculinas, que nascem na axila de uma bráctea ovada. Na base da espiga dispõem-se as flores femininas, agrupadas por 1 a 3 num involúcro comum, tendo um cálice com 5 a 8 lóbulos e com 7 a 9 estiletes salientes (Conedera et al., 2016).

Os frutos (castanhas), possuem uma cobertura coriácea de cor castanha, lustrosa externamente e contêm normalmente uma só semente com uma cobertura membranosa de cor castanha ou amarelada. As castanhas agrupam-se de 1 a 3 no interior de uma cúpula globosa e espinhosa (ouriço), deiscente por 2 a 4 valvas. Segundo o número de castanhas por cúpula, assim varia a sua forma. As principais características referentes à sua flor, folha e fruto são apresentadas na Tabela 1.

Tabela 1 Principais características de *Castanea sativa*

Flor	Início de floração	Maio
	Fim de floração	Junho
	Inflorescência	Amentilho
	Cor	Amarelo
Folha	Perenidade	Caducifólia
	Margem	Serrada
	Limbo	Oblongo-lanceolado
Fruto	Tipo	Glande
	Consistência	Seco
	Maturação	Outubro

2.1.3 Principais usos

Devido ao seu carácter multifuncional, o castanheiro foi cultivado em diferentes sistemas de gestão, de acordo com os produtos e os serviços visados.

A madeira de castanheiro é particularmente adequada para uso externo, graças ao seu alto teor natural de taninos que atua como proteção contra a decadência. Anteriormente, a extração de taninos também era um uso muito comum da madeira (Conedera et al., 2016). Devido à sua alta capacidade de regeneração, a madeira de castanheiro fornece principalmente madeira de fogo, carvão vegetal, madeira para construção de postes e madeira para pequenos produtos (barris, telhas, travessas, etc.). As florestas de castanheiros

puros são raras, com uma cobertura de cerca de 10%, produzindo madeira para os setores da construção ou do mobiliário (M. Conedera & Krebs, 2008).

Os soutos tradicionais para a produção de frutas consistem em campos abertos, geralmente compostos por árvores enxertadas por auto esterilidade das espécies. As frutas comestíveis podem ser consumidas de diferentes maneiras: assadas, fervidas, secas ou transformadas em farinha. Para além deste tipo de consumo, as castanhas também são muito utilizadas para confeccionar bolos e pastéis (Conedera et al., 2016). Trata-se de um fruto rico em hidratos de carbono, isento de colesterol, que contém elementos minerais como o potássio, fósforo, cálcio, magnésio e valores importantes de oligoelementos como o cobre e manganês. Também os aminoácidos e as fibras são componentes relevantes.

2.1.4 Importância económica da *Castanea sativa* em Portugal

A castanha foi, durante muito tempo, o principal alimento das populações rurais de montanha. O fruto, considerado na época de inferior qualidade, era um alimento de eleição para os animais domésticos, com reconhecido sucesso na qualidade da carne, particularmente dos suínos (Borges et al., 2007).

Hoje em dia, em Portugal, a área ocupada com castanheiros é cerca de 35.718 hectares, dando origem a uma produção média de 26.780 toneladas anuais de castanha (FAO, 2016), sendo que 85% da produção nacional se verifica na região de Trás-os-Montes (J. Gomes-Laranjo, 2013). As áreas de mercado mais representativas são Bragança, Chaves, Guarda e Portalegre, onde são produzidas as cultivares Cota, Longal, Judia, Martainha, Rebordã, Bária e Colarinha (J. Gomes-Laranjo, 2013). A nível nacional existem quatro Denominações de Origem Protegida (DOP) para a castanha: Castanha da Terra Fria; Castanha dos Soutos da Lapa, Castanha da Padrela (região estudada neste projeto) e Castanha de Marvão.

Após uma fase de evidente decréscimo, que se fez sentir desde os anos 50 do século XX, assiste-se, desde o início da década de 90 do mesmo século, a um período de evidente ressurgimento da importância da castanha, visível tanto nos maiores níveis de produção atingidos como no aumento da área de souto plantada. Este facto resulta da reconhecida rentabilidade das explorações (Borges et al., 2007) e do incentivo dos subsídios, que podem, igualmente, referir-se razões associadas ao custo e escassez da mão de obra para a atividade agrícola, o que tem levado os proprietários, mesmo os ausentes, a optarem por florestar os seus solos com castanheiros (prevalecendo nitidamente a produção do fruto em detrimento

da madeira). A cultura dos castanheiros permite, ainda, a manutenção da pastorícia, para além de ser favorável ao desenvolvimento da caça na região.

A produtividade média dos soutos em Portugal ronda os 750 kg/ha, ficando bastante aquém dos níveis de produtividade dos países europeus produtores de castanha, como a Itália (2280 kg/ha), a França (1080 kg/ha) e a Grécia (3470 kg/ha) (FAO, 2016).

A procura crescente deste fruto está associada à sua recente inclusão na gastronomia urbana, sendo utilizado de maneiras muito diversas: cruas, assadas, cozidas, fritas, na sopa, com carne, para sobremesas, etc., começando, inclusivamente, a ser mais explorada pela indústria alimentar - congelada, pilada, confitada, em calda, em puré, em flocos, etc (Mundo Português, 2015).

A época de produção e comercialização, duma forma geral, ocorre desde meados de outubro a meados de janeiro, sendo que cerca de 70 a 80 % da castanha destina-se à exportação e os restantes 20 a 30 % ao mercado interno.

A castanha portuguesa impõe-se há décadas no mercado externo pela sua qualidade, sendo um produto que permite manter, com larga vantagem, um saldo positivo na balança comercial (J. Gomes-Laranjo, 2013). Os principais importadores são a Espanha e os mercados tradicionais de emigração portuguesa, nomeadamente o Brasil, a França e a Suíça. As aquisições de castanha ao exterior têm vindo a aumentar nos últimos anos, aproximando-se das 2000 toneladas anuais e provém quase na totalidade de Espanha.

As cotações da castanha, tanto nos mercados de produção, como nos abastecedores, oscilam bastante ao longo da campanha, consoante a variedade e o calibre dos frutos. As variedades Rebordã (Sabugal) e Judia são as mais valorizadas para o consumo em fresco.

Especialmente na região de Trás-os-Montes, esta espécie é por vezes o melhor recurso cultural para vastas áreas, proporcionando aos agricultores bons rendimentos em zonas onde não é possível desenvolver outras culturas. Assim, verifica-se, para além do aparecimento de novas áreas plantadas, a introdução de novas técnicas culturais, o que se tem traduzido num aumento da produção e da melhoria da qualidade da castanha. Também o sector da indústria da congelação da castanha está em crescimento nesta região.

2.2 VANT

Inicialmente, os VANT começaram por ser utilizados, exclusivamente, para fins militares, mas após a Segunda Guerra Mundial, estes começaram a ser usados como alvos ou plataformas de reconhecimento de armas. Contudo, recentemente, fins civis, como a gestão agrícola, despertaram grande interesse pelos VANT.

Pioneiramente, Herwitz et al. (2004) descreveram a utilidade dos VANT para detecção de anomalias de irrigação, fertilização e maturação de frutos de culturas em campos agrícolas. Os autores utilizaram o VANT Pathfinder-Plus (desenvolvido pela NASA) movido a energia solar (com uma extensão de asa de 36,3 m e um peso de 318 kg), com capacidade de voo de várias horas. Este era equipado com câmaras de espectro visível e multiespectral para adquirir imagens (0,5 m e 1 m / pixel, respetivamente) de uma plantação de café no Havai, a 6400 m de altitude. Outro exemplo do uso de grandes VANT de asa fixa, é o caso do TARATS / APV-3 (também desenvolvido pela NASA), que foi utilizado para estudar vinhas na Califórnia (Johnson et al., 2003).

Contudo, na última década, os avanços tecnológicos conduziram ao desenvolvimento de VANT com tamanhos e pesos mais reduzidos (peso inferior a 5 kg), com principal foco na redução do peso e tamanho dos sensores, e aumentos consideráveis de precisão, como a utilização de unidades de medida inercial (IMU) e auto pilotos através de Sistemas Globais de Navegação por Satélite (*Global Navigation Satellite Systems*, GNSS)(Berni et al., 2009; Turner et al., 2012). Geralmente, no caso da gestão agrícola, são utilizados dois tipos de VANT: asa rotativa e asa fixa (Berni et al., 2009; Sugiura et al., 2005; Xiang & Tian, 2011; Zarco-Tejada et al., 2013), tendo estas duas plataformas aéreas as suas vantagens e limitações. Enquanto que os VANT de asa rotativa não tripulados possuem sistemas de voo mais complexos, estes são capazes de realizar voos de altitudes mais baixas, possuem capacidade de suspensão (capacidade de manter uma posição estável em voo) e realizam voos de baixa velocidade. Para além disso, estes VANT são também capazes de cruzar em qualquer direção no campo não possuindo requisitos especiais para levantar e aterrar, o que pode ser crítico em algumas áreas. Os VANT de asa fixa oferecem sistemas de voo mais simples e durações mais longas, aumentando assim a sua capacidade para cobrir áreas mais amplas. No entanto, a altitude de voo é maior, reduzindo assim a resolução da imagem. Estes também não conseguem rodar e percorrer pistas específicas (Zarco-Tejada et al., 2013).

Desta forma, o tipo de VANT utilizado dependerá, do objetivo do estudo ou do produto final desejado.

Concluindo, esta tecnologia possui potencial para revolucionar a agricultura não só a nível temporal e espacial, mas também a fisiologia ambiental num curto espaço de tempo em relação a outras metodologias mais tradicionais (Anderson & Gaston, 2013), como imagens de satélite e voos tripulados (cuja disponibilidade é limitada pelas condições climáticas e custos significativos) (Darren Turner et al., 2012).

2.2.1 VANT e outras tecnologias de deteção remota

As tecnologias tradicionais de deteção remota, englobam as plataformas de aeronaves via satélite, aeronaves tripuladas e equipamentos terrestres. Cada uma destas tecnologias possui benefícios e restrições em relação aos fatores tecnológicos, operacionais e económicos. As altas resoluções espaciais e temporais, flexibilidade e custos operacionais reduzidos, tornam os VANT uma boa alternativa às plataformas tradicionais de controlo remoto para aplicações agroflorestais (Salamí et al., 2014). Os principais fatores que apoiam o forte crescimento dos VANT, estão relacionados à crescente consciencialização sobre os benefícios que esta tecnologia oferece a uma ampla gama de indústrias e setores não comerciais, bem como a introdução de sistemas de baixo custo e de fácil uso. Sendo utilizados como um novo método de aquisição de dados geográficos, os VANT complementam as técnicas existentes, preenchendo a lacuna entre imagens de grande área fornecidas por satélites e aeronaves tripuladas, e imagens de menor cobertura, mas altamente precisas fornecidas por técnicas terrestres.

A fotogrametria dos VANT (Colomina & Molina, 2014) efetivamente abre várias oportunidades para novas aplicações no domínio aéreo de alcance aproximado, apresentando-se assim como uma alternativa de baixo custo à fotogrametria aérea tripulada clássica para mapeamento topográfico em larga escala ou registo 3D detalhado de informações no solo sendo uma solução complementar válida para aquisições terrestres (Figura 2).




Figura 2 Técnicas e plataformas para fins de registo em 3D, de acordo com as dimensões e complexidade da cena. (Adaptado de (Nex & Remondino, 2014))

A Tabela 2 apresenta as principais vantagens e desvantagens das várias técnicas de detecção remota mencionadas anteriormente, nomeadamente, satélites, aeronaves tripuladas, VANT e técnicas terrestres.

Tabela 2 Vantagens e desvantagens das diferentes técnicas de detecção remota (Adaptado de (Pádua et al., 2017))

Tecnologias de detecção remota	Vantagens	Desvantagens
Satélite Figura 3 (A)	• Cobertura extensiva; • Ampla capacidade espectral.	• Baixa resolução; • Tempo de aquisição de imagens; • Cobertura fraca em certas regiões; • Sensível a nuvens.
Aeronave tripulada Figura 3 (B)	• Grande cobertura com um único voo; • Alta-Resolução; • Ampla capacidade espectral;	• Dispendioso (para pequenos projetos); • Tempo de aquisição de imagens; • Dependência do clima; • Sensível a nuvens;

		• Não disponível em regiões remotas.
VANT de asa fixa e de asa rotativa Figura 3 (C, D)	• Baixo custo para pequenos projetos; • Alta-Resolução • Não afetados pelas nuvens devido à sua baixa altitude de voo; • Precisão de posicionamento.	• Baixa cobertura; • Regulamentos podem restringir operações; • Sensíveis ao mau tempo; • Dificuldade em reconstruir áreas homogêneas.
Técnicas terrestres Figura 3 (E)	• Excelente precisão de posicionamento; • Dados reduzidos (apenas os necessários); • Alta-Resolução; • Classificação de dados no local.	• Trabalho intensivo; • Apenas uma linha de visão; • Acessibilidade.

Uma das grandes vantagens da utilização dos VANT para aquisição de dados em comparação com tecnologias como satélites e aeronaves tripuladas, consiste na sua maior flexibilidade e facilidade de operação, permitindo assim a realização de voos recursivos e rápidos. Ou seja, os VANT são muito úteis quando há necessidade de realizar voos a parcelas de média/pequena dimensão. Em relação aos seus custos associados, os VANT quando comparados com aeronaves tripuladas possuem um custo mais reduzido, sendo assim indicados para pequenos projetos com orçamentos reduzidos.

Uma comparação técnica entre VANT de asa rotativa, aeronaves tripuladas e satélites foi realizada por (Matese et al., 2015), para avaliar a sua relação custo-eficácia com foco na agricultura de precisão. Neste estudo, os autores, classificaram os VANT como sendo o equipamento com melhor flexibilidade, independência ótima da cobertura da nuvem e em relação às tarefas de processamento, a resolução e a precisão também foram classificadas como otimizadas. No entanto, o intervalo de cobertura, o mosaico e geocodificação foram classificados como pobres em comparação com as outras duas plataformas. O referido estudo concluiu ainda que, em pequenos campos (5 ha), os VANT de asa rotativa são uma solução mais económica. No entanto, e de acordo com a própria experiência dos autores, estes

afirmam que os VANT de tamanhos mais reduzidos de asa fixa podem ser utilizados até uma área de um quilómetro quadrado - com uma distância de amostra de terra (*Ground Sample Distance*, GSD) de 5 cm/pixel até 10 cm/pixel. Contudo, estes valores de limite dependem sempre da autonomia do VANT utilizado (neste caso, o eBee, produzido pela SenseFly, foi usado como referência). De salientar que, a cobertura da área de imagem, também é influenciada pela altitude de voo (que influencia diretamente o GSD), velocidade, resistência e resolução do sensor.

Assim, os VANT representam uma evolução na aquisição de dados estatísticos agrícolas e florestais de áreas pequenas a médias. Estas plataformas aéreas comerciais de baixo custo combinadas com sensores de imagem de alta resolução permitem obter dados precisos sobre a “saúde das culturas e árvores em larga escala com influência de nuvens insignificantes”(Quiroz, 2015).

A Figura 3 mostra exemplos das várias tecnologias de deteção remota mencionadas anteriormente.




Figura 3 Exemplos de tecnologias de deteção remota. (A) Satélite: ERS-2. (B) Aeronave Tripulada: Helio Courier. (C) VANT de asa fixa: senseFly eBee. (D) VANT de asa rotativa: DJI Phantom 4. (E) Técnica terrestre: Optech ILRIS-3D.

2.2.2 Sensores RGB

Os sensores RGB consistem em sensores de luz visível capazes de captar imagens visíveis ao olho humano, em que a sua luz visível ótica opera na faixa de comprimento de onda, aproximadamente, de 400 nm a 700 nm (Austin, 2011).

Estes sensores equipados em VANT são capazes de fornecer imagens de alta resolução a partir de uma perspectiva aérea, sendo que estas podem ser processadas em mosaicos de ortofotografia, através da junção de um conjunto de imagens (Darren Turner et al., 2012), ou para construir modelos de superfície digitais (DSM), através de algoritmos de reconstrução tridimensional (3D) com base em algoritmos de visão por computador ou estruturas a partir de movimento (SfM) (Nex & Remondino, 2014). Os mosaicos orto fotográficos podem ser utilizados em aplicações que incluam mapas e imagens, contagem de plantas, vigilância, resposta de emergência e topografia. Os DSM podem ser úteis para a construção 3D e mapeamento ou computação de volume.

Frequentemente, as aplicações de detecção remota separam os canais RGB e operam com canais individuais de vermelho, verde e azul. A reatribuição de cores é usada para criar imagens com pseudo-cores, com o intuito de aprimorar determinados recursos que podem ser muito úteis na análise de terrenos. Contudo, embora este tipo de imagem possa fornecer informações visuais valiosas para agricultores e silvicultores, não é muito adequada para avaliação de propriedades vegetais, devido à falta de informação obtida na região NIR, onde ocorre a alta refletância da vegetação (Nebikera et al., 2008).

A Figura 4 mostra exemplos de alguns dos sensores RGB mais utilizados em VANT.



Figura 4 Exemplos de sensores RGB. (A) Panasonic Lumix DMC-TZ71. (B) GoPro 4. (C) Nikon D800.

2.2.3 Sensores infravermelho

Os sensores infravermelho, consistem em sensores em que o seu espectro cobre comprimentos de onda mais longos do que o espectro de luz visível, variando entre os 700 nm (NIR) e os 1 000 000 nm (*Far-infrared*, FIR). Os limites entre o visível e o NIR, numa extremidade, e entre o FIR e as micro-ondas, na outra extremidade, não são precisos e estão abertos a diferentes interpretações (Austin, 2011). A banda NIR, desde os 700 nm a aproximadamente 8500 nm, representa a região onde ocorre uma refletância elevada da planta, sendo, portanto, crucial para a maioria das aplicações agroflorestais. Contudo, normalmente, estas aplicações utilizam bandas NIR entre os 400nm e 1000nm, sendo um intervalo suficiente para discriminar vegetação.

Frequentemente, os sensores NIR, são utilizados em aplicações de agricultura de precisão constituindo a base para a análise da vegetação, onde, vegetação saudável que está em crescimento e com produção de energia a partir da fotossíntese reflete mais na região do NIR. Estes dados quando combinados com dados RGB, podem ser utilizados para cálculos de índices de vegetação (VI), que se baseiam no facto da vegetação refletir diversos comprimentos de onda de forma diferente. A maioria das câmaras *off-the-shelf* comuns possuem filtros que bloqueiam o NIR, no entanto, é relativamente fácil transformar uma câmara RGB numa câmara NIR, removendo o filtro e substituindo-o por um que filtre as bandas vermelhas, verdes ou azuis visíveis.

Enquanto que o olho humano é menos sensível ao NIR, o FIR é inteiramente invisível. Com o aumento da intensidade, esta radiação pode ser interpretada como calor. As câmaras térmicas operam aproximadamente no espectro em comprimentos de onda de 5000 nm a 14000 nm. A intensidade de cada pixel pode ser transformada numa medida de temperatura. Em comparação com as câmaras convencionais, as câmaras térmicas são mais dispendiosas e a resolução da imagem é menor (Mejias et al., 2015). Estes sensores permitem criar mapas térmicos completos (Lagüela et al., 2015), para por exemplo, efetuar gestão de irrigação (Gonzalez-Dugo et al., 2013), avaliar a funcionalidade de painéis solares (Quater et al., 2014) e detetar animais selvagens ou gado (Israel, 2011). A Figura 5 mostra exemplos de alguns sensores NIR mais utilizados em VANT.



Figura 5 Exemplos de sensores RE. (A) Fujifilm X-M1. (B) Panasonic Lumix 7. (C) Canon S110.

2.2.4 Sensores LIDAR

Light Detection And Ranging (LIDAR) consiste numa tecnologia ótica de deteção remota capaz de medir propriedades da luz refletida de modo a obter a distância relativa a um determinado objeto distante. Esta tecnologia é muito utilizada para criar mapas de alta resolução, com aplicações em geodesia, arqueologia, geografia, geologia, geomorfologia, sismologia, silvicultura, física atmosférica, orientação a laser, mapeamento de bandas laser (ALSM) e altimetria a laser (Cracknell & Hayes, 2007).

Ao contrário dos sensores passivos que detetam energia naturalmente emitida por um objeto, o LIDAR utiliza sensores ativos que emitem a sua própria fonte de energia para iluminação. A fonte de energia atinge objetos e a energia refletida dos objetos é detetada e medida por sensores. O LIDAR é um tipo de sensor ativo que utiliza um radar de laser (amplificação de luz por emissão estimulada de radiação) para transmitir um pulso de luz, e um recetor com detetores sensíveis para medir a luz refletida. A distância ao objeto é determinada pela diferença do tempo entre pulsos transmitidos e refletidos através do uso da velocidade da luz para calcular a distância percorrida. A Figura 6 mostra exemplos de alguns sensores LIDAR mais utilizados em VANT.




Figura 6 Exemplos de sensores LIDAR. (A) LeddarTech – Puck VLP-16. (B) LeddarTech – Routescene. (C) LeddarTech – Vu8.

2.2.5 Tipos de dados obtidos por VANT

Atualmente, os tipos de dados mais comum obtidos por VANT, consistem em dados para realizar mapeamento fotogramétrico em larga escala (Hugenholtz et al., 2013; Whitehead et al., 2013). As questões, como a estabilidade da plataforma e o uso de câmaras não métricas, geralmente, significam que a geometria das imagens adquiridas é de qualidade mais baixa do que a obtida nos levantamentos fotogramétricos tradicionais realizados a partir de aeronaves tripuladas (Hardin & Jensen, 2011). Os voos realizados pelos VANT também tendem a adquirir imagens com grande quantidade de sobreposição (Figura 7 (A)), devido à sua baixa altura de voo e à baixa precisão dos sensores de navegação, podendo assim originar diferenças significativas entre a área da imagem estimada durante o planeamento do voo e a cobertura real do solo de cada imagem, especialmente em terrenos montanhosos (Haala et al., 2011; Zhang et al., 2011).

Apesar das desvantagens mencionadas, as baixas alturas de voo normalmente tornam possível a obtenção de imagens com resolução espacial elevada, em que, este nível de detalhe, combinado com baixos custos, flexibilidade no tempo de aquisição de imagens e curtos espaços de tempo entre estes, tornam a fotogrametria baseada em VANT uma opção bastante fiável e atrativa (Crommelinck et al., 2016). Nos últimos vinte anos, as imagens digitais de alta resolução substituíram em grande parte a fotografia aérea analógica, bem como o desenvolvimento de sistemas de navegação a bordo que fornecem informações precisas sobre posicionamento e altitudes. Além disso, normalmente, é incluído uma série de pontos de controlo de terra (*Ground Control Points*, GCP) com precisão no ajuste fotogramétrico. Estes, consistem em alvos especialmente colocados no terreno que são pesquisados por um GNSS aquando a aquisição de imagens por parte do VANT (Hugenholtz et al., 2013), para realização da triangulação aérea.

A triangulação aérea refere-se ao processo pelo qual as posições reais e orientações das imagens de um voo são restabelecidas. Também é prática comum incluir uma série de pontos de verificação, não sendo utilizados durante o processo de triangulação aérea, mas que podem ser usados para posteriormente fornecer uma verificação independente sobre a precisão do ajuste. Após a triangulação aérea, as imagens orientadas podem ser usadas para gerar um modelo de superfície digital (DSM), que fornece uma representação detalhada da superfície do terreno, incluindo as elevações de objetos, como árvores e edifícios.

O processo de produção do DSM cria uma nuvem de pontos ao combinar recursos de vários pares de imagens (Whitehead et al., 2013). Outro tipo de dado que pode ser gerado nesta fase, consiste no modelo de terreno digital (DTM), sendo este produzido através da inclusão de uma filtragem da nuvem de pontos densa usada para produzir o DSM ou através de interpolação de uma nuvem de pontos dispersos (Arefi et al., 2009). Os DTM muitas vezes exigem edição manual para remover a influência de edifícios maiores e áreas com vegetação forte, que, geralmente não são adequadamente filtradas.

Após a criação do DTM e DSM, estes podem ser usados para ortoretificar as imagens originais. A ortoretificação (Figura 7 (A, B)) refere-se à remoção de distorções, que resultam da perspectiva de geometria central associada à fotografia. Uma vez ortoretificadas, as imagens possuem uma geometria ortogonal, sendo usadas para efetuar medições diretas. Para além das medições diretas, as imagens individuais podem ser combinadas num mosaico (Figura 7 (B)), fornecendo assim uma imagem perfeita da área de voo na resolução desejada.

Assim, o processamento fotogramétrico das imagens obtidas por VANT, coloca uma série de desafios, pois as características dessas imagens são mais parecidas com as encontradas em fotogrametria terrestre do que a fotografia aérea convencional (Turner et al., 2014). As imagens obtidas por VANT estão sujeitas a escalas variáveis, altas quantidades de sobreposição e orientações de imagens variáveis (Zhang et al., 2011).



Figura 7 Exemplo de geração de um ortomosaico: (A) Imagens adquiridas pelo VANT. (B) Mosaico ortoretificado (Pádua et al., 2017).

2.2.6 Aplicação dos VANT na monitorização automática

Há um grande número de estudos e projetos que demonstram o grande potencial do uso de VANT para mapeamento e monitorização de vegetação. Um conjunto de casos de estudo em que são utilizados VANT com foco na monitorização/deteção/mapeamento de vegetação está listado na Tabela 3. As aplicações de mapeamento e monitorização envolvem a aquisição e processamento de dados, e os resultados obtidos fornecem a base para tomar decisões e desencadear diferentes ações para a vegetação. Com base no grau de participação da aplicação no processo, foram classificadas as aplicações como passivas, proativas ou reativas.

Tabela 3 Exemplos de aplicações e casos de estudo de monitorização de vegetação com uso de VANT.

Área de aplicação	Caso de estudo
Aplicações passivas	
Monitorização de mudanças climáticas	Mapeando de musgo na Antártida (Lucieer et al., 2017)
	Monitorização da biodiversidade na floresta de Fontainebleau (Gademer et al., 2010)
Monitorização da saúde das pastagens	Determinação da cobertura do dossel e tamanho do seu espaçamento (Rango et al., 2009)
	Monitorização de mudanças na estrutura do dossel (Wallace, 2013)
	Identificação de madeira morta (Dunford et al., 2009)
Inventário de pastagens / florestas	Diferenciação da vegetação de pastagens (Laliberte & Rango, 2009)
	Mapeamento e caracterização de florestas ripícolas (Dunford et al., 2009)
Pesquisa topográfica e mapeamento	Mapeamento do substrato e da vegetação nos rios (Jensen et al., 2009)
	Avaliação da erosão do barranco efémero em campos agrícolas (Frankenberger e al., 2008)
Aplicações proativas	
Combate a incêndios	Deteção e monitorização de incêndios florestais (Merino et al., 2012)
Agricultura de precisão	Modelação da estrutura do dossel (Mathews & Jensen, 2013)
	Deteção de stress hídrico (Zarco-Tejada et al., 2012)
	Estimativa do nível de nitrogénio (Uto et al., 2013)
	Deteção de patógenos (Calderón et al., 2013)
	Amostragem aerobiológica (Techy et al., 2008)
	Monitorização da saúde da planta (Nebikera et al., 2008)
	Mapeamento de ervas invasivas (Herwitz et al., 2004)
	Monitorização da aplicação de herbicida (Xiang & Tian, 2011)
Aplicação reativa	
Pulverização	Pulverização de produtos químicos em culturas (Faiçal et al., 2014)

As aplicações passivas estão desenvolvidas principalmente para aquisição de informações, e não na realização de uma ação direta sobre a vegetação em curto prazo. Exemplos de tais aplicações inclui: estimar a cobertura do dossel, controlar a mudança da vegetação, modelar características biofísicas e bioquímicas e mapear espécies vegetais (Dunford et al., 2009; Hung et al., 2012) . A mudança da vegetação (Rango et al., 2009; Wallace, 2013) é um indicador importante para a mudança climática (Lucieer et al., 2017), conservação da biodiversidade (Gademer et al., 2010), estimativas da saúde da planta e eficácia do tratamento aplicado (Rango & Havstad, 2003). Na agricultura, as mudanças do estado da cultura ao longo do tempo, podem ser extrapoladas, com o intuito de prever o crescimento futuro das mesmas (Sugiura et al., 2005; Xiang & Tian, 2011). As aplicações de modelação e mapeamento são também usadas para a criação de um inventário florestal. Laliberte & Rango, (2009) destacam a capacidade das imagens de VANT para quantificar padrões espaciais, vegetação e solo que não são detetáveis com imagens obtidas por aeronaves pilotadas ou satélite. A alta resolução, baixo custo e flexibilidade dos VANT, são recursos valiosos para obtenção de dados atualizados em ambientes que mudam continuamente, como em zonas ribeiras (Jensen et al., 2009), onde a vegetação e o fluxo do rio estão sempre em constante mudança e ravinas em campos agrícolas (Frankenberger et al., 2008), onde a sua intermitência torna difícil a deteção por topografia e mapeamento topográfico geral. De salientar também a versatilidade dos sistemas baseados em VANT onde estes podem ser utilizados em diferentes contextos, como o caso da plataforma *AggieAir* (Jensen et al., 2009), que está envolvida em projetos agropecuários, ribeirinhos, habitats e mapeamento rodoviário.

As aplicações proativas geralmente monitorizam o estado da vegetação para detetar áreas de doenças, deficiência de nutrientes e ervas invasivas. Estas diferem da aplicação passiva, pois os dados adquiridos são utilizados para decisões sobre ações de curto prazo. A sua principal área de aplicação consiste na agricultura de precisão (*Precision Agriculture*, PA), sendo que a PA permite que fertilizantes, pesticidas, herbicidas e irrigação sejam aplicados às necessidades específicas de cada cultura em cada área específica, em vez de se aplicarem igualmente a todo o campo, melhorando assim o produto e de modo a economizar recursos. Por exemplo, a monitorização do estado da água presente na vegetação (Baluja et al., 2012; Berni et al., 2009; Sugiura et al., 2005; Zarco-Tejada et al., 2012) é amplamente divulgado na literatura sendo conotada como necessária para otimizar as estratégias de irrigação. O mapeamento de nitrogénio (Tokekar et al., 2016) também pode ser usado para orientar

tarefas de fertilizantes. A amostragem aerobiológica (Techy et al., 2008) permite aos fitopatologistas, detetar, monitorizar e prever a disseminação de patógenos de alto risco em plantas em campos agrícolas. Calderón et al., (2013) avaliaram métodos para a detecção precoce de *Verticillium wilt*, que consiste na doença mais limitante em todas as regiões tradicionais de oliveiras em todo o mundo. Outro campo de aplicação relevante onde é necessária uma resposta rápida e eficiente é a luta contra os incêndios, sendo estes uma catástrofe devastadora para a floresta. Para combater este problema, já foram apresentadas experiências de detecção remota através de VANT para incêndios florestais. Em Merino et al., (2012), uma frota heterogênea de VANT cooperam na detecção e monitorização de incêndios florestais. Todas as aplicações anteriormente mencionadas, envolvem a aquisição e processamento de dados de forma rápida e recursiva para diferentes períodos de tempo, tornando assim os sistemas baseados em VANT particularmente adequados. No caso de incêndios florestais, a segurança é adicionada às vantagens já mencionadas dos VANT.

Num futuro próximo, é esperado que os VANT sejam utilizados para aplicações reativas, o que aumentaria a sua capacidade autónoma para tomar decisões e executar ações. No Japão, sistemas com base no uso de VANT, estão a ser utilizados para sementeira e pulverização (Austin, 2011). São consideradas aplicações de sementeira ou pulverização inteligentes, aplicações em que os dados produzidos pelos sensores são processados em tempo real e o sistema possui inteligência para reagir de acordo com os resultados da verificação. Em Costa et al.(2012), o feedback obtido de uma rede de sensores sem fio implantada no campo de colheita, é usado para controlar a rota de um VANT de pulverização. Contudo, conforme indicado por Zecha et al. (2013), futuras soluções deste tipo exigirão um intercâmbio padronizado de dados entre componentes do sistema. Outros desafios a serem abordados por soluções baseadas em VANT, são a precisão limitada de dados de posição e orientação, problemas de sincronização entre sensores de imagem e o sistema de navegação GPS, alta variação entre imagens, distorção de perspectiva e alta variabilidade em condições de iluminação (Darren Turner et al., 2012).

2.3 Segmentação de imagens

Segmentação de imagens refere-se ao processo de partição de imagens digitais em diferentes partes. A segmentação é realizada com base num conjunto de pixéis de uma região que são semelhantes, com base em alguns critérios de homogeneidade como cor, intensidade ou textura, onde estes são utilizados para localizar e identificar objetos ou limites de uma imagem (Kandwal et al., 2014). As aplicações práticas da segmentação de imagens incluem identificação e reconhecimento de objetos, reconhecimento facial, processamento de imagens médicas, investigação criminal, sistema de segurança aeroportuária, imagens de satélite, garantia de qualidade em fábricas, entre muitos outros (Smistad et al., 2015; Uijlings, Sande et al., 2013; Uroukov & Speller, 2015; Vieira et al., 2017). Existem várias técnicas de segmentação aplicadas às várias áreas anteriormente descritas, contudo, a seleção da técnica depende do tipo de imagem e da natureza do problema (Kandwal et al., 2014).

2.3.1 Técnicas de segmentação

Atualmente, existem diversas técnicas de segmentação, existindo pequenas diferenças entre estas, não existindo, portanto, um algoritmo aplicável a todos os tipos de imagens digitais, cumprindo todos os objetivos definidos. Assim, o algoritmo desenvolvido para um grupo de imagens nem sempre é diretamente aplicável a imagens de outras classes (Nadernejad et al., 2008). Atualmente, a abordagem de segmentação de imagem divide-se nas seguintes categorias:

- **Baseada na descontinuidade:** onde a subdivisão das imagens é realizada com base em mudanças abruptas na intensidade dos pixéis de uma imagem. O principal foco desta técnica consiste, principalmente, na identificação de pontos, linhas e contornos isolados. Esta categoria inclui algoritmos de segmentação de imagem como a deteção de contornos;
- **Baseada em semelhanças:** em que a subdivisão das imagens é realizada com base em semelhanças da intensidade dos pixéis ou níveis de cinza de uma imagem. O principal foco desta técnica consiste na identificação de pontos, linhas e contornos similares. Esta categoria inclui algoritmos de segmentação de imagem como *threshold* (limiar), crescimento de regiões e junção/divisão de regiões.

2.3.1.1 Métodos de segmentação com base em contornos

Os contornos numa imagem podem ser representados por zonas fronteira e, portanto, estes poderão auxiliar na deteção e segmentação de objetos (Khalifa, 2010; Nadernejad et al., 2008). A deteção dos contornos é feita com recurso a algoritmos que identificam pontos de uma imagem digital em que exista uma mudança abrupta na sua intensidade. Com os pontos identificados, estes são ligados entre si de forma a criar os limites dos objetos presentes na imagem (Khalifa, 2010). Existem diferentes métodos de deteção de contornos, no entanto, os dois mais proeminentes são:

- **Método baseado no histograma dos cinzentos:** onde a segmentação depende da separação do primeiro plano do plano de fundo, através da seleção de um valor limiar (*threshold*) T . Contudo, os valores de *threshold* por vezes não são os ideais, devido à presença de ruído. Assim, são substituídas as curvas do objeto e do fundo por duas curvas gaussianas cónicas (Kang et al., 2009), cuja interseção é escolhida como valor do *threshold* T ;
- **Método baseado no gradiente:** em que o gradiente consiste na primeira derivada da imagem $f(x, y)$, quando existe uma mudança abrupta na intensidade próxima do contorno. Este método também consiste em operadores de gradiente de convolução com a imagem (Kang et al., 2009). O alto valor da magnitude do gradiente consiste em pontos com mudança abrupta entre as intensidades da região, sendo que esses pontos são denominados de pixéis do contorno, e que podem ser interligados de maneira a formar os limites. Normalmente os operadores de *Sobel* (Figura 8 (B)), *Canny* (Figura 8 (C)), *Laplace*, *LaPLace* Gaussiano (LOG), entre outros, são utilizados como operadores deste método. Na prática, os algoritmos de deteção de contorno requerem um equilíbrio entre a deteção precisa de contornos e a redução do nível de ruído. Se o nível de precisão for elevado, o ruído criará a deteção de inúmeros contornos adicionais falsos. Por outro lado, se o utilizador reduzir em demasia o nível de ruído (Kang et al., 2009), pode resultar na redução da precisão dos contornos e muitas das arestas úteis podem não ser detetadas. Assim, o algoritmo de deteção de contorno é geralmente adequado para imagens simples e sem ruído (Varshney et al., 2009).




Figura 8 Métodos de segmentação com base na detecção de contornos: (A) Imagem original. (B) Operador Sobel. (C) Operador Canny.

2.3.1.2 Métodos de *threshold*

A segmentação de imagens através do método de *threshold*, consiste numa segmentação simples, contudo, é uma abordagem bastante eficaz para segmentar imagens com base na região do espaço de imagem, isto é, características da imagem (Varshney et al., 2009). Normalmente, esse método é utilizado em imagens com objetos claros com fundo escuro ou vice-versa. O algoritmo de *threshold* seleciona um valor de limiar adequado T , de modo a dividir os pixels da imagem em várias classes e objetos separados do plano de fundo. Qualquer pixel (x, y) para o qual $f(x, y) \geq T$ é considerado um primeiro plano enquanto que qualquer pixel (x, y) que possui o valor $f(x, y) < T$ é considerado como plano de fundo. Com base na seleção do valor de *threshold*, existem dois tipos de métodos de *thresholding*:

- **Threshold global:** sendo este utilizado quando a distribuição da intensidade entre os objetos do primeiro plano e do plano de fundo são bastante distintas. Quando existe esta distinção entre os objetos, um único valor de *threshold* pode ser usado simplesmente para diferenciar os dois objetos. Assim, neste tipo de *threshold*, o valor do limite T depende unicamente da propriedade do pixel e do valor do nível de cinza da imagem. Os dois métodos de *threshold* global mais comuns são o método de *Otsu* (Otsu, 1979), sendo ilustrado um exemplo da aplicação deste método na Figura 9 (A) e o *threshold* baseado na entropia (Langote & Chaudhari, 2012);
- **Threshold local:** consiste na divisão de uma imagem em várias sub-regiões e, posteriormente, são selecionados vários *thresholds* T_s para cada sub-região, respetivamente. Assim, o *threshold* depende do valor do pixel $f(x, y)$ e da sua posição $p(x, y)$. Os dois métodos de *threshold* local mais comuns são o *threshold* estatístico simples (Figura 9 (B)) e o *threshold* de transformação do histograma baseado em entropia 2-D (Kang et al., 2009).




Figura 9 Métodos de *threshold*: (A) Imagem original. (B) *Threshold* global (Otsu). (C) *Threshold* local (Estatístico simples).

2.3.1.3 Métodos de segmentação com base na região

Em comparação com a segmentação baseada na detecção de contornos, os métodos de segmentação baseados em regiões são relativamente simples sendo mais imunes ao ruído. Ao contrário das técnicas de segmentação baseada em contornos que segmentam a imagem com base nas mudanças abruptas nas intensidades dos pixels vizinhos, os algoritmos de segmentação baseados em regiões segmentam uma imagem em regiões que são semelhantes de acordo com um conjunto de critérios predefinidos (Langote & Chaudhari, 2012). A segmentação baseada na região inclui:

- **Crescimento da região:** consiste no agrupamento de pixels de uma imagem em sub-regiões ou grandes regiões com base num critério predefinido, ou seja, o objetivo deste método, consiste em agrupar um conjunto de pixels com propriedades semelhantes para formar uma região (Langote & Chaudhari, 2012). O crescimento da região pode ser processado em quatro etapas: (1) Seleção de um grupo de pontos na imagem original; (2) Seleção de um conjunto de critérios para determinar pontos semelhantes com base em propriedades como intensidade ou cor do nível de cinza, e, posteriormente configuração de uma regra de inclusão; (3) Crescimento da região adicionando a cada ponto os pixels vizinhos que possuam propriedades predefinidas semelhantes ao pixel do ponto e (4) suspensão do crescimento da região quando não existem mais pixels que correspondam ao critério de inclusão nessa região. Um exemplo da aplicação deste método é demonstrado na Figura 10.
- **Divisão/junção da região:** consiste na subdivisão da imagem num conjunto de regiões arbitrárias não conectadas e consequente junção/divisão da região de acordo com uma condição de segmentação. Esta técnica de divisão particular, geralmente, é implementada teoricamente com base em dados de *quad tree*. *Quad tree*, é uma

árvore de suporte em que cada nó possui exatamente quatro ramos (Langote & Chaudhari, 2012). Para tal, existem duas etapas: (1) divisão da região em quatro ramos e (2) junção de uma região quando nenhuma divisão adicional for possível. Este processo é interrompido quando não for possível mais nenhuma junção.




Figura 10 Método de segmentação com base na região: (A) Imagem original. (B) Crescimento da região (região cor-de-rosa). (C) Imagem binarizada.

2.3.1.4 Métodos de segmentação com base em *clustering*

Clustering consiste na tarefa de aprendizagem sem supervisão, onde é necessário identificar um conjunto finito de categorias conhecido como *clusters* para classificar pixéis (Dehariya et al., 2010). Um critério de similaridade é definido entre os pixéis e, posteriormente, os pixéis semelhantes são agrupados com o intuito de formar *clusters*. Os critérios de similaridade incluem um atributo da imagem, como, tamanho, cor, textura, etc. A qualidade de um *cluster* depende da qualidade dos critérios de similaridade usados e da sua implementação. Métodos de *clustering* são classificados como:

- **Hard clustering:** O *hard clustering* pressupõe que um pixel só pode pertencer a um único *cluster* e que existam limites nítidos entre os diferentes *clusters*. Um dos algoritmos de *hard clustering* mais comum é o *K-means clustering* (Dehariya et al., 2010). Este algoritmo agrupa n pixéis de uma imagem em K número de *clusters*, onde $K < n$ e K é um número inteiro positivo. Inicialmente, os centroides dos *clusters* predefinidos são inicializados aleatoriamente e os *clusters* são formados com base em características de similaridade, como a intensidade do nível de cinza dos pixéis e a distância das intensidades dos pixéis. Um exemplo da aplicação deste método é demonstrado na Figura 11.
- **Fuzzy clustering:** este método pode ser usado em situações onde não existem limites claramente definidos entre diferentes objetos de uma imagem. O *fuzzy clustering* consiste na divisão dos pixéis de entrada em *clusters* ou grupos com base num critério

de similaridade. O critério de similaridade pode ser a distância, a conectividade, a intensidade, entre os diversos pixéis. O método inclui os algoritmos FCM (*fuzzy C means*), GK (*Gustafson-Kessel*), GMD (*Gaussian Mixture Decomposition*), FCV (*fuzzy C varieties*), entre outros.




Figura 11 Método de segmentação com base em *clustering*: (A) Imagem original. (B) *Clustering* de 3 regiões. (C) *Cluster 1*. (D) *Cluster 2*. (E) *Cluster 3*. (F) Binarização do *cluster 3*.

2.3.1.5 Segmentação com base em redes neurais

Neste método, inicialmente, a imagem é mapeada para uma rede neuronal onde cada “neurônio” representa um pixel (Kang et al., 2009; Pal & Pal, 1993). A rede neuronal é treinada com um conjunto de amostras de treino para determinar a conexão e os pesos entre os nós. A segmentação da rede neuronal inclui duas etapas importantes: (1) Extração de recursos: consistindo na determinação dos dados de entrada da rede neuronal; (2) Segmentação da imagem: realizada com base nos recursos extraídos das imagens. A rede neuronal baseada na segmentação possui três características básicas:

- Computação rápida e capacidade de computação altamente paralela, tornando assim adequado para aplicações em tempo real;
- Melhoramento dos resultados da segmentação quando os dados se desviam de uma situação normal;
- A sua alta robustez torna o método imune ao ruído.

2.3.2 Técnicas de segmentação na área agroflorestal

A visão por computador tem sido amplamente utilizada e estudada na área agroflorestal para detecção e identificação de vegetação (culturas e ervas invasivas). Após muitas décadas de estudo, a visão por computador melhorou, por exemplo, a gestão da qualidade dos sistemas de controlo de ervas invasivas (Onyango & Marchant, 2003; Schuster et al., 2007; Søgaaard, 2005), tendo sido também utilizada em outras aplicações agrícolas, como classificação e colheita de frutas (Abbasgholipour et al., 2011; Van Henten et al., 2003). Conforme resumido em Slaughter et al. (2008), muitos investigadores desenvolveram métodos de processamento digital de imagem, com orientação para visão por computador, com foco em diferentes campos e ambientes (em condições controladas e descontroladas). As técnicas de segmentação baseadas em imagens na área agroflorestal envolvem, geralmente, duas etapas principais: pré-processamento e classificação de pixéis (Hamuda et al., 2016), onde o pré-processamento consiste num aprimoramento do contraste da imagem e remoção do ruído e, a classificação de pixéis corresponde à segmentação da imagem. O objetivo inicial em quase todas as abordagens de detecção de vegetação, através de processamento digital de imagem, consiste em segmentar os diferentes pixéis da imagem em duas classes: vegetação (culturas, ervas invasivas e árvores) e fundo (solo e infraestruturas). A remoção do plano de fundo é um passo essencial e deve ser realizado de forma apropriada para evitar qualquer classificação errada. Segundo Hamuda et al. (2016), as tecnologias comuns de segmentação utilizadas para esse fim são: segmentação baseada em índices de cores, segmentação baseada em *thresholding* e segmentação baseada em aprendizagem. Nas próximas subsecções serão apresentadas e descritas as técnicas anteriormente mencionadas.

2.3.2.1 Técnicas com base em índices de vegetação

O Índice de Vegetação Espectral (*Vegetation Index* - VI), pode ser definido como um conjunto de operações aritméticas aplicadas em diferentes bandas (podendo ser bandas RGB, NIR ou uma junção das duas), que geralmente são utilizados na detecção remota para extração de diferentes características como estado de água, vigor vegetativo, presença de doenças, estimativa de biomassa, etc. (Pádua et al., 2017).

Hunt et al., (2010), testaram um sistema de câmaras montadas num VANT em dois campos de trigo fertilizados de forma variável no inverno e encontraram uma boa correlação entre o Índice de Área da Folha (*Leaf Area Index* - LAI) e o Índice de Vegetação de Diferença Verde Normalizada (*Green Normalized Difference Vegetation Index* - GNDVI). Os autores

afirmam que as imagens resultantes podem ser usadas para obter informações quantitativas sobre crescimento e saúde da vegetação. Na **Erro! A origem da referência não foi encontrada.** é demonstrada a aplicação do índice de vegetação GNDVI com posterior aplicação do Método de *Otsu* para binarizar a mesma.




Figura 12 Segmentação de vegetação com aplicação de ExG e Método de *Otsu*: (A) Imagem original. (B) Imagem ExG. (C) Imagem binarizada pelo Método de *Otsu*

Rasmussen et al., (2016) avaliaram a confiabilidade dos VI derivados de câmaras *off-the-shelf* montadas em VANT, assim como efetuaram uma avaliação das deficiências na aquisição de imagens e análise dessas imagens para posterior aplicação. Para tal, os autores utilizaram um VANT rotativo e um VANT de asa fixa, câmaras de luz visível (RGB), câmaras de cor infravermelha (CIR) e quatro VI diferentes (*Excess Green* - EXG, *Normalized Green Red Difference Index* - NGRDI, *Normalized Difference Vegetation Index* - NDVI e *Enhanced Normalized Difference Vegetation Index* - ENDVI). Os autores concluíram que os VI baseados em imagens adquiridas a partir de VANT ou câmaras terrestres com sensores avançados têm a mesma capacidade de quantificar as respostas das culturas aos tratamentos aplicados às mesmas. No entanto, três aspetos devem ser considerados: (1) é necessária estabilidade para condições de luz ambiente; (2) em condições de sol, a variação da refletância angular em relação ao procedimento de cultivo da parcela não deve ser desprezada; (3) o software para a produção de mosaicos requer testes para avaliar a refletância bidirecional.

Conforme relatado em estudos anteriores, os índices de vegetação revelaram ser uma boa ferramenta para deteção de vegetação presente em imagens aéreas. Assim, os VI podem ser usados para detetar vegetação presente numa imagem e efetuar análises tais como a estimativa da área de cobertura da mesma. Na Tabela 4 estão listados os VI mais comuns para deteção de vegetação, estando estes divididos em VI que utilizam apenas informação RGB e VI que utilizam uma combinação de informações RGB e RE.

Tabela 4 Lista de VI mais comuns para detecção de vegetação

VI que requerem imagens RGB e RE		
Nome	Fórmula	Referência
<i>Blue Normalized Difference Vegetation Index</i>	$BNDVI = \frac{RE - Blue}{RE + Blue}$	(Hancock and Dougherty, 2007)
<i>Difference Vegetation Index</i>	$DVI = RE - Red$	(Tucker, 1979)
<i>Enhanced Vegetation Index</i>	$EVI = G \left(\frac{RE - Red}{RE + 6 * Red - 7.5 * Blue + 1} \right)$	(Justice et al., 1998)
<i>Excess RedEdge</i>	$ExRE = 2 * RE - Green - Blue$	Derivado do ExG
<i>Green Difference Vegetation Index</i>	$GDVI = RE - Green$	(Sripada et al., 2006)
<i>Green Normalized Difference Vegetation Index</i>	$GNDVI = \frac{RE - Green}{RE + Green}$	(Gitelson et al., 1996)
<i>Green Soil-Adjusted Vegetation Index</i>	$GSAVI = \frac{RE - Green}{RE + Green + L} * 1.5$	(Sripada et al., 2006)
<i>Modified Soil-Adjusted Vegetation Index</i>	$MSAVI = \frac{(RE - Red) * 1.5}{RE + Red + 0.5}$	(Qi et al., 1994)
<i>Normalized Difference Vegetation Index</i>	$NDVI = \frac{RE - Red}{RE + Red}$	(Rouse et al., 1974)
<i>Optimized Soil-Adjusted Vegetation Index</i>	$OSAVI = \frac{1.5(RE - Red)}{(RE + Red + 0.6)}$	(Rondeaux et al., 1996)
<i>Soil-Adjusted Vegetation Index</i>	$SAVI = \frac{RE - Red}{RE + Red + 0.5} * 1.5$	(Huete, 1988)
VI que requerem apenas imagem RGB		
Nome	Fórmula	Referência
<i>Excess Green</i>	$ExG = 2 * Green - Red - Blue$	(Woebbecke et al., 1995)
<i>Green-Blue Vegetation Index</i>	$GBVI = \frac{Green - Blue}{Green + Blue}$	(Kawashima and Nakatani, 1998)

<i>Green-Red Vegetation Index</i>	$GRVI = \frac{\text{Green} - \text{Red}}{\text{Green} + \text{Red}}$	(Tucker, 1979)
<i>Modified Green Red Vegetation Index</i>	$MGRVI = \frac{\text{Green}^2 - \text{Red}^2}{\text{Green}^2 + \text{Red}^2}$	(Bendig et al., 2015)
<i>Red Green Blue Vegetation Index</i>	$RGBVI = \frac{\text{Green}^2 - (\text{BlueRed})}{\text{Green}^2 + (\text{BlueRed})}$	(Bendig et al., 2015)
<i>Vegetation Index Green</i>	$VARIg = \frac{\text{Green} - \text{Red}}{\text{Green} + \text{Red} - \text{Blue}}$	(Gitelson et al., 2002)

2.3.2.2 Técnicas de *threshold*

As técnicas de *threshold* aplicadas na detecção de vegetação com base na segmentação de imagens, geralmente, assumem duas classes, sendo, a classe da vegetação e a classe de fundo (solo e infraestruturas). Muitas das abordagens baseadas em índice de cores consideradas anteriormente utilizaram um *threshold* baseado no método de *Otsu*. No entanto, existem outras abordagens para seleção de *threshold*. Esta seleção adequada desempenha um papel importante na segmentação. Por exemplo, se o valor do *threshold* definido for demasiado elevado, algumas regiões importantes (pixéis da vegetação) podem ser mescladas com outras regiões (pixéis de fundo), originando assim uma sub-segmentação, enquanto que um valor demasiado reduzido pode originar uma sobre-segmentação. Assim, vários investigadores aplicaram diferentes técnicas de *threshold* para resolver estes problemas mencionados, como, *threshold* dinâmico (Searcy & Reid, 1986), *threshold* fixo (Aitkenhead et al, 2003; Hemming & Rath, 2001), *hysteresis thresholding* (Marchant et al., 1998) e *threshold* com base na entropia do histograma (Tellaache et al., 2008). Contudo, apesar das várias técnicas existentes, o método de *Otsu* consiste na técnica de *threshold* mais utilizada devido à sua simplicidade e rapidez.

De acordo com um estudo realizado por (Sahoo et al., 1988), onde foram comparadas as precisões de segmentação de nove métodos de *threshold*, o método de *Otsu* demonstrou o maior valor de precisão em comparação com os restantes. Este método foi também aplicado por Ling & Ruzhitsky (1996) para segmentar e distinguir entre tomate presente numa imagem e o plano de fundo. Este método foi também aplicado em (Shrestha et al., 2004) para separar a vegetação do fundo, onde, removeram os pixéis de ruído em vez de usar dilatação morfológica, uma vez que, não requer tanta computação quanto as operações de dilatação. Gebhardt & Kühbauch (2007) e Gebhardt et al. (2006) desenvolveram um algoritmo para segmentar ervas invasivas em pastagens, através da conversão de imagens

RGB em imagem de escala de cinza e, conseqüentemente, calcular a homogeneidade local, obtendo assim um valor de *threshold* de homogeneidade com intuito de derivar imagens binárias. Kirk et al. (2009) desenvolveram um algoritmo para a classificação de pixels (pixels de vegetação ou solo), de modo a funcionar sob iluminações variadas. O algoritmo possui como base os pixels de verde e a sua intensidade, que são derivados da combinação de valores de pixel vermelho e verde. Os autores aplicaram um *threshold* automático com base na suposição de duas funções de distribuição Gaussiana de intensidades. Enquanto que a distribuição gaussiana com a média inferior representava a distribuição do solo, a distribuição gaussiana com média superior representava a vegetação. Meyer & Neto (2008), examinaram a qualidade da segmentação para alguns índices de cores com o uso do *threshold* de Otsu e *threshold* de zero. Em particular, os índices ExG (*Excess Green*) e o NDI (*Normalized Difference Index*) foram testados com o método de Otsu, enquanto que o índice ExGR (*Excess Green-Red*) foi testado com *threshold* zero. Na Figura 12 é demonstrado um exemplo da aplicação do Método de Otsu numa imagem com o índice de cores ExG. Os resultados mostraram que o *threshold* de zero era suficiente para a binarização de imagens ExGR. Noutro contexto, Guijarro et al. (2011) utilizaram duas abordagens de *threshold* automático para a segmentação da vegetação: método de Otsu e *threshold* baseado na intensidade média. Os resultados mostraram que o método de Otsu produziu sub-segmentação, ou seja, alguns pixels verdes não foram identificados. Conseqüentemente, a abordagem de *threshold* com base na intensidade média foi adotada no estudo, pois produziu uma segmentação rápida e robusta. Por outro lado, o valor médio da intensidade não foi considerado adequado por Burgos-Artizzu et al. (2011) para binarizar uma imagem com níveis de cinza que foi gerada pelos índices de cores combinados, pois o seu valor era menor que o valor calculado pelo método de Otsu. Em vez de utilizarem a média das intensidades, os autores utilizaram a combinação de Otsu com uma operação morfológica.

Com base nos estudos anteriormente referidos, a seleção do método de *threshold* nem sempre é uniforme, onde, em certos estudos, o método de Otsu revelou ser o mais indicado, enquanto que em outras pesquisas, não corresponde ao mais indicado, sendo utilizado outro método de *threshold*. Ou seja, o melhor método de segmentação está sempre dependente do problema associado e das suas características, sendo necessário estudar e identificar os problemas a resolver e só depois seleccionar o método mais adequado.

2.3.2.3 Técnicas com base em *machine learning*

Embora as abordagens baseadas em cores tenham demonstrado resultados de segmentação promissores, há casos em que estas não funcionam corretamente, especialmente em condições com muito sol ou céu nublado. Como resultado destas adversidades, vários investigadores estudaram abordagens mais sofisticadas, incluindo abordagens de *machine learning* supervisionada e não supervisionada, com simples transformação do espaço de cores como HSI (*Hue, Saturation, Intensity*) e LAB (representa a suavidade da cor, onde: L está compreendido entre o branco e o preto; A está compreendido entre vermelho/magenta e verde e B está compreendido entre amarelo e azul).

Meyer et al. (2004) aplicaram a abordagem de *machine learning* não supervisionada denominada de *fuzzy clustering*, para extrair a área de interesse de imagens *ExG* (*Excess Green*) e *ExR* (*Excess Red*). No caso do *machine learning* supervisionada, Tian & Slaughter, (1998) propuseram um algoritmo de segmentação adaptativo do ambiente (*Environmentally Adaptive Segmentation Algorithm* - EASA) aplicado em imagens RGB normalizadas de campos agrícolas para detetar vegetação. Mais tarde, Ruiz-Ruiz et al. (2009) aplicaram o EASA com saturação da matiz (Hue, Saturation) e apenas na matiz (Hue) em vez de espaço de cores RGB, para segmentação de vegetação mais robusta e rápida em condições de campo complexas. Zheng et al. (2009) propuseram um algoritmo de mudança média supervisionada com uma Rede Neuronal de Propagação de Retorno para classificar imagens em regiões vegetais e não-vegetais. Os recursos utilizados no algoritmo foram o espaço de cores RGB e HSI. Por outro lado, Zheng et al. (2010) aplicaram um algoritmo de mudança da média supervisionado, mas com uso de *Fisher Linear Discriminant* para separar vegetação verde de não-verde. O espaço de cores utilizado no algoritmo era LUV em vez de RGB e HSI. Para resolver o problema da iluminação, como regiões com sombras e/ou refletidas, Guo et al. (2013) introduziram um novo método como abordagem de *machine learning* baseada no modelo de árvore de decisão para segmentar a região da planta formando o fundo em imagens RGB.

3 Método proposto

Neste capítulo é apresentado o método proposto para efetuar a detecção e monitorização de castanheiros com base em imagens aéreas de alta resolução, sendo explicado o seu funcionamento genérico, assim como a descrição mais pormenorizada de cada etapa que este possui e os vários testes efetuados.

Para explorar o método proposto, duas imagens (RGB e RE) e o *Canopy Height Model* (CHM) da área de estudo são carregados como entradas. De salientar que o método permanece funcional, mesmo que seja usada apenas como entrada uma imagem RGB ou uma imagem RE. No entanto, os VI que requerem a combinação de imagens RGB e RE deixam de ser funcionais. Desta forma, o método proposto é versátil e robusto, permitindo o uso de imagens resultantes de equipamentos económicos, que normalmente só incorporam sensores RGB.

O modelo de elevação CHM é calculado subtraindo o DTM do DSM. A Figura 13 ilustra esse processo. O CHM é invariante em relação à inclinação do terreno, como mostrado na Figura 13 (C). O uso deste modelo de elevação é crucial, pois permite a remoção de vegetação rasteira, como ervas e arbustos, permitindo assim a análise da vegetação de interesse (neste caso castanheiros). No contexto deste estudo, vários VI foram obtidos a partir da revisão da literatura (capítulo 2.3.2.1) estando listados na Tabela 4, sendo que estes foram implementados e testados no método proposto.




Figura 13 Cálculo do CHM através do DTM e DSM: (A) linha de perfil marcada no DEM. (B) DTM e DSM. (C) CHM resultante da subtração do DTM ao DSM.

O método proposto é descrito no diagrama apresentado na Figura 14 e está organizado em três etapas principais: (1) detecção preliminar de pixels que potencialmente pertencem à copa de castanheiros. Nesta fase é criada uma imagem binária que representa *clusters* de pixels que contêm árvores; (2) é realizada uma operação de isolamento de *clusters* para estimar o número de árvores na parcela analisada; e (3) os parâmetros individuais da árvore são estimados. Os pixels classificados como não pertencentes à copa de castanheiros são mascarados (removidos da imagem), levando a uma extração mais precisa dos parâmetros desejados. Finalmente, é possível realizar uma análise multi-temporal, permitindo, e.g., a detecção de novas ou ausência de árvores nas séries temporais, evolução da copa e altura das árvores ao longo do tempo. Esta análise permite estabelecer uma correlação entre a evolução e os sintomas bióticos e abióticos.




Figura 14 Diagrama do método proposto

3.1 Etapa 1: Segmentação e primeiro *clustering*

O primeiro passo do método proposto baseia-se na seleção preliminar de pixels representando toda a vegetação, principalmente associada a castanheiros. Para tal, as técnicas comuns de segmentação baseadas em *thresholding* não são apropriadas, pois, essas técnicas segmentarão e considerarão tudo o que está presente na imagem. Assim, não existe distinção entre vegetação e não vegetação (Grigillo & Kanjir, 2012), o que resulta numa imagem com outros objetos para além da vegetação (e.g., infraestruturas, solo, estradas e possíveis efeitos das sombras da copa dos castanheiros). Para superar esta limitação, considerou-se o uso de índices de vegetação espectral. A Figura 15 apresenta um exemplo da aplicação do GNDVI. A imagem resultante (Figura 15 (B)) permite a criação de uma máscara da vegetação, através da aplicação do método de *Otsu* (Otsu, 1979), sendo que este efetua um *thresholding* da imagem em segundo plano - correspondente a áreas não vegetativas - e em primeiro plano correspondente, neste caso, à vegetação. O método de *Otsu* pressupõe que a imagem contém duas classes de pixels após o histograma bimodal (pixels do primeiro plano e pixels de fundo). Através do histograma, o método de *Otsu* calcula o *threshold* ótimo, dividindo ambas as classes, de modo a que sua diferenciação combinada (variância intra-classe) seja mínima ou equivalente (pois o quadrado da soma das distâncias quadradas é constante), de modo a que a sua variação inter-classe seja máxima. Após esta seleção, é criada uma máscara binária que contém todos os pixels pertencentes à vegetação. Consequentemente à criação da máscara binária, são aplicadas um

conjunto de operações morfológicas - abrir, fechar e remover objetos pequenos - ao resultado da operação de *threshold*. As operações morfológicas permitem simplificar a imagem binária resultante, de modo a melhorar a detecção de conjuntos de pixels interconectados (ou seja, *clusters* de pixels), conforme apresentado na Figura 15 (C). Assim, torna-se possível a análise a regiões separadamente. Contudo, quando as árvores estão muito próximas, estas apresentam-se conectadas na imagem binária e, conseqüentemente, agrupadas no mesmo *cluster* (Figura 15 (D)). Para superar este problema, o isolamento dos castanheiros conectados é alcançado através da realização de uma análise individual para cada *cluster* na segunda etapa do método proposto (Isolamento de *clusters*), que se baseia no perímetro de *clusters* individuais, pois caso existam árvores conectadas, o seu perímetro será superior ao perímetro de uma árvore isolada. O perímetro de uma árvore isolada é calculado posteriormente com base na moda do perímetro dos *clusters* presentes na parcela.




Figura 15 Segmentação e primeiro *clustering*: (A) Imagem RGB original. (B) Imagem resultante da aplicação do índice GNDVI. (C) Imagem binária resultante do *threshold* (Otsu) e operações morfológicas. (D) *Clusters* com árvores conectadas marcadas a vermelho

De modo a preparar a etapa 2 do método proposto - isolamento de *clusters* - é criada uma estrutura de dados com parâmetros individuais por *cluster*. Esses parâmetros são obtidos a partir da imagem binária sendo eles: perímetro dos *clusters*, centroide e caixa delimitadora. O valor do perímetro do *cluster* é utilizado para encontrar *clusters* com árvores interconectadas, uma

vez que esses *clusters* têm um valor de perímetro maior que os *clusters* isolados. Desta forma, o algoritmo aplicará automaticamente as operações morfológicas para dividir o *cluster* que contenha árvores conectadas em árvores individuais. O centroide do *cluster* (Figura 16) é crucial para associar uma identificação (ID) a cada árvore, enquanto que a caixa delimitadora do *cluster* é utilizada para o cálculo da altura de cada árvore, uma vez que o DEM fornecerá o valor máximo (normalmente a copa da árvore).




Figura 16 Centroides representados na imagem RGB

3.1.1 Testes de segmentação

Como referido no levantamento bibliográfico, não existe um método de segmentação ideal para todos os cenários, ou seja, o melhor método de segmentação dependerá sempre da cena a analisar. Como tal, de modo a determinar o método de segmentação mais adequado para a identificação da vegetação presente na imagem, foi realizada uma comparação entre diferentes métodos de segmentação, nomeadamente, aplicação direta do Método de *Otsu* e de *Threshold Adaptativo*, *K-Means Clustering*, assim como baseados nos Índices de Vegetação e espaço de cor HSV. Para avaliação dos diferentes métodos, foi selecionada uma imagem de referência (Figura 17(A)), onde esta foi segmentada manualmente e criada uma máscara binária (Figura 17(C)) e, posteriormente foi realizada uma comparação entre a máscara binária manual e a máscara binária gerada pelos diferentes métodos. A seleção da imagem de referência teve como base a existência de diferentes infraestruturas para além da vegetação (isolada e conectada), tais como, casas com telhados de cores diferentes e estradas (*outliers*), com o intuito de estudar o comportamento dos diferentes métodos face aos diversos *outliers* que uma imagem possa conter.




Figura 17 Imagem de referência para avaliação dos métodos de segmentação. (A) Imagem RGB. (B) Imagem RE. (C) Máscara binária manual.

A avaliação dos métodos consistiu em três parâmetros: detecção exata, que corresponde à detecção correta por parte do método; detecção em excesso, que corresponde à detecção incorreta, em que o método detetou como vegetação, mas que de acordo com a máscara binária manual não corresponde (falso positivo); e detecção em falta, correspondendo também a detecção incorreta, onde o método não detetou como vegetação, mas que de acordo com a máscara manual, esta era vegetação (falso negativo).

3.1.1.1 *K-Means Clustering*

Como referido no capítulo 2, o método *k-means clustering*, consiste num método de segmentação não supervisionado baseado na região, onde este agrupa os pixéis da imagem em K número de *clusters* de acordo com a sua similaridade. No caso específico do presente estudo, foi aplicado o método na imagem RGB e RE de referência com $K=2$, ou seja, pretende-se que o método agrupe os pixéis da imagem em dois *clusters* distintos - vegetação e não vegetação. Os diferentes *clusters* criados pelo método na imagem RGB e RE estão representados na Figura 18.




Figura 18 Aplicação do método *k-means* nas imagens RGB e RE. (A) *Cluster 1* da imagem RGB. (B) *Cluster 2* da imagem RGB. (C) *Cluster 1* da imagem RE. (D) *Cluster 2* da imagem RE.

Através da Figura 18 é possível aferir que a vegetação, quer na imagem RGB, quer na imagem RE, está representada no *cluster 2*. Contudo, devido ao facto do método não ser supervisionado, tal pode não acontecer em todos os casos, podendo a vegetação estar representada em *clusters* distintos, retratando assim um problema do método para o caso de estudo. No entanto, como a vegetação em ambos os casos se encontra no *cluster 2*, este foi binarizado, de modo a criar uma máscara binária com intuito de efetuar a comparação com a máscara binária manual. Esta comparação está ilustrada na Figura 19 e os dados relativos à sua comparação estão apresentados na Tabela 5.




Figura 19 Comparação das máscaras binárias geradas pelo *k-means* com a máscara binária manual. (A) *Cluster 2* da imagem RGB binarizado. (B) Avaliação do método aplicado na imagem RGB. (C) *Cluster 2* da imagem RE binarizado. (D) Avaliação do método aplicado na imagem RE

De acordo com os resultados representados na Tabela 5, concluiu-se que o método *K-means* possui uma boa performance quando aplicado à imagem RE, possuindo uma taxa de acerto de 96%. Contudo, quando este é aplicado na imagem RGB, apenas possui uma taxa de acerto de 74% com um erro considerável de detecção em excesso de 25%. Esta detecção em excesso corresponde à detecção das infraestruturas e sombras, não sendo assim considerado um método ideal quando aplicado a imagens RGB.

Tabela 5 Resultados da avaliação do método *K-Means* aplicado às imagens RGB

Tipo de imagem	Detecção exata	Detecção em excesso	Detecção em falta
RGB	74%	25%	1%
RE	96%	3%	1%

3.1.1.2 Método de *Otsu*

O método de *Otsu* consiste numa técnica de *threshold* global simples, sendo amplamente utilizada na área de processamento digital de imagem. Este método possui bons resultados quando a distribuição da intensidade entre os objetos pretendidos e o fundo da cena são bastante

distintas, o que neste caso, não se verifica, pois, a imagem é constituída por vários objetos diferentes com intensidades diversas, representando assim um problema para o desempenho do algoritmo. Para superar este problema, seria necessário efetuar um pré-processamento que distinguísse a vegetação dos restantes objetos (e.g. aplicação de índice de vegetação), e após este processamento aplicar o método de *Otsu*. Contudo, neste estudo, foi aplicado diretamente este método mas, sem pré-processamento, de forma a estudar e analisar o seu desempenho em imagens RGB e RE. Na Figura 20, estão ilustradas as máscaras binárias resultantes da aplicação do método nos dois tipos de imagem referidos, assim como a sua avaliação em comparação com a máscara binária manual. Na Tabela 6 estão apresentados os valores da avaliação.




Figura 20 Comparação das máscaras binárias geradas pelo método de *Otsu* com a máscara binária manual. (A) Imagem RGB binarizada. (B) Avaliação do método aplicado na imagem RGB. (C) Imagem RE binarizada. (D) Avaliação do método aplicado na imagem RE

De acordo com os resultados apresentados na Tabela 6, concluiu-se que, a aplicação direta do método de *Otsu* em imagens RGB e RE não consiste no método mais indicado, pois, este possui valores de deteção exata relativamente reduzidos. No caso da aplicação do método na imagem RE, este possui bastantes falsos positivos (18%) e falsos negativos (17%), o que no último caso, representa um grande problema, pois há perda de informação.

Relativamente à aplicação do método na imagem RGB, apesar de este não possuir muitos falsos positivos (2%), possui bastantes falsos negativos (16%), que na sua maioria corresponde a sombras da vegetação e infraestruturas.

Tabela 6 Resultados da avaliação do método de *Otsu* aplicado às imagens RGB e RE

Tipo de imagem	Deteção exata	Deteção em excesso (falsos positivos)	Deteção em falta (falsos negativos)
RGB	82%	16%	2%
RE	65%	18%	17%

3.1.1.3 *Threshold* adaptativo

A diferença entre o método de *Otsu* e o *Threshold* adaptativo, consiste no número de *thresholds* T que são utilizados.

Enquanto que o método de *Otsu* devido a ser um método global, aplica apenas um *threshold* T para toda a imagem, o *threshold* adaptativo, devido a ser um *threshold* local, aplica vários *thresholds* T à imagem. Ou seja, o *threshold* adaptativo, antes de calcular o valor de T, divide a imagem em várias sub-regiões e, posteriormente, seleciona vários valores de T para as várias sub-regiões criadas. A aplicação deste método é ilustrada na Figura 21, onde são demonstradas as máscaras binárias geradas pelo mesmo na imagem RGB e RE, assim como a sua avaliação em comparação com a máscara binária manual. Na Tabela 7 estão apresentados os valores da avaliação.




Figura 21 Comparação das máscaras binárias geradas pelo *threshold* adaptativo com a máscara binária manual. (A) Imagem RGB binarizada. (B) Avaliação do método aplicado na imagem RGB. (C) Imagem RE binarizada. (D) Avaliação do método aplicado na imagem RE.

Através dos resultados apresentados na Tabela 7, verificou-se que a aplicação do *threshold* adaptativo, quer na imagem RGB, quer na imagem RE, não possui detecções satisfatórias, uma vez que em ambos os casos, o método possui uma taxa de erro superior a 40%. Isto deve-se ao facto de o método não ser capaz de discriminar a vegetação da sua sombra e das infraestruturas presentes na imagem.

Assim concluiu-se que, tal como no caso anterior do método de *Otsu*, o *threshold* adaptativo necessita de um pré-processamento para eliminar as infraestruturas e sombras de modo a aumentar a sua percentagem de acerto.

Tabela 7 Resultados da avaliação do *threshold* adaptativo aplicado às imagens RGB e RE

Tipo de imagem	Detecção exata	Detecção em excesso (falsos positivos)	Detecção em falta (falsos negativos)
RGB	59%	38%	3%
RE	45%	46%	9%

3.1.1.4 Espaço de cor HSV

Como referido no levantamento bibliográfico no capítulo 2.3.2.3, o espaço de cor HSV ou HSB consiste num espaço de cor composto pelos componentes *Hue* (Tonalidade), *Saturation* (Saturação) e *Value* ou *Bright* (Brilho), conforme ilustrado na Figura 22.




Figura 22 Representação do espaço de cor HSV (Adaptado de The MathWorks, Inc., n.d.)

Este espaço de cores foi utilizado por alguns autores referido nesse mesmo capítulo para discriminar vegetação presente numa imagem. Para tal, os autores apenas aplicavam threshold na banda Hue, pois é nesta banda que é definida a cor.

No MATLAB, os valores desta banda variam de vermelho a amarelo, verde, ciano, azul, magenta e de volta a vermelho, sendo que estes parâmetros variam de 0 a 1. Assim, neste estudo foi aplicado este espectro de cores na imagem RGB e RE, sendo apenas usado threshold na banda Hue.

No caso da imagem RGB, como a vegetação possui cor verde, o seu threshold varia entre 0.2 a 0.27, que corresponde aos verdes neste modelo de cores, enquanto que, no caso da imagem RE, como a vegetação possui uma cor magenta, o seu threshold está compreendido entre 0.85 e 1. Na Figura 23 estão ilustradas as imagens RGB e RE que foram convertidas para o espaço de cor HSV.




Figura 23 Imagens convertidas para o espaço de cor HSV. (A) Imagem RGB convertida. (B) Imagem RE convertida.

Após a conversão das imagens para o espaço de cor HSV, foi aplicado um *threshold* às mesmas no canal *Hue*, com os valores anteriormente referidos, resultando assim nas máscaras binárias representadas na Figura 24. Tal como nos métodos referidos anteriormente, nesta figura, está ilustrada a comparação entre as máscaras binárias geradas pelo método e a máscara binária manual.




Figura 24 Comparação das máscaras binárias geradas pelo espaço de cor HSV com a máscara binária manual. (A) Imagem RGB binarizada. (B) Avaliação do método aplicado na imagem RGB. (C) Imagem RE binarizada. (D) Avaliação do método aplicado na imagem RE.

Através da Tabela 8, conclui-se que a conversão das imagens para o espaço de cor HSV permite obter resultados bastante aceitáveis, sendo que as imagens base RGB e RE utilizadas, possuem em ambos os casos resultados positivos no parâmetro de detecção exata.

No caso da aplicação da conversão do espaço de cor HSV à imagem RE, esta revelou ser a solução mais adequada, pois teve uma taxa de acerto de 96%. No caso da imagem RGB, apesar da taxa de acerto não ser tão elevada quanto a RE, esta possui 84% de taxa de acerto, podendo ser considerado um valor aceitável. Contudo, neste ultimo caso, o processo possui alguns problemas que também foram detetados em métodos anteriores, uma vez que este não conseguiu discriminar corretamente alguns *outliers* como a estrada ou sombras da vegetação.

Tabela 8 Resultados da avaliação das imagens RGB e RE convertidas para o espaço de cor HSV

Tipo de imagem	Deteção exata	Deteção em excesso (falsos positivos)	Deteção em falta (falsos negativos)
RGB	84%	13%	3%
RE	96%	2%	2%

3.1.1.5 Índices de vegetação

Durante o levantamento bibliográfico referente a índices de vegetação, foi identificada a existência de um vasto número de índices de vegetação (*Vegetation Indices* - VI), que utilizam apenas imagens RGB e que utilizam combinação de imagens RGB com RE.

Assim, de modo a selecionar o VI mais adequado para análise e comparação com os métodos anteriores na imagem de referência, foi realizado um estudo detalhado usando os 17 VI listados na Tabela 4 (capítulo 2.3.2.1) – dos quais 6 VI são baseados apenas em informações RGB e 11 VI baseados em informações RE para além das informações RGB. Os testes foram realizados nas sete áreas apresentadas na Figura 25. A seleção das sete áreas foi realizada de modo a estudar o comportamento dos índices em diferentes condições, como plantações de castanheiros recentes (áreas 3 e 4), castanheiros adultos (áreas 1, 2 e 7) e ambos (áreas 5 e 6). A proximidade entre castanheiros foi também considerada na seleção: castanheiros com espaço regular entre eles (áreas 2, 3, 4 e 7) e castanheiros com áreas de copa sobrepostas (áreas 1, 5 e 6). Os resultados fornecidos pela aplicação das segmentações baseadas em VI foram comparados com segmentações manuais.



Figura 25 Sete áreas selecionadas para identificar o VI com maior percentagem de acerto na identificação de castanheiros.

A Tabela 9 apresenta os resultados de detecção exata dos testes para os VI mais precisos (estando os resultados de todos os índices apresentados no Anexo A). A Tabela 10 representa os valores de erro dos índices RE e RGB, onde o erro é dividido em detecção em excesso (Ex) e detecção em falta (F). Os valores de detecção excessiva correspondem a falsos positivos, ou seja, valores detetados como vegetação através do índice de vegetação, mas que não são classificados como vegetação na segmentação manual. Os valores de deficiência de detecção correspondem a falsos negativos, ou seja, valores que foram classificados como vegetação na segmentação manual, mas que não foram detetados como tal pelo índice de vegetação. Através da Tabela 9 e da Tabela 10 é possível aferir que os VI baseados em RE apresentam um comportamento melhor em relação aos índices que apenas utilizam informação RGB. Contudo, os VI baseados em RGB também apresentam um comportamento muito satisfatório, pois possuem uma taxa de precisão geral superior a 90%.

Tabela 9 Índices RGB e RE com melhor performance, isto é, valores correspondentes a positivos-positivos em comparação com a segmentação manual.

Índices RE							
Índice	Área 1	Área 2	Área 3	Área 4	Área 5	Área 6	Área 7
EXRE	96 %	98 %	97 %	99 %	98 %	99 %	94 %
GNDVI	95 %	97 %	98 %	98 %	96 %	98 %	95 %
GSAVI	95 %	97 %	98 %	98 %	97 %	99 %	95 %
GDVI	94 %	97 %	98 %	98 %	98 %	99 %	93 %
OSAVI	93 %	96 %	95 %	98 %	97 %	98 %	87 %
Índices RGB							
EXG	93 %	95 %	96 %	98 %	95 %	99 %	89 %
GRVI	87 %	94 %	91 %	97 %	92 %	98 %	82 %
RGBVI	93 %	96 %	97 %	98 %	96 %	99 %	90 %

Tabela 10 Erro dos Índices RE e RGB com melhor performance: (Ex) Detecção em excesso (F) Detecção em falta

Índices RE														
	Área 1		Área 2		Área 3		Área 4		Área 5		Área 6		Área 7	
Índice	Ex (%)	F (%)	Ex (%)	F (%)	Ex (%)	F (%)	Ex (%)	F (%)	Ex (%)	F (%)	Ex (%)	F (%)	Ex (%)	F (%)
EXRE	1	3	1	1	0	3	0	1	1	1	0	1	0	6
GNDVI	4	1	2	1	1	1	2	0	4	0	2	0	3	2
GSAVI	4	1	2	1	1	1	2	0	2	1	1	0	2	3
GDVI	3	3	2	1	1	1	2	0	2	0	1	0	2	5
OSAVI	4	3	2	2	2	3	0	2	2	1	1	1	6	7
Índices RGB														
EXG	0	7	0	5	0	4	0	2	0	5	0	1	0	11
GRVI	7	6	0	6	1	8	0	3	3	5	1	1	6	12
RGBVI	0	7	0	4	0	3	0	2	0	4	0	1	0	10

Assim, analisando as tabelas anteriores, foi selecionado o índice com melhor desempenho em Imagens RGB e em imagens RE, de modo a comparar com a imagem de referência.

No caso dos índices RE, o que possuiu melhor desempenho foi o GNDVI, uma vez que, para além de possuir uma taxa de acerto superior a 95% nas 7 áreas, também correspondeu ao índice com menor detecção em falta, ou seja, com menor perda de informação. Em relação aos índices RGB, o que teve melhor desempenho foi o índice RGBVI, com taxas de acerto superiores a 90% e que em relação à perda de informação (detecção em falta), quando comparado com os restantes índices RGB, foi o que menor taxa possuiu. Na Figura 26 estão representadas as máscaras binárias resultantes da aplicação do método de *Otsu* aos índices de vegetação GNDVI e RGBVI, assim como a sua comparação com a máscara manual.




Figura 26 Comparação das máscaras binárias criadas pelos índices de vegetação com a máscara binária manual. (A) Imagem RGB binarizada. (B) Avaliação do método aplicado na imagem RGB. (C) Imagem RE binarizada. (D) Avaliação do método aplicado na imagem RE.

Com base nos resultados apresentados na Tabela 11, aferiu-se que a aplicação dos índices de vegetação em imagens RGB e RE possuíram bons resultados, com taxas de acerto superiores a 93%. O índice GNDVI aplicado na imagem RE demonstrou possuir o melhor desempenho, contudo, o índice RGBVI aplicado na imagem RGB, apesar de possuir uma taxa mais baixa, esta é de 93%, sendo bastante satisfatória.

Tabela 11 Resultados da avaliação dos índices de vegetação aplicados às imagens RGB e RE

Tipo de imagem	Detecção exata	Detecção em excesso	Detecção em falta
RGB (RGBVI)	93%	1%	6%
RE (GNDVI)	96%	3%	1%

3.1.2 Síntese

Após a avaliação efetuada aos métodos de segmentação anteriormente indicados, nomeadamente, *k-means*, *Otsu*, *threshold* adaptativo e, com base em HSV e índices de vegetação concluiu-se que os índices de vegetação permitiram uma melhor performance na discriminação de vegetação em imagens RGB e RE (Tabela 12).

Tabela 12 Resultados da avaliação dos vários métodos de segmentação e métodos baseados em HSV e VI aplicados às imagens RGB e RE

Método	Deteção exata	Deteção em excesso	Deteção em falta
<i>K-means</i> (RGB)	74%	25%	1%
<i>K-means</i> (RE)	96%	3%	1%
<i>Otsu</i> (RGB)	82%	16%	2%
<i>Otsu</i> (RE)	65%	18%	17%
<i>Threshold</i> adaptativo (RGB)	59%	38%	3%
<i>Threshold</i> adaptativo (RE)	45%	46%	9%
Baseado em HSV (RGB)	84%	13%	3%
Baseado em HSV (RE)	96%	2%	2%
Baseado em VI (RGB)	93%	1%	6%
Baseado em VI (RE)	96%	3%	1%

Conclui-se ainda que, a aplicação direta do método de *Otsu* e do *threshold* adaptativo, corresponderam aos métodos de segmentação que tiveram piores resultados, uma vez que estes consistem em métodos de *threshold* simples, onde são necessárias a existência de diferenças significativas entre o primeiro plano e o plano de fundo presentes na imagem. Contudo, quando estes possuem um pré-processamento, como o caso da aplicação dos índices de vegetação, estes revelam ser uma boa solução.

Relativamente aos métodos de segmentação *k-means* e baseado em HSV, apesar de estes terem obtido boa performance quando aplicados a imagens RE (96%), quando aplicados em imagens RGB, o seu desempenho é mais reduzido, sendo inferior a 85%.

Assim, os índices de vegetação, mais especificamente o GNDVI no caso de imagens RE e o RGBVI no caso de imagens RGB, corresponderam ao método selecionado para efetuar segmentação de vegetação, uma vez que, estes possuíram melhor comportamento, quer em

imagens RE quer em imagens RGB, tornando assim o algoritmo mais robusto e flexível no que concerne ao tipo de imagem a ser utilizado.

3.2 Etapa 2: Isolamento de *clusters*

A abordagem da segmentação baseada em VI, é capaz de remover corretamente a maioria das áreas não vegetativas, permitindo assim a detecção de grandes áreas de vegetação. No entanto, o tamanho da copa das árvores pode gerar *clusters* com pixels interconectados que podem incluir várias árvores. No caso específico da monitorização de castanheiros, é necessário distinguir cada árvore individualmente. Para atingir esse objetivo, é efetuada uma análise individual por *cluster* detetada na etapa 1. Este processo começa com a estimativa do perímetro de uma árvore isolada com base na moda dos *clusters* presentes na parcela.

Com a configuração do perímetro padrão, este é comparado ao perímetro de cada *cluster* detetado, onde os *clusters* que possuírem um valor superior são identificados. Em seguida, o perímetro de todos os *clusters* marcados é dividido pelo perímetro médio dos *clusters* presentes na parcela, para estimar o número de árvores presentes em cada *cluster* (Equação 1). Essa estimativa é necessária apenas para iniciar o processo.

$$\#A = \text{round} \left(\frac{P_{cluster}}{\text{média}(P_{clustersT})} \right) \quad (\text{Equação 1})$$

Onde:

#A – número estimado de árvores

$P_{cluster}$ – Perímetro do *cluster* a analisar

$P_{clustersT}$ – Perímetro total dos *clusters* presentes na parcela

Posteriormente ao cálculo da estimativa do numero de árvores presente no *cluster*, é efetuada a operação morfológica de erosão (*erode*) (Figura 27 (A)) recursivamente até o numero de *clusters* atingir o número de árvores estimadas (Figura 27 (B)). Finalmente, o processo é revertido pela aplicação da operação morfológica de dilatação (*dilate*) (Figura 27 (C)), com a separação adequada dos *clusters* através de uma linha de um pixel de espessura.




Figura 27 Isolamento dos *clusters*: (A) *Cluster* original composto por cinco castanheiros conectados. (B) *Clusters* resultantes da operação morfológica de erosão com os respectivos centroides representados. (C) *Clusters* resultantes da operação morfológica de dilatação, resultando em cinco *clusters* desconetados

Após as operações anteriormente descritas, os *clusters* recém-criados serão submetidos a um segundo *clustering* de pixéis, de modo a atualizar o conjunto original, que foi criado na etapa 1. A Figura 28 apresenta o resultado dessa operação, assim como as etapas complementares.




Figura 28 Operação de isolamento de *clusters* aplicada a toda a parcela: (A) *Clusters* com perímetro superior ao perímetro padrão marcados a vermelho. (B) Imagem erodida. (C) Imagem com dilatação com os *clusters* separados marcados a vermelho

3.2.1 Testes para isolamento de *clusters*

Como referido no capítulo anterior, após calculado o índice de vegetação e binarização do mesmo, devido ao tamanho da copa de algumas árvores, estas aparecem conectadas estando representadas no mesmo *cluster*. Porém, é necessário efetuar a separação das mesmas, de modo a estarem representadas em *clusters* diferentes com o intuito de extrair parâmetros individuais. Para as separar, foram realizados testes a métodos de separação de *clusters*, nomeadamente, detecção de círculos através da transformada de *Hough* (Hough, 1962), uma vez que no geral as árvores possuem uma forma geométrica similar a círculos na imagem binária, *WaterShed Transform* e separação através de operações morfológicas. Para efetuar avaliação aos métodos

referidos, foram selecionados três *clusters* que possuem árvores conectadas, estando estes ilustrados na Figura 29 assim como as respectivas máscaras binárias.




Figura 29 *Clusters* com árvores conectadas e sua respectiva binarização. (A) Imagem RGB do *cluster* 1. (B) Imagem RGB do *cluster* 2. (C) Imagem RGB do *cluster* 3. (D). Imagem binarizada do *cluster* 1. (E) Imagem binarizada do *cluster* 2. (F) Imagem binarizada do *cluster* 3.

De salientar que, no caso dos *clusters* 1 e 2, a árvore que se encontra no canto superior esquerdo não está conectada com as restantes na máscara binária, não estando assim representada na mesma. Assim, o *cluster* 1 possui cinco árvores conectadas, no *cluster* 2 existem quatro árvores conectadas e no *cluster* 3 apenas duas.

3.2.1.1 Transformada de *Hough*

A transformada de *Hough* consiste numa técnica de extração de características utilizada na análise de imagens através de visão por computador e processamento digital de imagem (Stockman & Shapiro, 2001). O objetivo da técnica consiste em encontrar padrões paramétricos, como linhas e círculos em imagens com ruído, através de um “processo de votação”. Este processo é realizado num espaço de parâmetros, a partir do qual os candidatos são obtidos como máxima local no espaço de acumulação que é explicitamente construído pelo algoritmo para calcular a transformada de *Hough*.

Inicialmente, a transformada clássica de *Hough* apenas tinha como objetivo a identificação de linhas na imagem, contudo, mais tarde, foi estendida para identificar a localização de formas geométricas, mais especificamente círculos ou elipses.

Deste modo, foi aplicado o método nos *clusters* anteriormente referidos, estando os resultados demonstrados na Figura 30.




Figura 30 Resultados da aplicação da transformada de *Hough*. (A) *Cluster 1*. (B) *Cluster 2*. (C) *Cluster 3*

Após a aplicação do método, verificou-se que este conseguiu identificar e separar as árvores conectadas no *cluster 1* e *3*, identificando cinco e duas árvores respetivamente, enquanto que no *cluster 2*, que possuía quatro árvores, este apenas identificou três. Apesar dos resultados corretos nos *clusters 1* e *3* em relação ao número de árvores, este possui erro na identificação total da árvore, isto é, o método não discrimina na totalidade a forma da copa das árvores.

3.2.1.2 Segmentação *Watershed*

Na morfologia matemática, o método *Watershed*, originalmente proposto por Digabel e Lantu'ejou (Digabel & Lantu'ejou, 1978; Lantuejou, 1978) e mais tarde melhorado por Beucher e Lantu'ejou (Beucher & Lantuejou, 1979), consiste num método de segmentação de imagens que pode ser classificado como uma abordagem de segmentação baseada em regiões (Beucher & Lantuejou, 1979; Serra, 1982; Vincent & Soille, 1991).

A ideia intuitiva subjacente a este método provém da geografia: considera-se uma superfície topográfica e gotas de água que caem sobre a mesma. Uma bacia de retenção é dada pela região tal que, quando gotas de água caem sobre a região, estas percorram o relevo da superfície, através de fluxos descendentes, até chegar a um mesmo mínimo da superfície. As linhas que separam diferentes bacias de retenção são chamadas de *watersheds* (Serra, 1982). Uma formulação alternativa facilmente expressa na forma de algoritmo para a segmentação *watershed* é baseada na simulação de uma inundação: considera-se uma imagem como uma superfície topográfica, onde o objetivo é produzir linhas de divisão nesta superfície. Para tal, é

feito um “furo” em cada mínimo local da superfície, que, posteriormente é submersa a uma taxa constante, de modo a que água percorra todos os mínimos locais. Quando frentes de água, vindas de diferentes mínimos locais, se encontram, é criada uma barreira (linha de separação de objetos). Este processo termina quando apenas os topos das barreiras estão visíveis acima do nível da água, correspondendo às linhas de *watershed*. Dessa forma, a cada mínimo local é associado uma bacia de retenção, ou seja, no caso do processamento digital de imagem, a cada objeto é associado um *cluster*.

Na Figura 31 é demonstrado o resultado da aplicação deste método nos *clusters* de referência.




Figura 31 Resultados da aplicação o método *Watershed*. (A) *Cluster 1*. (B) *Cluster 2*. (C) *Cluster 3*.

Através dos resultados ilustrados anteriormente, verificou-se que o método *watershed* não consiste numa boa solução para separação de árvores conectadas, pois apesar de este discriminar corretamente o *cluster 3*, que possui apenas duas árvores, o método possui erro considerável nos *clusters 1* e *2*, onde detetou sete árvores em ambos os *clusters* quando estes possuem cinco e quatro árvores respetivamente.

3.2.1.3 Operações morfológicas

As operações morfológicas aplicadas no isolamento de *clusters* consistem na erosão e dilatação. A operação morfológica de erosão, consiste em erodir os limites de regiões dos pixels do primeiro plano de uma imagem binária (tipicamente pixels brancos) tornando assim as áreas dessas regiões mais reduzidas. As Figura 32 (A, B e C) apresentam a aplicação deste operador com os centroides de cada região ilustrados a azul. Contudo, é necessário definir um limite de regiões a ser separadas de modo a interromper o processo, caso contrário, o operador efetua erosões infinitamente, eliminando assim todas as regiões. Este limite é calculado através da Equação 2, apresentada no capítulo 3.2, onde é calculado o perímetro de cada *cluster* e dividido pelo perímetro padrão de uma árvore isolada. Todavia, com a aplicação deste operador é verificada perda de informação, uma vez que as áreas originais das regiões são reduzidas. Para reverter este processo, é aplicada a operação morfológica de dilatação, que contrariamente ao

operador de erosão, dilata as regiões, voltando assim à área original, sem as conectar, possuindo estas uma linha de um pixel que as separa. Após a aplicação das duas operações anteriormente referidas, o algoritmo torna-se capaz de identificar separadamente as árvores conectadas em cada *cluster* (Figura 32 (D, E e F)).




Figura 32 Resultados da aplicação de operações morfológicas. (A) Erosão no *cluster* 1. (B) Erosão no *cluster* 2. (C) Erosão no *cluster* 3. (D) Dilatação e detecção de árvores no *cluster* 1. (E) Dilatação e detecção de árvores no *cluster* 2. (F) Dilatação e detecção de árvores no *cluster* 3

Mediante os resultados demonstrados na imagem anterior, verificou-se que através da aplicação das operações morfológicas erosão e dilatação, o algoritmo foi capaz de identificar corretamente as árvores conectadas nos *clusters* 1, 2 e 3, identificando cinco, quatro e duas árvores respectivamente.

3.2.2 Síntese

Na Tabela 13 estão listados, resumidamente, os resultados dos métodos utilizados anteriormente para separação de *clusters* conectados, nomeadamente, transformada de *Hough*, *Watershed* e operações morfológicas. Através desta tabela, verificou-se que as operações morfológicas, erosão (*erode*) e dilatação (*dilate*), consistiram no melhor método, sendo capaz de identificar corretamente todas as árvores conectadas.

Tabela 13 Resultados dos vários métodos para isolamento de *clusters*

	Nº de árvores presentes	Nº de árvores detetadas com transformada de <i>Hough</i>	Nº de árvores detetadas com <i>Watershed</i>	Nº de árvores detetadas com operações morfológicas
<i>Cluster 1</i>	5	5	7	5
<i>Cluster 2</i>	4	3	7	4
<i>Cluster 3</i>	2	2	2	2

Concluindo, as operações morfológicas corresponderam ao método selecionado para efetuar isolamento de *clusters*, etapa 2, do método proposto.

3.3 Etapa 3: Extração de parâmetros

Os centros dos *clusters* - obtidos na etapa 2 - são agora utilizados para extração do diâmetro, área da copa e a altura de cada castanheiro. Através da combinação das máscaras obtidas de ambos os processos de *clustering* de pixéis, é possível a extração dos parâmetros corretos de cada castanheiro individualmente. Em relação à extração do diâmetro, os centros dos *clusters* obtidos a partir da segunda operação de *clustering* de pixéis, são sobrepostos à imagem binária obtida no primeiro passo do método. Isto é alcançado através da medição das distâncias euclidianas de cada *cluster*. Assim, a distância máxima é selecionada e transposta para estimar o diâmetro de cada árvore. A mesma abordagem é aplicada para a obtenção da altura da árvore. No entanto, o valor de altura é extraído do CHM, onde é combinado o centro do *cluster* com o CHM correspondente e obtido o valor máximo do *cluster*, que então, é assumido como o topo da copa. Este procedimento resulta na altura da árvore. Para além destes parâmetros individuais, também é possível o calculo dos parâmetros de toda a parcela, como o número total de árvores e área total de cobertura das copas, somando todas as áreas individuais (Equação 2).

$$A_t = \sum_{i=1}^n \text{area}(\text{cluster}(i)), n = \text{número total de clusters} \quad (\text{Equação 2})$$

O método proposto também é capaz de realizar análises multi-temporais através da sobreposição das máscaras binárias dos vários períodos. Ou seja, os dados baseados em VANT adquiridos em diferentes épocas - ou a partir de qualquer outra plataforma de detecção remota - podem ser usados para criar uma série de tempo, o que permite uma comparação entre diferentes períodos de tempo. A análise multi-temporal representa uma excelente ferramenta para a gestão de soutos, permitindo a avaliação da sua evolução ao longo do tempo tanto ao nível da parcela

como ao nível de cada árvore individual. Para além da extração dos parâmetros anteriormente mencionados, através da análise multi-temporal, também é possível a deteção de novas plantações ou árvores que morram ao longo dos anos. As validações desses parâmetros serão discutidas na próxima secção.

4 Materiais e validação do método proposto

Este capítulo apresenta os materiais utilizados para efetuar validação do método proposto, sendo descritas as áreas de estudo assim como a descrição dos tipos de dados fornecidos pelas mesmas. Os parâmetros de validação realizados são os seguintes: (1) número de castanheiros presentes na parcela; (2) alturas dos castanheiros e (3) diâmetro da copa, sendo que a altura e o diâmetro foram medidos no terreno manualmente. Finalmente, os resultados obtidos com a aplicação do método proposto foram comparados com dados recolhidos no terreno. Para além da validação dos parâmetros extraídos pelo método proposto, é também apresentado uma análise multi-temporal da mesma parcela, ao longo de 3 anos (2014, 2015 e 2017).

4.1 Descrição das áreas de estudo e aquisição de dados

A área de caso de estudo (438 ha) para efetuar a validação do método proposto, consiste na área localizada nas regiões da Padrela e Tazém (Valpaços, Vila Real, região Nordeste de Portugal), correspondente a uma das principais regiões de castanheiros em Portugal. Muitas famílias desta região dedicam-se à produção de castanha, que posteriormente é vendida para unidades que embalam, congelam e transformam este produto (AGROTEC, 2013). A Denominação de Origem Protegida (DOP) da Padrela estende-se por cinco mil hectares, estando principalmente na zona de Carrazedo de Montenegro (Valpaços), mas abrangendo ainda algumas freguesias de Chaves, Murça e Vila Pouca de Aguiar (Figura 33).

A DOP da Padrela possui uma produção de castanha anual entre 8 e 10 mil toneladas, o que representa um volume de negócios de aproximadamente 20 milhões de euros para cerca de 1500 famílias que se dedicam à produção da mesma, sendo que grande parte da sua produção destina-se ao mercado externo, onde os principais países de exportação são Itália, Brasil, França e Espanha (Rádio Renascença, 2016).

Para além destes voos realizados na região da Padrela, foi também efetuado outro voo complementar a uma pequena parcela de castanheiros na região de Souto de Escarão (Alijó, Vila Real, região Nordeste de Portugal), com o intuito de realizar comparações entre as medições geradas pelo método proposto e medições manuais efetuadas no terreno.




Figura 33 Áreas de cultivo de castanha no norte de Portugal. Adaptado de (Borges et al., 2007)

4.2 Plataformas de detecção remota e descrição dos dados

A aquisição de dados na região da Padrela, devido à sua extensão (438 ha), foi realizada através do drone de asa fixa *senseFly eBee* (*senseFly SA*, Lausanne, Suíça), ilustrado na Figura 34 (A), enquanto que a aquisição de dados na região de Souto de Escarão, devido à sua extensão mais limitada, foi realizada com o drone de asa rotativa *DJI Phantom 4* (Figura 34 (B)), estando as principais características de cada *drone* representadas na Tabela 14.



A



B

Figura 34 VANT utilizados para aquisição de dados. (A) *senseFly eBee*. (B) *DJI Phantom 4*

Tabela 14 Principais características do *senseFly eBee* e *DJI Phantom 4*

Características	<i>senseFly eBee</i>	<i>DJI Phantom 4</i>
Peso	690 g	1380 g
Envergadura das asas	96 cm	35 cm
Tempo máximo de voo	50 minutos	28 minutos
Velocidade nominal de voo	11-25 m/s	20 m/s
Cobertura máxima	200 ha	42 ha

Para aquisição das imagens da região da Padrela, foram realizados dois voos utilizando o mesmo plano de voo (Figura 35), cada um com um sensor diferente.




Figura 35 Plano de voo da região da Padrela

O primeiro voo foi realizado com uma câmara *Canon IXUS 127 HS* (Figura 36 (A)) e o segundo com uma câmara *Canon PowerShot ELPH 110 HS* (Figura 36 (B)). O primeiro sensor registou imagens dentro da zona visível do espectro eletromagnético (RGB), enquanto que o segundo sensor registou imagens em *RedEdge* (RE), e as bandas verde e azul. O RE consiste na região espectral onde a refletância de uma planta muda de baixo para alto (de 680nm para 730nm). Os dados foram adquiridos em julho de 2014, setembro de 2015 e julho de 2017, a 550 m de altitude.



Figura 36 Câmaras utilizadas para aquisição das imagens. (A) *Canon IXUS 127 HS*. (B) *Canon PowerShot ELPH 110 HS*

Após a aquisição de dados, a ortorretificação e georreferenciação das imagens foram realizadas com base em pontos de controlo de terra (*Ground Control Points* - GCP), gerando assim os mosaicos RGB (Figura 37 (A)) e RE (Figura 37 (B)). Os modelos de elevação, nomeadamente, o DTM e o DSM (Figura 37 (C)) foram gerados com base no sistema de coordenadas *World Geodetic System of 1984* (WGS84).




Figura 37 Mosaicos gerados pelo VANT *senseFly eBee* na região da Padrela. (A) Mosaico RGB. (B) Mosaico RE. (C) Modelo Digital de Superfície (DSM)

Para aquisição das imagens na região de Souto de Escarão, como o *drone* apenas possui um sensor RGB, foi efetuado um só voo, sendo que o mosaico RGB gerado e o modelo de elevação se encontram ilustrados na Figura 38. Os dados foram adquiridos em julho de 2017, a 120 m de altitude.




Figura 38 Mosaicos gerados pelo drone DJI Phantom 4 na região de Souto de Escarão. (A) Mosaico RGB. (B) Modelo Digital de Superfície (DSM)

4.3 Validação do número de árvores detetadas

A próxima tarefa consistiu na validação do número de árvores detetadas pelo método proposto. Para esse propósito, o método foi aplicado a cinco parcelas diferentes e o número de árvores foi obtido automaticamente. A seleção destas cinco parcelas, teve como base a existência de castanheiros em fase adulta e castanheiros recentes em desenvolvimento. Novamente, os resultados do método foram comparados com a contagem manual (Figura 39).




Figura 39 Validação do numero de árvores detetadas: (parte superior, esquerda para direita) Imagens RGB das áreas 1,3 e 5; (parte inferior, esquerda para direita) detecção automática de árvores realizado pelo método proposto.

A Tabela 15 apresenta as principais conclusões da validação realizada. Ocorreram falhas de detecção nos casos em que a copa das árvores era demasiado pequeno para ser detetado. Para além disso, esta falha pode também estar relacionada com os dados usados, uma vez que o voo foi feito a 550 m de altitude, tornando essas pequenas árvores insignificantes na imagem. Noutros casos, houve falha de detecção quando as árvores não apresentavam folhagem devido a doença, tornando impossível detetar a vegetação da copa através do VI. Contudo, o método proposto possui no geral uma taxa de precisão no cálculo do numero de árvores presentes na parcela superior a 95%.

Tabela 15 Validação do número de árvores detetadas: comparação entre a contagem manual e automática

	Parcela n° 1	Parcela n° 2	Parcela n° 3	Parcela n° 4	Parcela n° 5
N° de árvores (manualmente)	80	57	81	60	59
N° de árvores (automaticamente)	77	56	79	58	58
Árvores falhadas	3	1	2	2	1
Precisão	96 %	98 %	97 %	97 %	98 %

4.4 Validação da estimativa da altura das árvores

Para validar a estimativa da altura das árvores, foram medidos 12 castanheiros manualmente no terreno (medidas dendrométricas - precisão ~10 cm) e comparados com os valores obtidos pelo método proposto. A Figura 40 apresenta os gráficos que mostram a relação entre medidas manuais e as medidas estimadas pela aplicação do método proposto, utilizando dois VANT diferentes e com GSD diferente. A reta de regressão linear correspondente ao VANT eBee apresenta um $R^2 = 0,78$ (Figura 40 (A)). O R^2 é conhecido como o coeficiente de determinação e representa uma medida estatística do quão próximo os dados estão da linha de regressão ajustada. No geral, quanto maior o R^2 , melhor o modelo se encaixa nos dados. A aplicação do método proposto para a estimativa de altura das árvores resultou numa precisão de 78%. Considerando que o instrumento utilizado nas medidas manuais (dendrometria) tem um erro intrínseco de 10 cm, essa precisão pode ser considerada aceitável (Mohan et al., 2017). Para além disso, alguns erros podem estar relacionados com os modelos de elevação digital utilizados, uma vez que o voo foi realizado a 550 m de altitude (GSD ~ 16 cm). De modo a testar a influência da altitude de voo na estimativa da altura, foi realizado um voo a 100 m de altitude (GSD ~3 cm) com DJI Phantom 4, na mesma área. Nesse caso, a precisão do método ao estimar a altura das árvores foi superior a 85% (Figura 40 (B)).




Figura 40 Validação da estimativa da altura das árvores. Comparação entre as alturas obtidas através do método proposto e medidas manuais dendrométricas: (A) 16 cm GSD. (B) 3 cm GSD.

4.5 Validação da estimativa do diâmetro da copa das árvores

Em relação à validação da estimativa do diâmetro da copa das árvores, foram selecionados dois grupos de árvores: um grupo composto pelas 12 árvores utilizadas na seção anterior e outro grupo composto por 28 castanheiros (Figura 41). Novamente, os resultados obtidos pelo método proposto foram comparados com as medidas realizadas no terreno (medidas dendrométricas).



Figura 41 Imagem RGB representante do grupo composto por 28 castanheiros. GSD ~3 cm; Altitude do voo: 100 m; Equipamento: DJI Phantom 4.

A Figura 42 apresenta os gráficos que mostram a relação entre as medidas manuais e as estimadas pelo método proposto. A regressão linear apresenta um R^2 de 0,95, o que indica que o diâmetro estimado pelo método se ajusta aos dados reais com uma taxa de precisão superior a 90%. Neste caso específico, não foi detetada nenhuma influência na resolução da imagem, uma vez que ambos os grupos forneceram uma precisão similar.

Os resultados obtidos mostraram a eficácia do método proposto na estimativa do diâmetro de castanheiros numa parcela, com uma taxa de sucesso superior a 96%.




Figura 42 Validação do diâmetro dos castanheiros: comparação entre os valores obtidos pelo método proposto com o diâmetro medido manualmente no terreno em (A) grupo 1, composto por 12 castanheiros analisados num modelo com 16 cm de GSD. (B) grupo 2, composto por 28 castanheiros analisados num modelo com 3 cm de GSD. (C) grupo 1 e grupo 2 combinados.

4.6 Análise Multi-Temporal ao nível do Souto

As séries temporais disponíveis das campanhas de 2014, 2015 e 2017 foram utilizadas para realizar uma análise multi-temporal. Os parâmetros comparados ao longo desses anos são: número de castanheiros presentes na parcela e respetiva área de cobertura. A Figura 43 mostra a evolução dos castanheiros da parcela, ao longo do tempo. A primeira imagem por linha na Figura 43 representa a subtração das máscaras dos diversos períodos e a segunda imagem ilustra essas diferenças na imagem RGB.




Figura 43 Análise multi-temporal entre os diferentes períodos. As diferenças estão representadas através de diferentes cores (esquerda) e estão sobrepostas na imagem RGB (direita): (A) 2014-2015. (C) 2015-2017. (E) 2014-2017.

Através da análise da Tabela 16 – que representa o número de árvores na parcela e a sua respetiva área de cobertura dos diferentes períodos estudados, numa parcela com o total de 8572 m^2 - e da Tabela 17– que representa a evolução da área da copa das árvores no tempo abrangido

pelo período analisado - permitiu concluir que no período 2014-2015 houve um declínio de 66 m^2 de área de cobertura (correspondente a 2% da área da parcela estudada). Considerando o curto período do tempo envolvido (José Gomes-Laranjo et al., 2012) e os solos geralmente inadequados para uma cultura exigente como *Castanea Sativa* (Bounous, 2002), este declínio era esperado. Para além destes fatores, também pode ser considerado o facto de que as campanhas de 2014 e 2017 foram realizadas em julho, enquanto que a campanha de 2015 foi realizada em setembro. Esse facto pode prejudicar os resultados, uma vez que é precisamente neste último período do ano que os castanheiros começam a perder a folha. Nas séries temporais 2015-2017 e 2014-2017, foram detetados crescimentos de 561 m^2 (15% da área da parcela estudada) e de 495 m^2 (13% da área da parcela estudada) na cobertura da copa, respetivamente.

Tabela 16 Caracterização da parcela estudada com análise multi-temporal em relação ao número de árvores detetadas.

2014		2015		2017	
Nº de árvores	Área de cobertura	Nº de árvores	Área de cobertura	Nº de árvores	Área de cobertura
72	$3\,814\text{ m}^2$	72	$3\,748\text{ m}^2$	72	$4\,309\text{ m}^2$

Tabela 17 Crescimento e declínio da vegetação da parcela estudada ao longo do período de tempo que abrangeu as três campanhas.

De 2014 para 2015		De 2015 para 2017		De 2014 para 2017	
Crescimento	Declínio	Crescimento	Declínio	Crescimento	Declínio
219 m^2	285 m^2	772 m^2	211 m^2	742 m^2	247 m^2

Em relação ao número de árvores, embora o número total da parcela permaneça o mesmo - 72 árvores - ao longo das três campanhas, na série temporal 2014-2015 foram detetadas duas novas árvores e outras duas que desapareceram (Figura 44).




Figura 44 Análise multi-temporal: (A) Detecção de novas árvores e desaparecimento de árvores na serie temporal 2014-2015. (B) exemplo de uma árvore afetada pela doença da tinta ao qual não será detetada pelo VI.

4.7 Análise Multi-Temporal ao nível da árvore

O método proposto, para além de realizar uma análise multi-temporal ao nível da parcela, também é capaz de realizar uma análise multi-temporal no nível individual de cada árvore. Isto só é possível devido à etapa 2 do método - isolamento de *cluster* - onde as árvores estão separadas corretamente. Para ilustrar o desempenho do método, foram selecionadas dez árvores (Figura 45), em que a sua seleção teve como base a existência de árvores com crescimento e árvores com declínio nos parâmetros extraídos. Essas árvores referem-se à linha de árvores representada no topo da Figura 44 (A).




Figura 45 Análise multi-temporal ao nível individual da árvore: (A) Imagem RGB da campanha de 2014. (B) Imagem RGB da campanha de 2017. (C) diferença das máscaras obtidas através da aplicação do método proposto.

Os resultados quantitativos obtidos da aplicação do método proposto às dez árvores selecionadas estão apresentados na Tabela 18. Através desta tabela é possível aferir que no geral, no período de tempo considerado (2014 - 2017) houve um crescimento na cobertura da copa e diâmetro dos castanheiros analisados. Contudo, os castanheiros números 4 e 5 mostraram uma regressão nesses parâmetros. Particularmente, o castanheiro número 5 teve uma regressão da área de cobertura de $24,5 \text{ m}^2$ (-73%) e uma diminuição de 2,6 m no seu diâmetro (-65%). Este declínio deve-se ao facto de esta possuir doença da tinta, confirmada no campo. Porém, para além desses dois casos particulares, entre 2014 e 2017, os castanheiros representados na Figura 45 tiveram um crescimento médio de $8,1 \text{ m}^2$ (+ 16%) na área de cobertura da copa e de 0,5m (+ 6%) no seu diâmetro.

Tabela 18 Análise multi-temporal ao nível individual da árvore: estimativa da área de cobertura e do diâmetro da copa e estimativa da altura de cada árvore presente na amostra estudada.

	2014			2017		
ID	Área de cobertura (m^2)	Diâmetro (m)	Altura (m)	Área de cobertura (m^2)	Diâmetro (m)	Altura (m)
1	65,7	10,1	7,2	73,1	10,2	8,1
2	51,8	8,9	7,2	55,4	9,1	6,4
3	45,4	8,4	6,4	59,1	9,3	7,1
4	35,2	7,7	5,6	33,7	7,1	4,0
5	33,7	7,4	5,6	9,2	4,8	4,8
6	39,2	7,3	6,3	45,5	7,9	6,8
7	44,3	7,8	7,0	48,7	8,2	7,2
8	61,9	9,5	8,2	72,1	10,1	8,4
9	54,9	9,2	7,4	63,7	9,5	8,1
10	52,1	8,3	6,7	62,5	9,2	7,7

Em relação à altura das árvores, foi referido antes (Capítulo 4.4) que a qualidade do modelo influencia a qualidade da medição. Também foi afirmado que as medidas são afetadas por erros de instrumento e de utilizador que podem exceder 10 cm. No entanto, os castanheiros números 2, 4 e 5 mostraram uma regressão de altura além do erro esperado. Apesar destas regressões na altura das árvores, os restantes castanheiros possuíram um crescimento médio de 0,5 m (+ 7%).

5 Conclusões e trabalho futuro

Este trabalho foi desenvolvido com a principal motivação de implementar um método automático para monitorização de castanheiros, sendo este capaz de fornecer informações ao utilizador relativas ao soute e ao nível individual de cada árvore, presente no mesmo.

5.1 Conclusões

De uma forma geral, os objetivos propostos nesta dissertação foram atingidos, tendo sido desenvolvido uma metodologia automática de gestão e extração de parâmetros ao nível de souts e ao nível individual de cada árvore.

Depois de realizado o levantamento do estado da arte sobre VANT e técnicas de processamento digital de imagem, foram identificados e caracterizados os métodos com melhor desempenho de modo a atingir os objetivos referentes ao estudo. Após a identificação dos métodos, foi proposto uma metodologia capaz de extrair parâmetros de souts, com o intuito de auxiliar agricultores na gestão dos seus terrenos.

A metodologia proposta foi dividida em três etapas: segmentação e primeiro *clustering*; isolamento de *clusters* e extração de parâmetros. No que concerne à primeira etapa, foram realizados testes a vários métodos de segmentação que melhor discriminassem vegetação em imagens RGB e RE, sendo que os índices de vegetação consistiram no método com melhor desempenho, com uma taxa de acerto superior a 93% nos dois tipos de imagem. Assim, o método proposto mostrou-se eficaz quando aplicado tanto em câmaras adquiridas por consumidores comuns, mais baratas, como a imagens de sensores multiespectrais, embora o melhor desempenho tenha sido alcançado quando foram utilizados índices de vegetação baseados em informações RE. Conclui-se, também, que, relativamente à aplicação dos vários métodos, de uma forma geral, estes apresentaram melhor desempenho quando aplicados à imagem RE. Relativamente à etapa de isolamento de *clusters*, após testes efetuados a diferentes métodos, tais como transformada de *Hough*, segmentação *Watershed* e operações morfológicas, este último método foi o que apresentou melhor desempenho, conseguindo separar árvores conectadas de forma correta com taxas de acerto plenas (100%) nas imagens de referência. Em relação à extração dos parâmetros, o método proposto alcançou uma precisão superior a 90% na estimativa da área da copa e do diâmetro, e mais de 80% na estimativa da altura das árvores.

Estes resultados surgem da comparação de medições manuais, efetuados no terreno, com as medições obtidas pela metodologia proposta.

Assim, analisando os resultados globais, estes sugerem que a metodologia proposta pode ser utilizada como uma alternativa eficaz ao método manual para monitorização de parcelas de castanheiros. Para além disso, o método forneceu resultados semelhantes quando aplicado em estudos tanto ao nível global da parcela como ao nível individual da árvore, tanto para análise estática quanto multi-temporal.

No caso das análises multi-temporais, estas revelaram possuir um excelente potencial, uma vez que, o agricultor tem a possibilidade de acompanhar a evolução da sua cultura ao longo dos anos, podendo detetar anomalias no crescimento de castanheiros. Estas anomalias podem estar relacionadas com deficiências, ao nível de nutrientes, ou poderão ser provocadas por doenças. Assim, este tipo de análise pode ser visto como uma ferramenta auxiliar de deteção prévia de doenças no castanheiro. Para além de efetuar um acompanhamento do crescimento dos castanheiros, a análise multi-temporal também é capaz de detetar novas plantações que surjam ao longo dos anos assim como detetar árvores que desapareceram.

5.2 Trabalho futuro

Nesta dissertação foram implementados e testados vários métodos de segmentação sendo que os métodos com melhor desempenho corresponderam a métodos aplicados a imagens RE. Assim, futuramente, e no sentido de proporcionar este tipo de análise a baixo custo, pretende-se estudar e desenvolver métodos que possuam melhor desempenho recorrendo, exclusivamente, a imagens RGB, através de técnicas de *machine learning*.

Em relação aos parâmetros extraídos, como a altura das árvores correspondeu ao valor com menor taxa de precisão, estamos convencidos que com os futuros melhoramentos aos sensores de aquisição de dados e ferramentas de processamento fotogramétrico, possam aumentar este valor.

Para além dos melhoramentos anteriormente referidos, a pesquisa futura deve concentrar-se, também, na monitorização e gestão de florestas e outras culturas de importância socioeconómica para o país, como o caso da oliveira (*Olea europaea L.*), pinheiro-manso (*Pinus pinea*) e sobreiro (*Quercus suber L.*), com foco no cálculo de estimativas de atributos individuais da árvore, como altura, tamanho da copa e diâmetro, e, assim, desenvolver modelos

preditivos de biomassa e o volume do tronco a partir de imagens de VANT e da correlação conhecida, destes parâmetros, com a área da copa.

Aparte deste trabalho também se pretende explorar a utilização de outros tipos de dados adquiridos por sensores multi-espectrais e térmicos. Pretende-se ainda fazer um estudo para otimização da recolha dos dados provenientes de VANT como a altura de voo, sobreposição de imagens e as melhores épocas para a aquisição de dados para monitorização dentro da mesma época e entre épocas.

Nota: Parte do trabalho realizado nesta dissertação foi apresentado na 5ª edição de *International Conference on small Unmanned Aerial Systems for Environmental Research* com o título “Automatic Chestnut trees monitoring by aerial photographs obtained by unmanned aerial vehicle” (Marques et al., 2017) e contribuiu para a realização do artigo “Chestnut Trees Automatic Monitoring Using UAV High-Resolution Images ” submetido no jornal *ISPRS Journal of Photogrammetry and Remote Sensing* encontrando-se em revisão.

Bibliografia

- Abbasgholipour, M., Omid, M., Keyhani, A., & Mohtasebi, S. S. (2011). Color image segmentation with genetic algorithm in a raisin sorting system based on machine vision in variable conditions. *Expert Systems with Applications*, 38(4), 3671–3678. <https://doi.org/10.1016/j.eswa.2010.09.023>
- AGROTEC. (2013, Outubro 31). Castanha: Da apanha à transformação na zona da Padrela | Agrotec.pt. Obtido 2 de Novembro de 2017, de <http://www.agrotec.pt/noticias/castanha-da-apanha-transformacao-na-zona-da-padrela/>
- Aitkenhead, M. J., Dalgetty, I. A., Mullins, C. E., McDonald, A. J. S., & Strachan, N. J. C. (2003). Weed and crop discrimination using image analysis and artificial intelligence methods. *Computers and Electronics in Agriculture*, 39(3), 157–171. [https://doi.org/10.1016/S0168-1699\(03\)00076-0](https://doi.org/10.1016/S0168-1699(03)00076-0)
- Anderson, K., & Gaston, K. J. (2013). Lightweight unmanned aerial vehicles will revolutionize spatial ecology. *Frontiers in Ecology and the Environment*, 11(3), 138–146. <https://doi.org/10.1890/120150>
- Arefi, H., d'Angelo, P., Mayer, H., & Reinartz, P. (2009). Automatic generation of digital terrain models from Cartosat-1 stereo images. Em C. Heipke, K. Jacobsen, S. Müller, & U. Sörgel (Eds.) (Vol. 83, pp. 1–6). Apresentado na ISPRS workshop Hannover 2009, Hannover, Germany: ISPRS. Obtido de <http://elib.dlr.de/59313/>
- Austin, R. (2011). *Unmanned Aircraft Systems: UAVS Design, Development and Deployment*. John Wiley & Sons.
- Avanzato, D. (2009). Following chestnut footprints (*Castanea spp.*): cultivation and culture, folklore and history, traditions and uses. *Following chestnut footprints (Castanea spp.):*

- cultivation and culture, folklore and history, traditions and uses*. Obtido de <https://www.cabdirect.org/cabdirect/abstract/20103105789>
- Baluja, J., Diago, M. P., Balda, P., Zorer, R., Meggio, F., Morales, F., & Tardaguila, J. (2012). Assessment of vineyard water status variability by thermal and multispectral imagery using an unmanned aerial vehicle (UAV). *Irrigation Science*, 30(6), 511–522. <https://doi.org/10.1007/s00271-012-0382-9>
- Battisti, A., Benvegnù, I., Colombari, F., & Haack, R. A. (2014). Invasion by the chestnut gall wasp in Italy causes significant yield loss in *Castanea sativa* nut production. *Agricultural and Forest Entomology*, 16(1), 75–79. <https://doi.org/10.1111/afe.12036>
- Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., ... Bareth, G. (2015). Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, 39, 79–87. <https://doi.org/10.1016/j.jag.2015.02.012>
- Berni, J. A. J., Zarco-Tejada, P. J., Suarez, L., & Fereres, E. (2009). Thermal and Narrowband Multispectral Remote Sensing for Vegetation Monitoring From an Unmanned Aerial Vehicle. *IEEE Transactions on Geoscience and Remote Sensing*, 47(3), 722–738. <https://doi.org/10.1109/TGRS.2008.2010457>
- Beucher, S., & Lantuejoul, C. (1979). Use of Watersheds in Contour Detection. Apresentado na International Workshop on Image Processing: Real-time Edge and Motion Detection/Estimation, Rennes, France.
- Borges, O. P., Soeiro Carvalho, J., Reis Correia, P., & Paula Silva, A. (2007). Lipid and fatty acid profiles of *Castanea sativa* Mill. Chestnuts of 17 native Portuguese cultivars. *Journal of Food Composition and Analysis*, 20(2), 80–89. <https://doi.org/10.1016/j.jfca.2006.07.008>

- Bounous, G. (2002). *Il Castagno: coltura, ambiente ed utilizzazioni in Italia e nel mondo*. Edagricole.
- Burgos-Artizzu, X. P., Ribeiro, A., Guijarro, M., & Pajares, G. (2011). Real-time image processing for crop/weed discrimination in maize fields. *Computers and Electronics in Agriculture*, 75(2), 337–346. <https://doi.org/10.1016/j.compag.2010.12.011>
- Calderón, R., Navas-Cortés, J. A., Lucena, C., & Zarco-Tejada, P. J. (2013). High-resolution airborne hyperspectral and thermal imagery for early detection of Verticillium wilt of olive using fluorescence, temperature and narrow-band spectral indices. *Remote Sensing of Environment*, 139(Supplement C), 231–245. <https://doi.org/10.1016/j.rse.2013.07.031>
- Colomina, I., & Molina, P. (2014). Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 92, 79–97. <https://doi.org/10.1016/j.isprsjprs.2014.02.013>
- Conedera, M., & Krebs, P. (2008). HISTORY, PRESENT SITUATION AND PERSPECTIVE OF CHESTNUT CULTIVATION IN EUROPE. *Acta Horticulturae*, (784), 23–28. <https://doi.org/10.17660/ActaHortic.2008.784.1>
- Conedera, M., Manetti, M., Giudici, F., & Amorini, E. (2004). {Distribution and economic potential of the Sweet chestnut (*Castanea sativa* Mill.) in Europe}. *Ecologia Mediterranea*, 30(2), 179–193.
- Conedera, M., Tinner, W., Krebs, P., de Rigo, D., & Caudullo, G. (2016). *Castanea sativa in Europe: distribution, habitat, usage and threats*.
- Costa, F. G., Ueyama, J., Braun, T., Pessin, G., Osório, F. S., & Vargas, P. A. (2012). The use of unmanned aerial vehicles and wireless sensor network in agricultural applications. *Em 2012 IEEE International Geoscience and Remote Sensing Symposium* (pp. 5045–5048). <https://doi.org/10.1109/IGARSS.2012.6352477>

- Cracknell, A. P., & Hayes, L. W. B. (2007). *Introduction to remote sensing*. London; New York: Taylor & Francis.
- Crommelinck, S., Bennett, R., Gerke, M., Nex, F., Yang, M. Y., & Vosselman, G. (2016). Review of Automatic Feature Extraction from High-Resolution Optical Sensor Data for UAV-Based Cadastral Mapping. *Remote Sensing*, 8(8), 689. <https://doi.org/10.3390/rs8080689>
- Dass, R., & Devi, S. (sem data). *Image Segmentation Techniques 1*.
- Dehariya, V. K., Shrivastava, S. K., & Jain, R. C. (2010). Clustering of Image Data Set Using K-Means and Fuzzy K-Means Algorithms. Em *2010 International Conference on Computational Intelligence and Communication Networks* (pp. 386–391). <https://doi.org/10.1109/CICN.2010.80>
- Digabel, H., & Lantuéjoul, C. (1978). Iterative algorithms (Vol. 19, p. 8). Apresentado na Proc. 2nd European Symp. Quantitative Analysis of Microstructures in Material Science, Biology and Medicine, Stuttgart, West Germany: Riederer Verlag.
- Dunford, R., Michel, K., Gagnage, M., & Piégay, H. (2009). Potential and constraints of Unmanned Aerial Vehicle technology for the characterization of Mediterranean riparian forest. *International Journal of Remote Sensing*, 30(19), 4915–4935.
- Faiçal, B. S., Costa, F. G., Pessin, G., Ueyama, J., Freitas, H., Colombo, A., ... Braun, T. (2014). The use of unmanned aerial vehicles and wireless sensor networks for spraying pesticides. *Journal of Systems Architecture*, 60(4), 393–404. <https://doi.org/10.1016/j.sysarc.2014.01.004>
- Frankenberger, J. R., Huang, C., & Nouwakpo, K. (2008). Low-Altitude Digital Photogrammetry Technique to Assess Ephemeral Gully Erosion. Em *IGARSS 2008 - 2008 IEEE International Geoscience and Remote Sensing Symposium* (Vol. 4, p. IV-117-IV-120). <https://doi.org/10.1109/IGARSS.2008.4779670>

- Gademer, A., Petitpas, B., Mobaied, S., Beaudoin, L., Riera, B., Roux, M., & Rudant, J. P. (2010). Developing a lowcost Vertical Take Off and Landing Unmanned Aerial System for centimetric monitoring of biodiversity the Fontainebleau Forest case. Em *2010 IEEE International Geoscience and Remote Sensing Symposium* (pp. 600–603). <https://doi.org/10.1109/IGARSS.2010.5649994>
- Gebhardt, S., & Kühbauch, W. (2007). A new algorithm for automatic Rumex obtusifolius detection in digital images using colour and texture features and the influence of image resolution. *Precision Agriculture*, 8(1–2), 1–13. <https://doi.org/10.1007/s11119-006-9024-7>
- Gebhardt, S., Schellberg, J., Lock, R., & Kühbauch, W. (2006). Identification of broad-leaved dock (Rumex obtusifolius L.) on grassland by means of digital image processing. *Precision Agriculture*, 7(3), 165–178. <https://doi.org/10.1007/s11119-006-9006-9>
- Getzin, S., Wiegand, K., & Schöning, I. (2012). Assessing biodiversity in forests using very high-resolution images and unmanned aerial vehicles. *Methods in Ecology and Evolution*, 3(2), 397–404. <https://doi.org/10.1111/j.2041-210X.2011.00158.x>
- Gitelson, A. A., Kaufman, Y. J., & Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*, 58(3), 289–298. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)
- Gitelson, A. A., Kaufman, Y. J., Stark, R., & Rundquist, D. (2002). Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*, 80(1), 76–87. [https://doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/10.1016/S0034-4257(01)00289-9)
- Gomes-Laranjo, J. (2013). A fileira da castanha em Portugal. Uma fileira de oportunidades. *Hortofruticultura & floricultura. Agrotec*, pp. 38–40.

- Gomes-Laranjo, J., Dinis, L.-T., Martins, L., Portela, E., Pinto, T., Ara, M. C., ... Costa, R. (2012). Characterization of Chestnut Behavior with Photosynthetic Traits. <https://doi.org/10.5772/26227>
- Gonzalez-Dugo, V., Zarco-Tejada, P., Nicolás, E., Nortes, P. A., Alarcón, J. J., Intrigliolo, D. S., & Fereres, E. (2013). Using high resolution UAV thermal imagery to assess the variability in the water status of five fruit tree species within a commercial orchard. *Precision Agriculture*, 14(6), 660–678. <https://doi.org/10.1007/s11119-013-9322-9>
- Grigillo, D., & Kanjir, U. (2012). Urban object extraction from digital surface model and digital aerial images. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, I-3, 215–220. <https://doi.org/10.5194/isprsannals-I-3-215-2012>
- Guijarro, M., Pajares, G., Riomoros, I., Herrera, P. J., Burgos-Artizzu, X. P., & Ribeiro, A. (2011). Automatic segmentation of relevant textures in agricultural images. *Computers and Electronics in Agriculture*, 75(1), 75–83. <https://doi.org/10.1016/j.compag.2010.09.013>
- Guo, W., Rage, U. K., & Ninomiya, S. (2013). Illumination invariant segmentation of vegetation for time series wheat images based on decision tree model. *Computers and Electronics in Agriculture*, 96(Supplement C), 58–66. <https://doi.org/10.1016/j.compag.2013.04.010>
- Haala, N., Cramer, M., Weimer, F., & Trittler, M. (2011). Performance Test on Uav-Based Photogrammetric Data Collection. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 3822, 7–12. <https://doi.org/10.5194/isprsarchives-XXXVIII-1-C22-7-2011>
- Hamuda, E., Glavin, M., & Jones, E. (2016). A survey of image processing techniques for plant extraction and segmentation in the field. *Computers and Electronics in Agriculture*, 125(Supplement C), 184–199. <https://doi.org/10.1016/j.compag.2016.04.024>

- Hancock, D. W., & Dougherty, C. T. (2007). Relationships between Blue- and Red-based Vegetation Indices and Leaf Area and Yield of Alfalfa. *Crop Science*, 47(6), 2547–2556. <https://doi.org/10.2135/cropsci2007.01.0031>
- Hardin, P. J., & Jensen, R. R. (2011). Small-Scale Unmanned Aerial Vehicles in Environmental Remote Sensing: Challenges and Opportunities. *GIScience & Remote Sensing*, 48(1), 99–111. <https://doi.org/10.2747/1548-1603.48.1.99>
- Hemming, J., & Rath, T. (2001). PA—Precision Agriculture: Computer-Vision-based Weed Identification under Field Conditions using Controlled Lighting. *Journal of Agricultural Engineering Research*, 78(3), 233–243. <https://doi.org/10.1006/jaer.2000.0639>
- Herwitz, S. R., Johnson, L. F., Dunagan, S. E., Higgins, R. G., Sullivan, D. V., Zheng, J., ... Brass, J. A. (2004). Imaging from an unmanned aerial vehicle: agricultural surveillance and decision support. *Computers and Electronics in Agriculture*, 44(1), 49–61. <https://doi.org/10.1016/j.compag.2004.02.006>
- Hough, P. V. C. (1962). *Method and Means for Recognizing Complex Patterns* (No. US 3069654). Originating Research Org. not identified. Obtido de <https://www.osti.gov/scitech/biblio/4746348>
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Hughenoltz, C. H., Whitehead, K., Brown, O. W., Barchyn, T. E., Moorman, B. J., LeClair, A., ... Hamilton, T. (2013). Geomorphological mapping with a small unmanned aircraft system (sUAS): Feature detection and accuracy assessment of a photogrammetrically-derived digital terrain model. *Geomorphology*, 194(Supplement C), 16–24. <https://doi.org/10.1016/j.geomorph.2013.03.023>

- Hung, C., Bryson, M., & Sukkarieh, S. (2012). Multi-class predictive template for tree crown detection. *ISPRS Journal of Photogrammetry and Remote Sensing*, 68(Supplement C), 170–183. <https://doi.org/10.1016/j.isprsjprs.2012.01.009>
- Hunt, E. R., Hively, W. D., Fujikawa, S. J., Linden, D. S., Daughtry, C. S. T., & McCarty, G. W. (2010). Acquisition of NIR-Green-Blue Digital Photographs from Unmanned Aircraft for Crop Monitoring. *Remote Sensing*, 2(1), 290–305. <https://doi.org/10.3390/rs2010290>
- Israel, M. (2011). A UAV-based Roe Deer Fawn Detection System. *International Archives of Photogrammetry and Remote Sensing*, Vol XXXVIII-1/C22, 1–5.
- Jensen, A. M., Chen, Y., McKee, M., Hardy, T., & Barfuss, S. L. (2009). AggieAir #x2014; a low-cost autonomous multispectral remote sensing platform: New developments and applications. In *2009 IEEE International Geoscience and Remote Sensing Symposium* (Vol. 4, p. IV-995-IV-998). <https://doi.org/10.1109/IGARSS.2009.5417547>
- Johnson, L. F., Herwitz, S., E. Dunagan, S., M. Lobitz, B., Sullivan, D. V., & E. Slye, R. (2003). *Collection of ultra high spatial and spectral resolution image data over California vineyards with a small UAV.*
- Justice, C. O., Vermote, E., Townshend, J. R. G., Defries, R., Roy, D. P., Hall, D. K., ... Barnsley, M. J. (1998). The Moderate Resolution Imaging Spectroradiometer (MODIS): land remote sensing for global change research. *IEEE Transactions on Geoscience and Remote Sensing*, 36(4), 1228–1249. <https://doi.org/10.1109/36.701075>
- Kaltenrieder, P., Procacci, G., Vannière, B., & Tinner, W. (2010). Vegetation and fire history of the Euganean Hills (Colli Euganei) as recorded by Lateglacial and Holocene sedimentary series from Lago della Costa (northeastern Italy). *The Holocene*, 20(5), 679–695. <https://doi.org/10.1177/0959683609358911>

- Kandwal, R., Kumar, A., & Bhargava, S. (2014). Review: Existing Image Segmentation Techniques. *International Journal of Advanced Research in Computer Science and Software Engineering*, 4, 153–156.
- Kang, W. X., Yang, Q. Q., & Liang, R. P. (2009). The Comparative Research on Image Segmentation Algorithms. Em *2009 First International Workshop on Education Technology and Computer Science* (Vol. 2, pp. 703–707). <https://doi.org/10.1109/ETCS.2009.417>
- Kawashima, S., & Nakatani, M. (1998). An Algorithm for Estimating Chlorophyll Content in Leaves Using a Video Camera. *Annals of Botany*, 81(1), 49–54. <https://doi.org/10.1006/anbo.1997.0544>
- Khalifa, A. (2010). *Evaluating The Effectiveness Of Region Growing And Edge Detection Segmentation Algorithms*. (Vol. 6).
- Kirk, K., Andersen, H. J., Thomsen, A. G., Jørgensen, J. R., & Jørgensen, R. N. (2009). Estimation of leaf area index in cereal crops using red–green images. *Biosystems Engineering*, 104(3), 308–317. <https://doi.org/10.1016/j.biosystemseng.2009.07.001>
- Lagüela, S., Díaz-Vilariño, L., Roca, D., & Lorenzo, H. (2015). Aerial thermography from low-cost UAV for the generation of thermographic digital terrain models. *Opto - Electronics Review*, (Vol. 23, No. 1), 76–82. <https://doi.org/10.1515/oere-2015-0006>
- Laliberte, A. S., & Rango, A. (2009). Texture and Scale in Object-Based Analysis of Subdecimeter Resolution Unmanned Aerial Vehicle (UAV) Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 47(3), 761–770. <https://doi.org/10.1109/TGRS.2008.2009355>
- Langote, V. B., & Chaudhari, D. S. (2012). Segmentation Techniques for Image Analysis. *International Journal of Advanced Engineering Research and Studies (IJAERS)*, 1.

- Lantuejoul, C. (1978). *La squelettisation et son application aux mesures topologiques des mosaïques polycristallines*.
- Ling, P. P., & Ruzhitsky, V. N. (1996). Machine Vision Techniques for Measuring the Canopy of Tomato Seedling. *Journal of Agricultural Engineering Research*, 65(2), 85–95. <https://doi.org/10.1006/jaer.1996.0082>
- Lucieer, A., Robinson, S., & Turner, D. (2017). *Using an unmanned aerial vehicle (UAV) for ultra-high resolution mapping of Antarctic moss beds*.
- Marchant, J. A., Tillett, R. D., & Brivot, R. (1998). Real-Time Segmentation of Plants and Weeds. *Real-Time Imaging*, 4(4), 243–253. <https://doi.org/10.1006/rtim.1997.0086>
- Marques, P., Pádua, L., Adão, T., Hruška, J., Sousa, J. J., Peres, E., ... Sousa, A. (2017). Automatic Chestnut trees monitoring by aerial photographs obtained by unmanned aerial vehicle (pp. 32–33). Apresentado na International Conference on small Unmanned Aerial Systems for Environmental Research, 5th Edition, Vila Real, Portugal: UTAD.
- Martins, L. M., Castro, J. P., Bento, R., & Sousa, J. J. (2015). Monitorização da condição fitossanitária do castanheiro por fotografia aérea obtida com aeronave não tripulada. *Revista de Ciências Agrárias*, 38(2), 184–190.
- Martins, L. M., Castro, J. P., & Gouveia, M. E. (2014). BIOLOGICAL CONTROL OF CHESTNUT BLIGHT IN PORTUGAL. *Acta Horticulturae*, (1043), 51–56. <https://doi.org/10.17660/ActaHortic.2014.1043.5>
- Matese, A., Toscano, P., Di Gennaro, S. F., Genesio, L., Vaccari, F. P., Primicerio, J., ... Gioli, B. (2015). Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture. *Remote Sensing*, 7(3), 2971–2990. <https://doi.org/10.3390/rs70302971>

- Mathews, A. J., & Jensen, J. L. R. (2013). Visualizing and Quantifying Vineyard Canopy LAI Using an Unmanned Aerial Vehicle (UAV) Collected High Density Structure from Motion Point Cloud. *Remote Sensing*, 5(5), 2164–2183. <https://doi.org/10.3390/rs5052164>
- Mejias, L., Lai, J., & Bruggemann, T. (2015). Sensors for Missions. Em K. P. Valavanis & G. J. Vachtsevanos (Eds.), *Handbook of Unmanned Aerial Vehicles* (pp. 385–399). Springer Netherlands. https://doi.org/10.1007/978-90-481-9707-1_6
- Merino, L., Caballero, F., Martínez-de-Dios, J. R., Maza, I., & Ollero, A. (2012). An Unmanned Aircraft System for Automatic Forest Fire Monitoring and Measurement. *Journal of Intelligent & Robotic Systems*, 65(1–4), 533–548. <https://doi.org/10.1007/s10846-011-9560-x>
- Meyer, G. E., Camargo Neto, J., Jones, D. D., & Hindman, T. W. (2004). Intensified fuzzy clusters for classifying plant, soil, and residue regions of interest from color images. *Computers and Electronics in Agriculture*, 42(3), 161–180. <https://doi.org/10.1016/j.compag.2003.08.002>
- Meyer, G. E., & Neto, J. C. (2008). Verification of color vegetation indices for automated crop imaging applications. *Computers and Electronics in Agriculture*, 63(2), 282–293. <https://doi.org/10.1016/j.compag.2008.03.009>
- Mohan, M., Silva, C. A., Klauberg, C., Jat, P., Catts, G., Cardil, A., ... Dia, M. (2017). Individual Tree Detection from Unmanned Aerial Vehicle (UAV) Derived Canopy Height Model in an Open Canopy Mixed Conifer Forest. *Forests*, 8(9), 340. <https://doi.org/10.3390/f8090340>
- Mundo Português. (2015, Outubro 26). A produção e comercialização da castanha em Portugal. Obtido 22 de Novembro de 2017, de <https://www.mundoportugues.pt/62817/>

- Nadernejad, E., Sharifzadeh, S., & Hassanpour, H. (2008). Edge detection techniques: Evaluations and comparisons. *Applied Mathematical Sciences*, 2, 1507–1520.
- Nebikera, S., Annena, A., Scherrerb, M., & Oeschc, D. (2008). A Light-weight Multispectral Sensor for Micro UAV - Opportunities for very high resolution airborne remote sensing. Em *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*.
- Nex, F., & Remondino, F. (2014). UAV for 3D mapping applications: a review. *Applied Geomatics*, 6(1), 1–15. <https://doi.org/10.1007/s12518-013-0120-x>
- Onyango, C. M., & Marchant, J. A. (2003). Segmentation of row crop plants from weeds using colour and morphology. *Computers and Electronics in Agriculture*, 39(3), 141–155. [https://doi.org/10.1016/S0168-1699\(03\)00023-1](https://doi.org/10.1016/S0168-1699(03)00023-1)
- Otsu, N. (1979). A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62–66. <https://doi.org/10.1109/TSMC.1979.4310076>
- Pádua, L., Vanko, J., Hruška, J., Adão, T., Sousa, J. J., Peres, E., & Morais, R. (2017). UAS, sensors, and data processing in agroforestry: a review towards practical applications. *International Journal of Remote Sensing*, 38(8–10), 2349–2391. <https://doi.org/10.1080/01431161.2017.1297548>
- Pajares, G. (2015). Overview and Current Status of Remote Sensing Applications Based on Unmanned Aerial Vehicles (UAVs). *Photogrammetric Engineering & Remote Sensing*, 81(4), 281–329. <https://doi.org/10.14358/PERS.81.4.281>
- Pal, N. R., & Pal, S. K. (1993). A review on image segmentation techniques. *Pattern Recognition*, 26(9), 1277–1294. [https://doi.org/10.1016/0031-3203\(93\)90135-J](https://doi.org/10.1016/0031-3203(93)90135-J)

- Portela, E., Roboredo, M., & Louzada, J. (2003). Assessment and Description of Magnesium Deficiencies in Chestnut Groves. *Journal of Plant Nutrition*, 26(3), 503–523. <https://doi.org/10.1081/PLN-120017662>
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48(2), 119–126. [https://doi.org/10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1)
- Quater, P. B., Grimaccia, F., Leva, S., Mussetta, M., & Aghaei, M. (2014). Light Unmanned Aerial Vehicles (UAVs) for Cooperative Inspection of PV Plants. *IEEE Journal of Photovoltaics*, 4(4), 1107–1113. <https://doi.org/10.1109/JPHOTOV.2014.2323714>
- Quiroz, R. (2015). Remote sensing as a monitoring tool for cropping area determination in smallholder agriculture in Tanzania and Uganda. Obtido de <https://cgspace.cgiar.org/handle/10568/69110>
- Rádio Renascença. (2016, Novembro 2). Queda tardia faz subir o preço da castanha - Renascença. Obtido 3 de Novembro de 2017, de http://rr.sapo.pt/noticia/67496/queda_tardia_faz_subir_o_preco_da_castanha
- Rango, A., & Havstad, K. (2003). The Utility of Historical Aerial Photographs for Detecting and Judging the Effectiveness of Rangeland Remediation Treatments. *Environmental Practice*, 5(2), 107–118. <https://doi.org/10.1017/S1466046603031065>
- Rango, A., Laliberte, A., Herrick, J. E., Winters, C., Havstad, K., Steele, C., & Browning, D. (2009). Unmanned aerial vehicle-based remote sensing for rangeland assessment, monitoring, and management. *Journal of Applied Remote Sensing*, 3(1), 033542-033542-15. <https://doi.org/10.1117/1.3216822>
- Rasmussen, J., Ntakos, G., Nielsen, J., Svensgaard, J., Poulsen, R. N., & Christensen, S. (2016). Are vegetation indices derived from consumer-grade cameras mounted on UAVs

- sufficiently reliable for assessing experimental plots? *European Journal of Agronomy*, 74, 75–92. <https://doi.org/10.1016/j.eja.2015.11.026>
- Rigling, D., & Prospero, S. (2017). Cryphonectria parasitica, the causal agent of chestnut blight: invasion history, population biology and disease control. *Molecular Plant Pathology*, n/a-n/a. <https://doi.org/10.1111/mpp.12542>
- Rondeaux, G., Steven, M., & Baret, F. (1996). Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*, 55(2), 95–107. [https://doi.org/10.1016/0034-4257\(95\)00186-7](https://doi.org/10.1016/0034-4257(95)00186-7)
- Rouse, J. W., Jr., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring Vegetation Systems in the Great Plains with ERTS. *NASA Special Publication*, 351, 309.
- Ruiz-Ruiz, G., Gómez-Gil, J., & Navas-Gracia, L. M. (2009). Testing different color spaces based on hue for the environmentally adaptive segmentation algorithm (EASA). *Computers and Electronics in Agriculture*, 68(1), 88–96. <https://doi.org/10.1016/j.compag.2009.04.009>
- Sahoo, P. K., Soltani, S., & Wong, A. K. C. (1988). A survey of thresholding techniques. *Computer Vision, Graphics, and Image Processing*, 41(2), 233–260. [https://doi.org/10.1016/0734-189X\(88\)90022-9](https://doi.org/10.1016/0734-189X(88)90022-9)
- Salamí, E., Barrado, C., & Pastor, E. (2014). UAV Flight Experiments Applied to the Remote Sensing of Vegetated Areas. *Remote Sensing*, 6(11), 11051–11081. <https://doi.org/10.3390/rs61111051>
- Schuster, I., Nordmeyer, H., & Rath, T. (2007). Comparison of vision-based and manual weed mapping in sugar beet. *Biosystems Engineering*, 98(1), 17–25. <https://doi.org/10.1016/j.biosystemseng.2007.06.009>
- Searcy, S. W., & Reid, J. F. (1986). Vision-Based Guidance of an Agricultural Tractor. In *1986 American Control Conference* (pp. 931–937).

- Serra, J. (1982). *Image analysis and mathematical morphology*, v. 1. Academic press.
- Shrestha, D. S., Steward, B. L., & Birrell, S. J. (2004). Video Processing for Early Stage Maize Plant Detection. *Biosystems Engineering*, 89(2), 119–129.
<https://doi.org/10.1016/j.biosystemseng.2004.06.007>
- Slaughter, D. C., Giles, D. K., & Downey, D. (2008). Autonomous robotic weed control systems: A review. *Computers and Electronics in Agriculture*, 61(1), 63–78.
<https://doi.org/10.1016/j.compag.2007.05.008>
- Smistad, E., Falch, T. L., Bozorgi, M., Elster, A. C., & Lindseth, F. (2015). Medical image segmentation on GPUs – A comprehensive review. *Medical Image Analysis*, 20(1), 1–18. <https://doi.org/10.1016/j.media.2014.10.012>
- Søgaard, H. T. (2005). Weed Classification by Active Shape Models. *Biosystems Engineering*, 91(3), 271–281. <https://doi.org/10.1016/j.biosystemseng.2005.04.011>
- Sripada, R. P., Heiniger, R. W., White, J. G., & Meijer, A. D. (2006). Aerial Color Infrared Photography for Determining Early In-Season Nitrogen Requirements in Corn. *Agronomy Journal*, 98(4), 968–977. <https://doi.org/10.2134/agronj2005.0200>
- Stockman, G., & Shapiro, L. G. (2001). *Computer Vision* (1st ed.). Upper Saddle River, NJ, USA: Prentice Hall PTR.
- Sugiura, R., Noguchi, N., & Ishii, K. (2005). Remote-sensing Technology for Vegetation Monitoring using an Unmanned Helicopter. *Biosystems Engineering*, 90(4), 369–379.
<https://doi.org/10.1016/j.biosystemseng.2004.12.011>
- Techy, L., Woolsey, C. A., & Schmale, D. G. (2008). Path planning for efficient UAV coordination in aerobiological sampling missions. In *2008 47th IEEE Conference on Decision and Control* (pp. 2814–2819). <https://doi.org/10.1109/CDC.2008.4739456>

- Tellaache, A., Burgos-Artizzu, X. P., Pajares, G., & Ribeiro, A. (2008). A vision-based method for weeds identification through the Bayesian decision theory. *Pattern Recognition*, 41(2), 521–530. <https://doi.org/10.1016/j.patcog.2007.07.007>
- Tian, L. F., & Slaughter, D. C. (1998). Environmentally adaptive segmentation algorithm for outdoor image segmentation. *Computers and Electronics in Agriculture*, 21(3), 153–168. [https://doi.org/10.1016/S0168-1699\(98\)00037-4](https://doi.org/10.1016/S0168-1699(98)00037-4)
- Tokekar, P., Hook, J. V., Mulla, D., & Isler, V. (2016). Sensor Planning for a Symbiotic UAV and UGV System for Precision Agriculture. *IEEE Transactions on Robotics*, 32(6), 1498–1511. <https://doi.org/10.1109/TRO.2016.2603528>
- Toth, C., & Józków, G. (2016). Remote sensing platforms and sensors: A survey. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 22–36. <https://doi.org/10.1016/j.isprsjprs.2015.10.004>
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
- Turner, D., Lucieer, A., & Wallace, L. (2014). Direct Georeferencing of Ultrahigh-Resolution UAV Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 52(5), 2738–2745. <https://doi.org/10.1109/TGRS.2013.2265295>
- Turner, D., Lucieer, A., & Watson, C. (2012). An Automated Technique for Generating Georectified Mosaics from Ultra-High Resolution Unmanned Aerial Vehicle (UAV) Imagery, Based on Structure from Motion (SfM) Point Clouds. *Remote Sensing*, 4(5), 1392–1410. <https://doi.org/10.3390/rs4051392>
- Uijlings, J. R. R., Sande, K. E. A. van de, Gevers, T., & Smeulders, A. W. M. (2013). Selective Search for Object Recognition. *International Journal of Computer Vision*, 104(2), 154–171. <https://doi.org/10.1007/s11263-013-0620-5>

- Uroukov, I., & Speller, R. (2015). A Preliminary Approach to Intelligent X-ray Imaging for Baggage Inspection at Airports. *Signal Processing Research*, 4(0), 1–1.
- Uto, K., Seki, H., Saito, G., & Kosugi, Y. (2013). Characterization of Rice Paddies by a UAV-Mounted Miniature Hyperspectral Sensor System. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6(2), 851–860. <https://doi.org/10.1109/JSTARS.2013.2250921>
- Valverde, A., González-Tirante, M., Medina-Sierra, M., Rivas, R., Santa-Regina, I., & Igual, J. M. (2017). Culturable bacterial diversity from the chestnut (Castanea sativa Mill.) phyllosphere and antagonism against the fungi causing the chestnut blight and ink diseases. *Microbiology* 2017, Vol. 3, Pages 293-314. <https://doi.org/10.3934/microbiol.2017.2.293>
- Van Henten, E. J., Van Tuijl, B. A. J., Hemming, J., Kornet, J. G., Bontsema, J., & Van Os, E. A. (2003). Field Test of an Autonomous Cucumber Picking Robot. *Biosystems Engineering*, 86(3), 305–313. <https://doi.org/10.1016/j.biosystemseng.2003.08.002>
- Varshney, S. S., Rajpal, N., & Purwar, R. (2009). Comparative study of image segmentation techniques and object matching using segmentation. Em 2009 *Proceeding of International Conference on Methods and Models in Computer Science (ICM2CS)* (pp. 1–6). <https://doi.org/10.1109/ICM2CS.2009.5397985>
- Vettraino, A. M., Morel, O., Perlerou, C., Robin, C., Diamandis, S., & Vannini, A. (2005). Occurrence and distribution of Phytophthora species in European chestnut stands, and their association with Ink Disease and crown decline. *European Journal of Plant Pathology*, 111(2), 169. <https://doi.org/10.1007/s10658-004-1882-0>
- Vieira, R., Antunes, M., Silva, C., & Assis, A. (2017). Automatic Documents Counterfeit Classification Using Image Processing and Analysis. Em *Pattern Recognition and*

- Image Analysis* (pp. 400–407). Springer, Cham. https://doi.org/10.1007/978-3-319-58838-4_44
- Vincent, L., & Soille, P. (1991). Watersheds in digital spaces: an efficient algorithm based on immersion simulations. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, (6), 583–598.
- Wallace, L. (2013). Assessing the stability of canopy maps produced from UAV-LiDAR data. *Em 2013 IEEE International Geoscience and Remote Sensing Symposium - IGARSS* (pp. 3879–3882). <https://doi.org/10.1109/IGARSS.2013.6723679>
- Whitehead, K., Moorman, B. J., & Hugenholtz, C. H. (2013). Low-cost, on-demand aerial photogrammetry for glaciological measurement. *The Cryosphere Discussions*, 7, 3043–3057. <https://doi.org/10.5194/tcd-7-3043-2013>
- Woebbecke, D. M. (University of N., Meyer, G. E., Von Bargen, K., & Mortensen, D. A. (1995). Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE (USA)*. Obtido de <http://agris.fao.org/agris-search/search.do?recordID=US9561468>
- Xiang, H., & Tian, L. (2011). Development of a low-cost agricultural remote sensing system based on an autonomous unmanned aerial vehicle (UAV). *Biosystems Engineering*, 108(2), 174–190. <https://doi.org/10.1016/j.biosystemseng.2010.11.010>
- Zarco-Tejada, P. J., González-Dugo, V., & Berni, J. A. J. (2012). Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. *Remote Sensing of Environment*, 117(Supplement C), 322–337. <https://doi.org/10.1016/j.rse.2011.10.007>
- Zarco-Tejada, P. J., Guillén-Climent, M. L., Hernández-Clemente, R., Catalina, A., González, M. R., & Martín, P. (2013). Estimating leaf carotenoid content in vineyards using high resolution hyperspectral imagery acquired from an unmanned aerial vehicle (UAV).

- Agricultural and Forest Meteorology*, 171–172, 281–294.
<https://doi.org/10.1016/j.agrformet.2012.12.013>
- Zecha, C. W., Link, J., & Claupein, W. (2013). Mobile sensor platforms: categorisation and research applications in precision farming. *Journal of Sensors and Sensor Systems*, 2(1), 51–72. <https://doi.org/10.5194/jsss-2-51-2013>
- Zhang, Y., Xiong, J., & Hao, L. (2011). Photogrammetric processing of low-altitude images acquired by unpiloted aerial vehicles. *The Photogrammetric Record*, 134(26), 190–211.
<https://doi.org/10.1111/j.1477-9730.2011.00641.x>
- Zheng, L., Shi, D., & Zhang, J. (2010). Segmentation of green vegetation of crop canopy images based on mean shift and Fisher linear discriminant. *Pattern Recognition Letters*, 31(9), 920–925. <https://doi.org/10.1016/j.patrec.2010.01.016>
- Zheng, L., Zhang, J., & Wang, Q. (2009). Mean-shift-based color segmentation of images containing green vegetation. *Computers and Electronics in Agriculture*, 65(1), 93–98.
<https://doi.org/10.1016/j.compag.2008.08.002>

Anexos

Anexo A – Resultados dos índices de vegetação testados

Índice de Vegetação	Área 1			Área 2			Área 3			Área 4			Área 5			Área 6			Área 7		
Índices RE																					
	E	Ex	F	E	Ex	F	E	Ex	F	E	Ex	F	E	Ex	F	E	Ex	F	E	Ex	F
BNDVI	93	1	6	96	1	3	95	0	5	98	0	2	97	0	3	99	0	1	89	0	11
DVI	93	4	3	96	2	2	96	2	2	98	0	2	97	2	1	98	1	1	87	5	8
EVI	92	5	3	96	2	2	95	2	3	98	0	2	96	3	1	98	1	1	87	7	6
ExRE	96	1	3	98	1	1	97	0	3	99	0	1	98	1	1	99	0	1	94	0	6
GDVI	94	3	3	97	2	1	98	1	1	98	2	0	98	2	0	99	1	0	93	2	5
GN	95	4	1	97	2	1	98	1	1	98	2	0	96	4	0	98	2	0	95	3	2
GSAVI	95	4	1	97	2	1	98	1	1	98	2	0	97	2	1	99	1	0	95	2	3
MSAVI	93	4	3	96	2	2	95	2	3	98	0	2	96	3	1	98	1	1	87	6	7
NDVI	92	5	3	96	2	2	95	2	3	98	0	2	96	3	1	98	1	1	86	7	7
OSAVI	93	4	3	96	2	2	95	2	3	98	0	2	97	2	1	98	1	1	87	6	7
SAVI	93	4	3	96	2	2	95	2	3	98	1	1	96	3	1	98	1	1	87	6	7
Índices RGB																					
	E	Ex	F	E	Ex	F	E	Ex	F	E	Ex	F	E	Ex	F	E	Ex	F	E	Ex	F
ExG	93	0	7	95	0	5	96	0	4	98	0	2	95	0	5	99	0	1	89	0	11
GBVI	90	3	7	73	25	2	64	35	1	54	46	0	95	1	4	99	0	1	88	1	11
GRVI	87	7	6	94	0	6	91	1	8	97	0	3	92	3	5	98	1	1	82	6	12
MGRVI	86	7	7	93	0	7	91	1	8	97	0	3	92	3	5	98	1	1	82	6	12
RGBVI	93	0	7	96	0	4	97	0	3	98	0	2	96	0	4	99	0	1	90	0	10
VARig	84	8	8	93	0	7	90	1	9	98	0	2	90	3	7	97	1	2	80	7	13

E – Detecção exata (%)

Ex – Detecção em excesso (falsos positivos) (%)

F – Detecção em falta (falsos negativos) (%)