



David Alexandre Fernandes Mestre

Licenciado em Ciências da Engenharia Eletrotécnica e de Computadores

**Monitorização de crescimento de plantas
cultivadas in-vitro usando processamento digital
de imagem**

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

Orientador: André Teixeira Bento Damas Mora, Professor Auxiliar,
Faculdade de Ciências e Tecnologia
da Universidade Nova de Lisboa

Co-orientador: José Manuel Matos Ribeiro da Fonseca, Professor Au-
xiliar com Agregação,
Faculdade de Ciências e Tecnologia
da Universidade Nova de Lisboa

Júri

Presidente: Doutor Paulo da Costa Luís da Fonseca Pinto
Arguente: Doutora Maria da Graça Vieira de Brito Almeida
Vogal: Doutor André Teixeira Bento Damas Mora



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE NOVA DE LISBOA

Março, 2017

Monitorização de crescimento de plantas cultivadas in-vitro usando processamento digital de imagem

Copyright © David Alexandre Fernandes Mestre, Faculdade de Ciências e Tecnologia, Universidade NOVA de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade NOVA de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

À minha família e amigos, um grande abraço.

AGRADECIMENTOS

Em primeiro lugar, gostaria de gratificar o meu orientador, Professor André Teixeira Bento Damas Mora e ao co-orientador, José Manuel Matos Ribeiro da Fonseca, por toda a orientação, conselhos, disponibilidade que prestaram ao longo do desenvolvimento desta dissertação sempre com boa disposição. Também queria agradecer pela oportunidade de lecionar aulas práticas.

Em segundo lugar, um agradecimento à empresa Boereboom Invitro Portugal por apresentar este problema e colaborar na aquisição das imagens usadas nesta dissertação.

À Faculdade de Ciências de Tecnologia da Universidade Nova de Lisboa e a todos os Professores que tive o gosto de conhecer e privilégio de aprender ao longo do percurso académico que realizei nesta instituição.

A todos os meus amigos e companheiros de curso que conheci durante todo este percurso, seja pelas aventuras passadas e pela grande amizade criada que ajudou a ultrapassar os piores momentos destes anos. De todas as amizades criadas, quero destacar os meus grandes colegas e amigos com quem passei estes anos: André Estevam, Daniela Oliveira, Duarte Segurado, Fábio Carmo, Fábio Silva, Gonçalo Freitas, Joana Barruncho e Miguel Prego. Também deixo aqui um agradecimento especial ao meu colega de Mestrado João Dinis, por todo o gozo e sofrimento que partilhámos ao longo das cadeiras. Em cada um de vocês levo uma amizade para a vida.

À minha família, que dirijo um dos meus maiores agradecimentos, pela educação e todo o apoio prestado. Em especial aos meus pais, agradeço por todos os sacrifícios e preocupações que tiveram que ultrapassar para que eu pudesse seguir com o meu percurso académico.

RESUMO

Processamento digital de imagem pode desempenhar um papel importante no estudo e monitorização de plantas, permitindo medir as suas características sem recorrer a métodos invasivos ou exaustivos. Em culturas de plantas *in-vitro*, as condições de cultura são determinantes para a evolução das plantas, sendo a monitorização das culturas uma ferramenta importante para avaliar o desempenho de cada ensaio de novas condições.

Nesta dissertação apresentamos um sistema de visão computacional e aprendizagem supervisionada para monitorização de plantas *in-vitro*, contribuindo para a avaliação da performance da produção em diferentes condições de crescimento, como por exemplo, o melhoramento do meio de cultura conforme as necessidades de cada espécie.

Como caso de estudo, foi analisada a produção de plantas *in-vitro*, adquirindo semanalmente imagens no espectro visível e infravermelho-próximo.

O método proposto pré-processa, regista e normaliza as imagens adquiridas de cada recipiente, sendo depois segmentadas através de uma *Random Forest* que classifica pixels como planta ou não-planta. No final é exportada a área total das plantas e o NDVI médio de cada sessão de monitorização. Foi criada uma interface gráfica para carregar e processar as imagens adquiridas de um recipiente.

A validação do método foi realizada com um conjunto de imagens em que a segmentação das plantas foi realizada manualmente. Apresentou valores de precisão de 96.9%, 96.8% sensibilidade e 96.9% especificidade. Nos resultados obtidos foi possível detetar diferentes comportamentos no crescimento das plantas de cada recipiente. Verificou-se também que a taxa de crescimento da área das plantas de um recipiente acompanhou a sua taxa de crescimento da vitalidade dada pelo NDVI médio.

Palavras-chave: Culturas de plantas *in-vitro*; Segmentação de plantas; Processamento digital de imagem; Aprendizagem Automática; Random forest.

ABSTRACT

Digital image processing can play an important role in the study and monitoring of plants, allowing to measure plant features without recurring to invasive or exhaustive methods. In in-vitro plant cultures, the culture conditions are determinant to the evolution of plants, being essential to monitor these cultures to evaluate the performance of each new conditions essay.

In this dissertation we present a computer vision and machine learning system for in-vitro plant monitoring, contributing for the evaluation of the production in different growing conditions, as for example, for the improvement of the culture medium for the necessities of each plant specie.

As a case study, we analysed the production of in-vitro plants, acquiring images weekly from visible and near infra-red spectrum.

The proposed method preprocesses, registers and normalizes the acquired images from one container, being then segmented using a trained Random Forest, which classifies pixels as plant or non-plant. At the end, plants total area and average NDVI for each monitoring session are exported. A graphical user interface was developed to load and process images acquired from one container.

The validation was done with an image dataset in which the plant segmentation was performed manually. The method obtained a precision of 96.9%, 96.8% sensitivity and 96.9% specificity. Analysing the results, it were detected several plant growth behaviours from the plants of each container. In addition, it was possible to verify that the growth rate of the plant area of a container followed its growth rate of the vitality given by the average NDVI.

Keywords: In-vitro plant cultures; Plant segmentation; Digital image procesing; Machine learning; Random forest.

ÍNDICE

Lista de Figuras	xv
Lista de Tabelas	xvii
Siglas	xix
1 Introdução	1
1.1 Motivação	1
1.2 Objetivos	2
1.3 Organização do documento	3
2 Estado da Arte	5
2.1 Monitorização de plantas	5
2.1.1 Espectro Eletromagnético	5
2.1.2 Taxa de crescimento das plantas	7
2.1.3 Estimação de clorofila	7
2.2 Segmentação de plantas	9
2.2.1 Índices de vegetação	9
2.2.2 <i>Normalized Difference Vegetation Index</i>	13
2.2.3 Segmentação com <i>machine learning</i>	14
2.2.4 Desafios	15
3 Conceitos Teóricos	17
3.1 Machine learning	17
3.1.1 Aprendizagem supervisionada	18
3.1.2 Métricas de avaliação	20
3.2 Speeded-Up Robust Features	22
3.3 Transformada circular de Hough	23
4 Aquisição de Imagem	27
4.1 Materiais	27
4.2 Aquisição	29
4.3 Desafios	30

5	Trabalho Desenvolvido	35
5.1	Pré-processamento de imagem	36
5.1.1	Região de interesse	38
5.1.2	Ajuste de escala	42
5.1.3	Registo das imagens visível e infravermelho-próximo	43
5.1.4	Balanceamento de brancos	44
5.1.5	Máscara do recipiente	46
5.2	Segmentação com Random Forest	46
5.2.1	Seleção de Características	47
5.2.2	Seleção do conjunto de treino	48
5.2.3	Treino da Random Forest	51
5.2.4	Aplicação da Random Forest	53
5.3	Extração de Informação	55
5.4	Protótipo de monitorização	56
6	Validação e Resultados Obtidos	59
6.1	Validação da metodologia proposta	59
6.1.1	Ground truth	59
6.1.2	Validação da metodologia	60
6.1.3	Validação da Área e NDVI médio	62
6.2	Resultados	65
7	Conclusão e Trabalho Futuro	71
7.1	Conclusão	71
7.2	Trabalho futuro	72
7.2.1	Melhorar aquisição de imagem	73
7.2.2	Mais casos de estudo	73
7.2.3	Aumentar o ground truth	73
7.2.4	Afinar método desenvolvido	73
7.2.5	Testar outros algoritmos de machine learning	74
	Bibliografia	75

LISTA DE FIGURAS

2.1	Refletância das plantas no espectro eletromagnético	6
2.2	Processamento digital da imagem realizado. (Wu et al. 2009)	8
2.3	Medidor SPAD.	8
2.4	Comparação entre CIVE, ExG e o método proposto em (Zheng et al. 2009).	13
2.5	Exemplo de um mapa global composto pelo NDVI.	14
2.6	Imagem de uma planta com retro-reflexão e transições de iluminação.	16
3.1	Exemplo de uma árvore de decisão.	19
3.2	Deteção do círculo através da transformada circular de Hough.	25
4.1	Câmara de fluxo de ar de onde foi realizado a aquisição de imagem.	28
4.2	Guias de calibração usadas na aquisição de imagem.	29
4.3	Exemplo de imagens adquiridas para um recipiente de plantas <i>in-vitro</i> na 2ª sessão.	32
4.4	Exemplo de imagens adquiridas para um recipiente de plantas <i>in-vitro</i> na 5ª sessão.	33
4.5	Exemplo de imagens adquiridas para um recipiente de plantas <i>in-vitro</i> na última sessão.	34
5.1	Fluxograma do método proposto.	37
5.2	Representação da desorientação da guia.	38
5.3	Extração dos círculos de alinhamento da guia.	40
5.4	Extração do recipiente <i>in-vitro</i> através da transformada circular de Hough.	42
5.5	Resultado final da correção do ângulo de orientação e recorte do recipiente <i>in-vitro</i>	42
5.6	Correspondência das características SURF entre as imagens do espectro visível e infravermelho-próximo.	44
5.7	Resultado da transformação geométrica numa imagem (a) e prevalecimento de um certo desalinhamento (b).	45
5.8	Balanceamento de brancos das imagens do espectro visível.	46
5.9	Isolamento da zona de interesse nas imagens do espectro visível.	47
5.10	Algumas das imagens usadas para extração dos dados de treino (esquerda) e representação da máscara com pontos a extrair (direita).	50

5.11 Fluxograma do algoritmo de exportação do conjunto de treino do conjunto de imagens selecionadas com base da máscara de pontos criada.	52
5.12 Fluxograma do algoritmo de segmentação.	54
5.13 Resultado da segmentação com a <i>random forest</i> , com os pixels classificados como não-planta e exteriores a preto.	55
5.14 <i>Screenshot</i> da aplicação desenvolvida.	57
6.1 Exemplo de imagens da segmentação realizada manualmente para o <i>ground truth</i>	61
6.2 Exemplo de imagens da segmentação realizada pela <i>random forest</i>	63
6.3 Exemplo de imagens da comparação da segmentação da <i>random forest</i> com o <i>ground truth</i> com indicação de falsos positivos a vermelho e falsos negativos a verde.	64
6.4 Comparação da evolução da área estimada pelo do método desenvolvido com a área determinada pelo <i>ground truth</i> do recipiente 20.	65
6.5 Comparação da evolução do NDVI médio estimado pelo do método desenvolvido com o NDVI médio determinado pelo <i>ground truth</i> do recipiente 20.	65
6.6 Segunda e última semana do recipiente 9. Este recipiente registou o terceiro maior crescimento.	66
6.7 Segunda semana e última semana do recipiente 10. Neste recipiente as plantas morreram.	66
6.8 Imagens visíveis e infravermelho-próximo segmentadas do recipiente 16.	67
6.9 Estimação da evolução da área dos vários recipientes ao longo das semanas.	68
6.10 Estimação da evolução do NDVI médio dos vários recipientes ao longo das semanas.	69

LISTA DE TABELAS

3.1	Representação das classificações possíveis numa matriz de confusão.	21
4.1	Datas das várias sessões realizadas de aquisição de imagem e espectros captados.	30
4.2	Configurações de aquisição de imagem usadas para cada perfil.	31
5.1	Características usadas para descrever um pixel no conjunto de dados.	48
5.2	Matriz de confusão da fase de treino.	53
5.3	Métricas de avaliação da fase de treino.	53
5.4	Esquema da tabela extraída da evolução da área e NDVI médio por sessão de um recipiente <i>in-vitro</i>	55
6.1	Imagens usadas para o <i>ground truth</i>	60
6.2	Valores médios das métricas de avaliação para o método desenvolvido dos pixels interiores do recipiente.	62
6.3	Taxa de crescimento da área e NDVI médio de cada recipiente entre a semana 1 e 12, ordenados do maior para o menor.	69

SIGLAS

CIVE *Colour Index of Vegetation Extraction.*

ExGR *Excess Green minus Excess Red Index.*

FN Falso negativo.

FP Falso positivo.

HSV *Hue Saturation and Value.*

NDVI *Normalized difference vegetation index.*

NIR *Infravermelho-próximo (near-infrared).*

RGB *Red blue and green.*

SURF *Speed-up robust features.*

TCH *Transformada circular de Hough.*

TFN *Taxa de falsos negativos.*

TFP *Taxa de falsos positivos.*

VN *Verdadeiro negativo.*

VP *Verdadeiro positivo.*

VPN *Valor preditivo negativo.*

VPP *Valor preditivo positivo.*

INTRODUÇÃO

1.1 Motivação

Técnicas de processamento digital de imagem têm vindo ao longo dos anos a mostrar cada vez mais vantagens na sua aplicabilidade na agricultura de precisão. O principal objetivo tem sido monitorizar as culturas para se conseguir determinar e acompanhar o seu grau de crescimento e identificar antecipadamente o aparecimento de irregularidades, sejam doenças ou problemas de irrigação. Existe então a necessidade de implementar sistemas que permitam monitorizar as plantações de forma automática, sem intervenção humana e idealmente de forma não invasiva. As imagens digitais têm ainda a vantagem de serem facilmente armazenáveis, não existindo qualquer tipo de deterioração com o tempo.

Micropropagação é uma técnica de cultura *in-vitro* que pode ser aplicada à produção de plantas. Esta técnica começa a partir de uma planta "mãe", sendo repartida em pequenos tecidos, originando uma nova geração de plantas. Este processo é repetido nestas mesmas plantas quando atingem um estado avançado, dando origem a grandes quantidades de plantas geneticamente iguais (Tillett et al. 1990). Como estas culturas habitualmente possuem um grande número de *stock*, torna-se exaustivo para um ser humano monitorizar cada recipiente para avaliar o estado de cada planta e o seu grau de crescimento.

Estas culturas são trabalhadas em condições esterilizadas onde é necessário ser cauteloso para garantir que os recipientes não sejam contaminados, colocando a cultura em risco. Existe então a necessidade de implementar métodos que não influenciam o alvo do estudo, para garantir que seja possível obter alguma informação de monitorização das culturas *in-vitro* sem danificar parcialmente as mesmas. O processamento digital de imagem tem a vantagem de ser uma técnica não intrusiva, pois é baseado em imagens digitais adquiridas a partir de uma câmara fotográfica, sem interferir com a cultura *in-vitro*.

No método de micro-propagação *in-vitro* é possível controlar as condições de cultura tais como o meio de cultura, iluminação e temperatura, beneficiando ou não a produção das plantas. Por isso um método que permita avaliar qual o desempenho de cada ensaio de condições de culturas é importante para determinar qual a melhor combinação, de forma a otimizar a produção com uma melhor vitalidade e fator de crescimento.

Esta dissertação teve o apoio da empresa *Boereboom Invitro Portugal*, nomeadamente na disponibilização para adquirir imagens da evolução de culturas *in-vitro*.

1.2 Objetivos

Esta dissertação tem como principal objetivo o estudo da evolução de culturas de plantas *in-vitro*, através do desenvolvimento de métodos baseados em processamento digital de imagem que permitam segmentar estas plantas e monitorizar o seu crescimento. Estes métodos analisam sequências de imagens adquiridas de cada recipiente, no espectro visível e infravermelho-próximo para estimar a área de vegetação e NDVI (*Normalized Difference Vegetation Index*) médio. Os métodos e uma interface de utilizador para processar as imagens e adquirir os resultados foram desenvolvidos em *Matlab*.

Esta dissertação contribuiu para o desenvolvimento de um conjunto de métodos que permitem monitorizar a evolução das culturas *in-vitro*, de modo a avaliar a performance das mesmas em diferentes condições ambientais e/ou composição do meio de cultura e assim contribuir para a otimização e maximização da produção.

Partimos então da seguinte questão de investigação: será o processamento digital de imagens útil para a monitorização e avaliação de performance de culturas de plantas *in-vitro*?

Ao longo da elaboração da dissertação, várias dificuldades foram enfrentadas. Na aquisição de imagem (capítulo 4), foram utilizadas duas máquinas fotográficas distintas para a aquisição de imagens do espectro visível e do espectro infravermelho-próximo, sendo que com a primeira foi realizada a aquisição de todas as imagens do espectro visível, e só depois é que foi realizada a aquisição de imagens do espectro infravermelho-próximo. Consequentemente, as plantas não ficaram completamente alinhadas e o pré-processamento de imagem para o registo de imagem não conseguiu corrigir completamente este problema.

Durante a validação do método (capítulo 6), foi necessária a criação de um conjunto de imagens segmentadas com a classificação real/esperada (*ground truth*). Para tal, foram segmentadas manualmente imagens para realizar a avaliação dos resultados obtidos pelo método desenvolvido. Esta tarefa foi morosa e fastidiosa de se realizar corretamente, pois neste caso exige que todos os pixels da planta sejam manualmente identificados. Esta identificação é extremamente desafiante de se realizar nos limites da planta.

1.3 Organização do documento

Este documento encontra-se organizado em mais 6 capítulos. No segundo capítulo, é feita uma revisão estado da arte, apresentando uma breve descrição das técnicas de monitorização de plantas através de várias bandas do espectro eletromagnético e vários métodos de segmentação de plantas encontrados na literatura.

No terceiro capítulo, são apresentados conceitos teóricos de *machine learning*, técnicas de processamento de imagem para deteção de características locais e a transformada circular de Hough.

O quarto capítulo é dedicado à aquisição de imagem realizada, descrevendo todo o processo realizado.

No quinto capítulo são descritos os métodos propostos para a segmentação e monitorização de plantas e no final o protótipo criado.

No sexto capítulo mostram-se: a validação do nosso método com um *ground truth* criado manualmente, os resultados obtidos pela segmentação automática e a estimação da área e NDVI médio.

No sétimo e último capítulo desenham-se as conclusões finais desta dissertação e deixa-se uma nota para trabalhos futuros.

CAPÍTULO



ESTADO DA ARTE

Este capítulo apresenta uma síntese de trabalhos que fazem uso de processamento digital de imagem para monitorização das plantas. Serão apresentadas algumas técnicas que usam várias bandas do espectro eletromagnético e como podem ser aplicadas para aferir a taxa de crescimento das plantas e a estimação do conteúdo de clorofila. Em seguida são apresentadas técnicas de segmentação de plantas. Estas são divididas em índices de vegetação e *machine learning* sendo discutidos os vários desafios destes tipos de segmentação. Por fim, é apresentado o *Normalized Difference Vegetation Index* que usa a banda visível e a banda do infravermelho-próximo para mapear vegetação.

2.1 Monitorização de plantas

Monitorização de plantas tem como objetivo medir os vários parâmetros das plantas relacionados com o crescimento, adaptação e identificação de irregularidades na mesma. Estas medidas são geralmente realizadas através do estudo da morfologia da planta, características da folha ou da fruta e fotossíntese (Li et al. 2014).

Métodos baseados em processamento digital de imagem permitem quantificar zonas da planta, sendo fontes primárias para o estudo da monitorização das plantas (Li et al. 2014). Em (Lobet et al. 2013) é apresentada uma base de dados de aplicações de processamento digital de imagem que foram desenvolvidas para a análise de plantas. Atualmente possui cerca 143 soluções de *software*¹.

2.1.1 Espectro Eletromagnético

Cada tipo de célula e tecido da planta tem propriedades específicas na absorção e reflexão de certos comprimentos de onda, mostrando assim diferentes aplicabilidades para cada

¹<http://www.plant-image-analysis.org/>

banda do espectro (Li et al. 2014). Por exemplo, na banda da luz visível (400 - 700 nm), devido à absorção da luz por parte da clorofila, a planta tem baixa reflexão. No entanto, na banda do infravermelho-próximo (700 - 1200 nm) a reflexão da planta é muito maior (figura 2.1). Em seguida será apresentada uma seleção de trabalhos que usam imagens no espectro de luz visível, imagem de fluorescência e espectrometria no infravermelho-próximo.

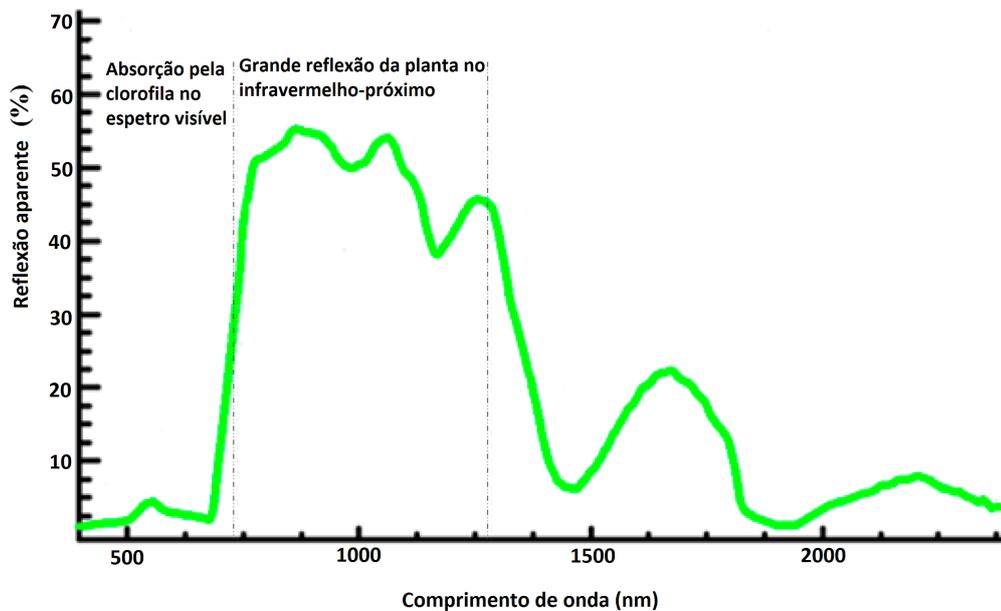


Figura 2.1: Refletância das plantas no espectro eletromagnético. Adaptado de (Li et al. 2014)

2.1.1.1 Espectro visível

A aquisição de imagem a partir do espectro visível da luz é o método convencional das câmaras digitais, existindo atualmente uma grande variedade das mesmas, para uma vasta gama de preços. Esta técnica é a mais aplicada e a mais simples, sendo usada principalmente para a determinação da área, estudo da morfologia da planta e detecção de sintomas (Barbedo 2016; Barbedo et al. 2016). Por apenas obter informação fisiológica da planta, pode ser difícil obter resultados fiáveis devido à sobreposição entre folhas (Li et al. 2014).

2.1.1.2 Imagens de Fluorescência

Fluorescência é a luz emitida por um objeto após a absorção de radiação num outro comprimento de onda. No caso da planta, a fluorescência da mesma corresponde à clorofila. Pode ser usado para determinar a capacidade que a planta possui para metabolizar a luz absorvida através da emissão de luz azul. Esta técnica tem como aplicabilidade a detecção

de doenças. No entanto, a maioria dos estudos realizados são limitados apenas a folhas individuais (Li et al. 2014).

2.1.1.3 Espetrometria de imagens no infravermelho-próximo

Espetrometria de imagens consiste na captação de luz de várias bandas do espectro eletromagnético. No espectro visível a planta tem uma baixa refletividade, ocorrendo apenas um pico na região do verde devido à clorofila (Figura 2.1). No entanto, no início do espectro do infravermelho-próximo, a planta tem uma maior refletividade, onde a espessura e o porte das folhas são os fatores de reflexão determinantes neste espectro (Li et al. 2014). Esta técnica permite realizar medições da biomassa verde, conteúdo de clorofila e o estado da água na planta. No entanto, equipamentos de espectrometria de imagens têm um custo elevado (Li et al. 2014).

2.1.2 Taxa de crescimento das plantas

Em (Wu et al. 2009) é aplicado processamento digital de imagem para a modelação do crescimento de plantas *Atractylodes lancea*. Através dos valores previamente determinados da biomassa de cada planta e da contagem de pixels que cada planta possui na imagem tratada, é construído um modelo linear que permite estimar a biomassa da planta através do número de pixels com que a mesma está representada na imagem. Também determinaram uma equação logística que modela a evolução da biomassa da planta com o tempo (Wu et al. 2009). Este método foi captado num ambiente esterilizado, fundo branco e lâmpadas fluorescentes como fonte de luz. O processamento digital de imagem foi realizado manualmente no *Adobe Photoshop*, onde foi feita uma conversão da imagem para escala de cinzentos, ajustamento do brilho, contraste e negativo da imagem, sendo depois contados os pixels pertencentes à planta (Figura 2.2). Os resultados permitiram concluir que é possível prever o crescimento das plantas *in-vitro* (Wu et al. 2009).

2.1.3 Estimação de clorofila

A cor das plantas permite obter indicações da quantidade de clorofila que a mesma tem. Nomeadamente a cor verde reflete os pigmentos de clorofila que as folhas possuem (Yao et al. 2010). O método mais usado para determinar a quantidade de clorofila presente numa folha é o uso de um medidor SPAD (*Soil Plant Analysis Development*) (Figura 2.3) (Menesatti et al. 2010). Este medidor, que transmite luz num comprimento de onda vermelho e outro infravermelho, calcula um valor designado por SPAD que está relacionado com o conteúdo de clorofila, devido à absorção da luz vermelha e reflexão da luz infravermelha (Markwell et al. 1995). No entanto, este medidor não é aplicável para monitorização em tempo real (Yadav et al. 2010).

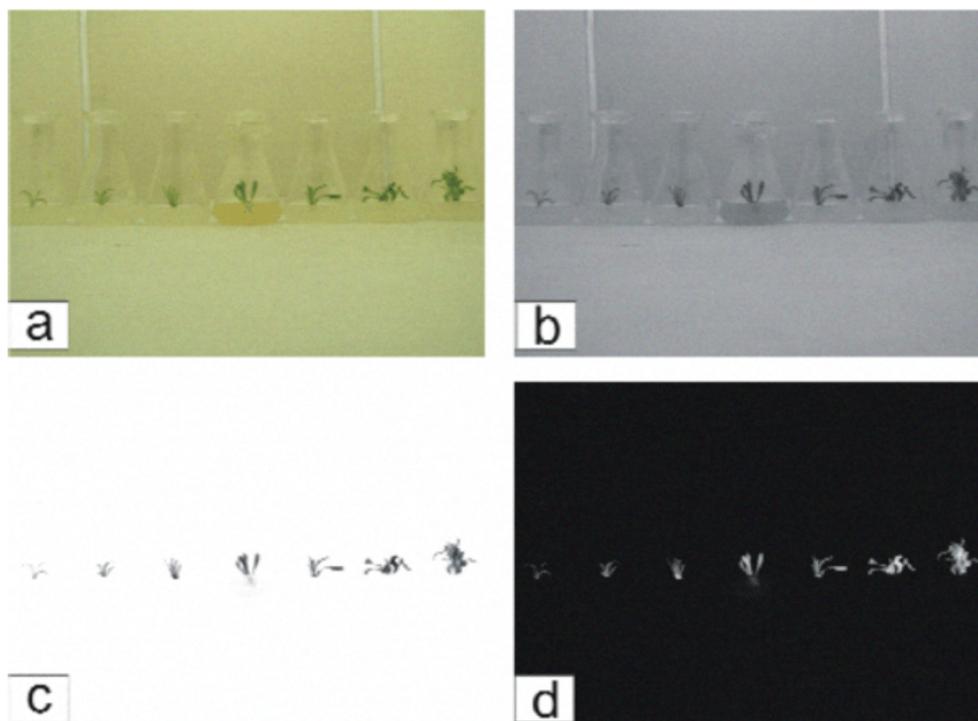


Figura 2.2: Processamento digital da imagem realizado. Em *a* está a imagem original; *b* a passagem para escala de cinzentos; *c* ajustamento do brilho e do contraste; *d* o negativo da imagem *c*. (Wu et al. 2009)



Figura 2.3: Medidor SPAD. (Yadav et al. 2010)

Como a atividade fotossintética está relacionada com o conteúdo de clorofila (MacIntyre et al. 2002), é importante avaliar as suas propriedades para otimização das culturas *in-vitro* para atingir uma produção eficiente. Como qualquer cor pode ser decomposta nas componentes RGB (*Red, green and blue*), é possível desenvolver correlações entre as intensidades destas cores com o conteúdo de clorofila da planta. Isto é verificado em (Yadav et al. 2010), onde é desenvolvido um método não invasivo para determinar o conteúdo de clorofila em culturas de micropropagação de plantas de batatas. Estes realizaram a aquisição de imagem das folhas através de um *scanner*, tendo sido depois obtido o histograma das componentes RGB via *Adobe Photoshop*. Daqui, retiraram os valores médios das componentes RGB e HSL (*Hue, saturation and lightness*) e os seus respetivos rácios. Estes

valores foram usados para a obtenção de modelos descritos em (Su et al. 2008), sendo os outros parâmetros desses modelos calculados posteriormente. Os autores concluíram que as componentes vermelha e verde são inversamente proporcionais ao conteúdo de clorofila na planta enquanto que a componente azul é diretamente proporcional. O uso dos rácios das componentes melhorou estes resultados (Yadav et al. 2010) e também se verificou que a luminosidade e saturação correlacionam negativamente com o conteúdo de clorofila.

2.2 Segmentação de plantas

Segmentação de plantas corresponde ao processo de identificar numa imagem digital, as regiões (conjunto de pixels) pertencentes às plantas presentes. A maioria da literatura encontrada é focada no processo de segmentação de plantas em ambientes não controlados, ou seja, em campos exteriores. Condições de iluminação trazem consigo grandes desafios para estes métodos, como por exemplo situações em que a iluminação é forte, provocando zonas de reflexo nas folhas das plantas, podendo-se tornar mal segmentadas. Também a presença de sombras das folhas na imagem podem originar uma segmentação em que essas sombras sejam consideradas como parte da folha. Visto que o objetivo é separar as plantas do resto que não são plantas, fundos complexos também podem induzir os métodos a erro (Hamuda et al. 2016).

Grande parte das técnicas de processamento de imagem para segmentação de plantas encontradas ao longo da literatura são em geral técnicas baseadas em índices de cor, nomeadamente índices de vegetação. Encontram-se também várias técnicas baseadas em *thresholds* que são usualmente combinadas com índices de cor, nomeadamente a junção destes índices com o método *Otsu* (Otsu 1979). As mais avançadas e as que permitem obter melhores resultados, apesar da maior complexidade computacional são técnicas de *machine learning* que também são aplicáveis para a segmentação de plantas e podem ser combinadas com os índices de vegetação (Hamuda et al. 2016).

2.2.1 Índices de vegetação

Índices de vegetação são úteis apenas para plantas onde a cor dominante é a verde, estando relacionados com características da planta como a massa fotossintética, clorofila e água (Li et al. 2014). Não são recomendáveis para ambientes com fraca ou forte iluminação.

Em seguida são enumerados vários índices de vegetação. Estes índices são calculados a partir das componentes RGB da imagem, originando uma imagem em escala de cinzentos, sendo que a maioria resulta numa imagem quase binária. As imagens em escala de cinzentos são constituídas por apenas um canal de cor com intensidades entre 0 a 255. Para convenção, define-se a componente vermelha, verde e azul de uma imagem como R, G e B.

- **Normalised Difference Index (NDI)** (Woebbecke et al. 1993)

Em (Woebbecke et al. 1993) foram testados vários índices de cor baseados nas componentes RGB da imagem com o objetivo de avaliar a eficácia dos mesmos em separar as plantas do fundo. O índice $\frac{G-R}{G+R}$ foi o que obteve melhores resultados, tendo sido o mesmo adaptado para formar o NDI:

$$NDI = 128 * \left(\frac{(G - R)}{(G + R)} + 1 \right) \quad (2.1)$$

Como $\frac{G-R}{G+R}$ produz valores entre -1 e 1, é necessário somar 1 e adicionar um fator de 128 para produzir uma imagem em escala de cinzentos entre 0 a 255. Este índice produz uma imagem quase binária (Hamuda et al. 2016).

- **Excess Green Index (ExG)** (D. M. Woebbecke et al. 1995)

Em (D. M. Woebbecke et al. 1995) o seguinte índice de cor foi o que obteve melhores resultados para a separação das plantas do solo descoberto:

$$ExG = 2G - R - B \quad (2.2)$$

Este índice de cor também produz uma imagem quase binária, sendo o mais usado na separação das plantas (Hamuda et al. 2016).

- **Excess Red Index (ExR)** (Meyer et al. 1999)

Este índice de cor foi inspirado na retina do olho humano, focando-se na componente vermelha:

$$ExR = 1.3R - G \quad (2.3)$$

Não possui melhores resultados que o ExG, mas ambos são usados em conjunto para um novo índice de cor (Meyer et al. 2004).

- **Excess Green minus Excess Red Index (ExGR)** (Meyer et al. 2004)

Este índice de cor consiste na combinação de dois índices apresentados anteriormente, nomeadamente o ExG (Eq. 2.2) e o ExR (Eq. 2.3). O primeiro permite extrair a zona da planta enquanto o segundo reduz o ruído de fundo, seja solo ou possíveis resíduos.

Como o nome indica, este componente resulta de uma subtração entre os dois índices:

$$ExGR = ExG - ExR \quad (2.4)$$

- **Colour Index of Vegetation Extraction (CIVE)** (Kataoka et al. 2003)

Introduzido em (Kataoka et al. 2003), CIVE apresentou melhor segmentação de plantas que o espectro infravermelho-próximo (Kataoka et al. 2003). Este índice é calculado através das componentes RGB da imagem:

$$CIVE = 0.441R - 0.811G + 0.385B + 18.78745 \quad (2.5)$$

- **Vegetative Index (VEG)** (Hague et al. 2006)

Produz uma imagem em escala de cinzentos através da seguinte fórmula:

$$VEG = \frac{G}{R^a B^{(1-a)}} \quad (2.6)$$

A componente a é constante de valor 0.667.

- **Modified Excess Green Index (MExG)** (Burgos-Artizzu et al. 2011)

Desenvolvido por (Burgos-Artizzu et al. 2011), onde para as experiências realizadas obteve melhores resultados que o índice de vegetação ExG. É definido como:

$$MExG = 1.262G - 0.884R - 0.311B \quad (2.7)$$

- **Combined Indices 1 (COM1)** (Guijarro et al. 2011)

Consiste na aplicação simultânea de quatro índices de vegetação referidos anteriormente. Quando estes são aplicados conjuntamente, permitiram obter resultados melhores do que individualmente (Hamuda et al. 2016).

$$COM1 = ExG + CIVE + ExGR + VEG \quad (2.8)$$

- **Combined Indices 2 (COM2)** (Guerrero et al. 2012)

É semelhante ao COM1, no entanto combina três índices em vez de quatro: ExG, CIVE e VEG. O ExGR foi retirado pois no ambiente usado (plantas de milho), este índice segmentava a sombra das plantas como parte da mesma. O índice é definido pela seguinte fórmula:

$$COM2 = 0.36ExG + 0.47CIVE + 0.17VEG \quad (2.9)$$

Aqui foi introduzido a contribuição por parte de cada índice de vegetação através de fatores de peso, nomeadamente 0.36, 0.47 e 0.17.

Estes métodos de índice de vegetação são usados frequentemente como medidas padrão para avaliar novos métodos de segmentação de vegetação propostos (Hamuda et al. 2016). Em várias técnicas novas propostas são usados índices de vegetação para avaliar o desempenho dos novos métodos em relação aos índices.

Em (Meyer e Neto 2008) os índices ExG e NDI são aplicados individualmente com o método de *threshold Otsu* (Otsu 1979), enquanto o ExGR é aplicado apenas um *threshold* de zero. Aqui o ExGR possui melhores resultados e o *threshold* a zero neste mostrou-se suficiente para segmentar as plantas, poupando tempo computacional em relação ao *Otsu*.

Outros métodos de segmentação foram propostos (Hamuda et al. 2016), e para avaliar estes métodos, foram usados vários índices de vegetação para comparação. Estes métodos são mais complexos, logo no geral obtiveram resultados superiores de precisão de segmentação das plantas em relação aos índices de vegetação. No entanto é importante ver qual dos índices obteve melhores resultados, apesar do desempenho ter dependido dos ambientes onde estes foram testados.

Em (Zheng et al. 2009) foram usados os índices ExG e CIVE como medidas de comparação ao método proposto. Foi testado em várias plantas e tipos de solo e iluminação, sendo que de entre os dois índices de vegetação, o CIVE obteve melhores resultados. Encontra-se um exemplo na Figura 2.4.

No ambiente usado em (Bai et al. 2013) os índices ExG, CIVE e ExGR foram utilizados, sendo que o índice que obteve melhores resultados foi novamente o CIVE.

Em (Zheng et al. 2010) foram comparados os índices NDI, ExGR e CIVE, onde obtiveram resultados semelhantes em desempenho médio, apesar das inconsistências ocorridas, nomeadamente imagens onde um método dava melhores resultados que os restantes.

Em (Guijarro et al. 2011) para demonstrar o desempenho do COM1, foram testados individualmente os índices ExG, CIVE, ExGR e VEG. Como resultado, o COM1 foi o que demonstrou melhor desempenho, sendo que os restantes individualmente provocavam em certas situações sobre-segmentação e sub-segmentação.

Em (Yu et al. 2013) foram usados novamente os índices ExG, CIVE, ExGR e VEG para avaliar o desempenho do método proposto. Aqui, o ExG demonstrou outra vez melhores resultados, enquanto o CIVE foi o pior.

Em (Guo et al. 2013) o ExG já não foi o obteve melhores resultados, tendo sido neste caso os métodos MExG e ExGR.

Em (Torres-Sánchez et al. 2014) com o objetivo de medir a precisão de mapeamento da fração de vegetação em campos de trigo, foram usados os seguintes índices de vegetação: ExG, ExGR, CIVE, VEG, COM1 e COM2. Destes índices, o ExG foi o que obteve maior nível médio de precisão, sendo que os restantes possuíram valores similares entre si à exceção do CIVE que foi o pior.

Em suma, não é possível retirar conclusões sobre qual o melhor índice de vegetação, sendo que o desempenho de cada um dependeu das condições de aquisição das imagens e do caso de estudo (Hamuda et al. 2016). Na maioria, todos os índices mostram boa adaptação em ambientes em ar livre, embora não possuam um bom desempenho quando

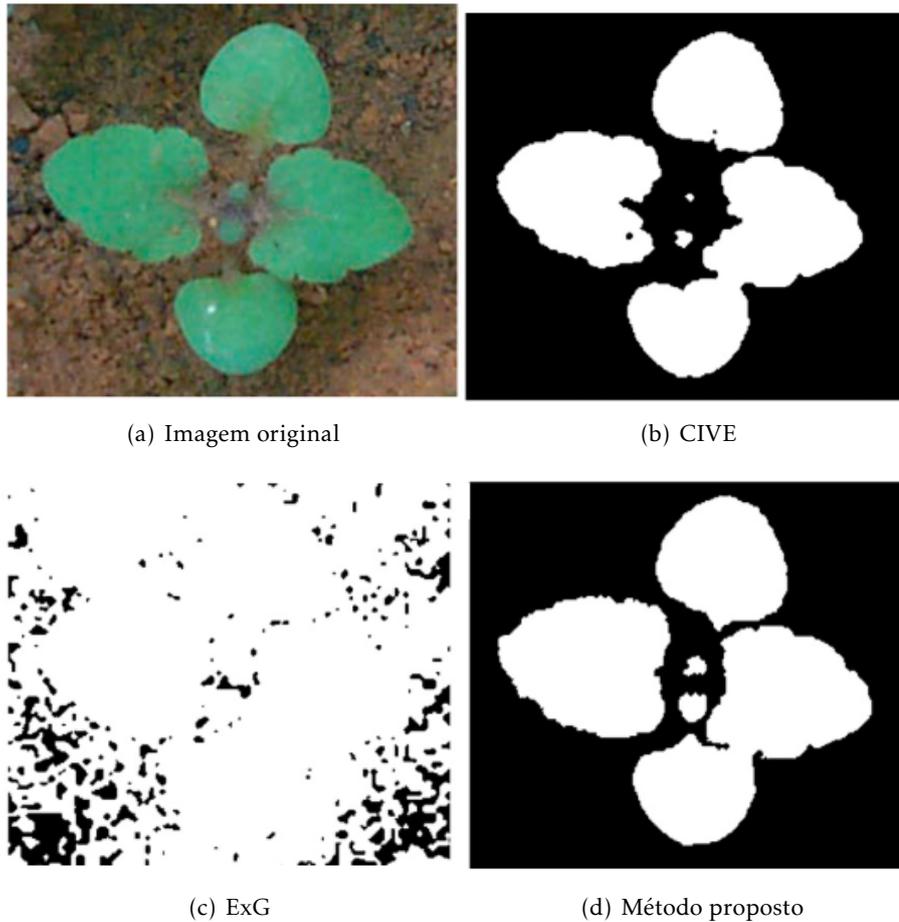


Figura 2.4: Comparação entre CIVE, ExG e o método proposto em (Zheng et al. 2009).

a iluminação é bastante forte ou fraca e falham na presença de sombras e zonas realçadas pela luz (Ye et al. 2015). A nível de tempo computacional, o COM1 e COM2 tem um aumento em relação aos restantes métodos, o que é de esperar visto que estes índices são uma combinação dos restantes. No entanto, estes métodos são fáceis de implementar, modificar e criar novas adaptações.

2.2.2 *Normalized Difference Vegetation Index*

A clorofila possui uma maior refletividade no início do espectro infravermelho-próximo do que no espectro visível (Secção 2.1.1.3). Logo o estudo do comportamento das plantas no espectro do infravermelho-próximo poderá ser vantajoso para a identificação das mesmas.

O *Normalized Difference Vegetation Index* (NDVI) é um índice de cor que permite identificar vegetação verde e medir a vitalidade da mesma. Esta parte do fato da clorofila refletir mais radiação no infravermelho-próximo do que no espectro do vermelho (Huete et al. 2002). É uma transformação espectral da banda do infravermelho e da banda do vermelho, que permite realçar as propriedades da vegetação, sendo a fórmula seguinte:

$$NDVI = \frac{\rho_{NIR} - \rho_{red}}{\rho_{NIR} + \rho_{red}} \quad (2.10)$$

As componentes ρ_{NIR} e ρ_{red} são respetivamente os fatores de refletância da banda do infravermelho-próximo e da banda do vermelho. Os valores do NDVI variam entre -1 a 1. No caso de um pixel possuir um grande valor na componente do infravermelho-próximo ρ_{NIR} e baixo valor na componente do vermelho ρ_{red} , significa que se trata de vegetação saudável pois a mesma absorve grande parte da radiação visível e reflete uma grande porção no infravermelho-próximo. No caso da vegetação não saudável é o oposto, tende a absorver mais luz visível e menos luz do infravermelho-próximo (Weier e Herring 2000).

O sistema MODIS (*Moderate Resolution Imaging Spectroradiometer*) capta imagens via satélite da superfície da Terra e utiliza o NDVI para construir mapas globais da vegetação (Figura 2.5). Os mapas são depois usados em várias aplicações, como classificação da cobertura de vegetação da Terra, desflorestação e estudo da variabilidade sazonal da vegetação global (Huete et al. 2002; MODIS). O NDVI reduz vários tipos de ruído como diferenças de iluminação, sombras, atenuação atmosférica e variações topográficas. Contudo, possui problemas de escalabilidade devido à saturação sobre a presença de grande biomassa (Huete et al. 2002).

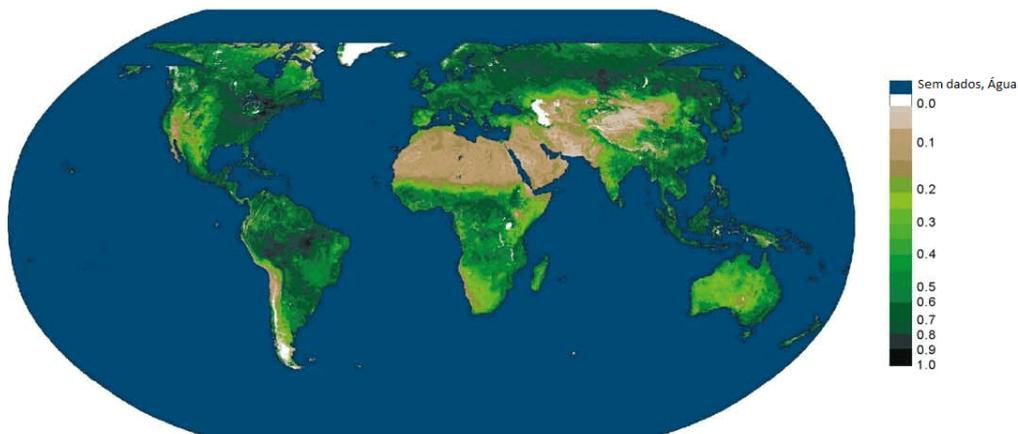


Figura 2.5: Exemplo de um mapa global composto pelo NDVI. Adaptado de (Huete et al. 2002)

2.2.3 Segmentação com *machine learning*

Métodos de segmentação com *machine learning* são os que possuem maior eficácia na deteção da vegetação, incluindo ambientes claros ou escuros. Como estes dependem da sua fase de treino, são métodos mais complexos que os índices de vegetação (Secção 2.2.1), possuindo um tempo computacional mais elevado (Hamuda et al. 2016).

Existem várias aplicações de métodos de aprendizagem para a segmentação de plantas, desde as redes neuronais, *fuzzy clustering* e árvores de decisão (Hamuda et al. 2016).

Em (Meyer et al. 2004) é aplicado *fuzzy clustering* para extrair a região de uma planta através de imagens onde são previamente aplicados os índices de vegetação ExG e ExR.

As árvores de decisão mostraram-se também como um método interessante a aplicar para a segmentação das plantas. Em (Guo et al. 2013) é apresentado um modelo de árvore de decisão para segmentar a planta do fundo da imagem através das componentes RGB da mesma. Este método mostrou-se eficaz pois não é necessário aplicar ajustamentos de *thresholds* para cada imagem.

Uma rede neuronal com um conjunto de treino suficientemente bom, isto é, que engloba todos os tipos de condições que possam acontecer a nível de iluminação, variação de cor, entre outros, consegue ser eficaz para lidar com estas condições noutras imagens (Smedt et al. 2011). Aplicações de redes neuronais encontram-se em (Zheng et al. 2009) onde é usada uma rede neuronal com *back propagation* que através das componentes RGB e HSI (*Hue saturation and intensity*) identifica se regiões da imagem são parte da planta ou não.

Em (Smedt et al. 2011) é apresentada também uma simples rede neuronal que tira partido do espectro de infravermelho-próximo para a segmentação da planta. As plantas refletem uma boa parte da luz pertencente à gama dos infravermelhos-próximo, enquanto o solo tende a absorver toda a luz nesse espectro. Logo a captação de imagens neste espectro pode-se mostrar vantajoso para uma boa segmentação das plantas (Smedt et al. 2011). Esta rede neuronal tem como entrada os valores RGB de um píxel da imagem captada no espectro do infravermelho-próximo. É uma rede simples, composta apenas por 2 camadas, *back propagation* para a aprendizagem e como saída tem a classificação do píxel como pertencente à planta ou ao fundo (Smedt et al. 2011).

Deep Learning tem vindo a surgir como novo método para a segmentação e identificação de objetos. Através de uma rede neuronal convolucional é possível obter bons resultados para segmentação e classificação (Zheng et al. 2015). O conjunto de treino torna-se essencial para a classificação correta sendo necessário um grande conjunto de imagens que engloba todas as condições possíveis. Em (Mohanty et al. 2016) encontra-se um exemplo da aplicação de uma rede neuronal convolucional para a deteção de doenças nas folhas de várias culturas. Esta rede foi treinada com um conjunto de treino de 54306 imagens de folhas de culturas saudáveis e doentes sobre várias condições. Este conjunto engloba 14 espécies e 26 doenças, sendo que a rede classifica 38 pares de espécie/doença.

2.2.4 Desafios

Apesar das várias soluções já apresentadas para a segmentação das plantas, ainda se encontram vários desafios por superar (Barbedo 2016). Como já foi referido, o fundo da imagem e a iluminação presente na altura da obtenção da imagem podem dificultar o processo de segmentação.

No caso do fundo, a solução mais fácil seria remover o mesmo manualmente, o que

não é vantajoso. No entanto em condições mais controladas como um laboratório, permitem facilitar a separação da planta, visto que o fundo pode ser por exemplo um quadro branco (Barbedo 2016).

A iluminação pode variar dependendo da sua intensidade e da posição da fonte de luz em relação ao objeto, o que pode afetar características da imagem. Conforme a iluminação, pode surgir zonas de retro-reflexão² nas plantas que podem dificultar o trabalho de segmentação, pois zonas da planta estarão muito claras em relação a outras devido a este fenómeno (Figura 2.6). Com isto ainda vêm o problema das sombras. Neste caso estes fenómenos podem ser minimizados regulando o ângulo de captura ou a posição da planta (Barbedo 2016).



Figura 2.6: Imagem de uma planta com retro-reflexão e transições de iluminação. (Barbedo 2016)

²reflexão da luz na direção de onde a mesma veio

CONCEITOS TEÓRICOS

3.1 Machine learning

Em aplicações tradicionais, é fornecido um programa sobre um conjunto de regras ao computador e este devolve uma resposta. No caso de *machine learning*, esta noção tradicional muda completamente. Em vez de fornecer um conjunto de regras para criar dados e respostas, é fornecido um conjunto de dados com as devidas respostas, e o computador devolve um programa que através dos dados, devolve a resposta (Samuel 1959). A ideia é então permitir que o computador retire conclusões através de dados fornecidos sem ser programado explicitamente.

Antes de apresentar com mais detalhe o que é *machine learning* e para facilitar a percepção do que será discutido, será realizada uma breve descrição do que são exemplos, características e classe do conjunto de dados. Exemplos ou observações são as várias instâncias presentes no conjunto de dados, sendo estes constituídos pelas suas características e classe. Características são os atributos associados aos exemplos do conjunto de dados. A classe é o valor ou categoria atribuída ao exemplo. Por exemplo, numa aplicação de processamento de imagem para identificar plantas, as observações podem ser pixels em que as suas características são por exemplo componentes de cor e a classe a indicação de o pixel pertencer ou não à planta.

Existem vários tipos de aprendizagem em *machine learning*, sendo os mais conhecidos a aprendizagem não-supervisionada e a supervisionada (Mohri 2012). A grande diferença entre estes está no conjunto de dados. No caso da não-supervisionada, o conjunto de dados recebido não vem classificado e na supervisionada o conjunto de dados vem classificado *à priori*. No cenário não-supervisionado, visto que o conjunto de dados é desconhecido, o objetivo é agrupar as várias observações através de medidas de semelhança de forma a descobrir padrões nos dados, para que assim sejam criados *clusters*. Visto que o trabalho

desenvolvido nesta dissertação usa uma aprendizagem supervisionada, é dedicada uma secção à mesma.

3.1.1 Aprendizagem supervisionada

Na aprendizagem supervisionada, o conjunto de dados vem devidamente classificado à priori, sendo estes constituídos pelas suas características X e classe C . O objetivo desta aprendizagem é encontrar uma função $g: X \Rightarrow C$ que consiga prever corretamente a classe C em observações X novas que não estão classificadas.

O conjunto de dados é separado em dois conjuntos, um para treinar o classificador e um para testar o classificador treinado. O classificador é construído na fase de treino através das observações que estão no conjunto de treino. Depois de treinado, este é testado com o conjunto de teste e os resultados das classes atribuídas às observações do conjunto de treino são avaliadas em relação à classe real.

O conjunto de treino deve ter observações diversificadas e reais ao problema que o classificador irá resolver. No entanto, cuidados devem ser feitos para evitar o classificador entrar em *overfitting* (Mohri 2012). *Overfitting* ocorre quando um classificador fica demasiado afinado a realizar as classificações do conjunto de treino e não é capaz de classificar corretamente novas observações que possam surgir e que não estejam presentes no conjunto de treino.

Uma das técnicas usadas para particionar o conjunto de dados é o *bootstrap* (Efron e Tibshirani 1997). Nesta técnica, é amostrado aleatoriamente n vezes com reposição o conjunto de dados composto por n observações. As observações repetidas na amostragem são retiradas, ficando em média, 63.2% dos exemplos originais no subconjunto amostrado. Este conjunto será utilizado para o treino e os restantes exemplos não incluídos neste conjunto, são utilizados como conjunto de teste.

Outra abordagem usada para particionar e validar o classificador é a validação cruzada a k grupos ou *k-fold cross-validation* (Hastie et al. 2009), que permite proteger o modelo contra *overfitting*. Este método consiste em dividir o conjunto de dados em k grupos exclusivos com igual número de observações. Sendo realizado k iterações, o algoritmo constrói um classificador utilizando $k - 1$ como treino e o restante como conjunto de teste. Em cada iteração, o subconjunto usado como conjunto de teste muda circularmente. No fim, cada um dos k grupos foi usado uma vez como conjunto de teste. O classificador final será originado do treino de todos os exemplos, sendo o seu erro a média dos erros de cada iteração, apresentando uma classificação pessimista, visto o classificador final ser construído com todo o conjunto de dados mas foi sendo avaliado com base em $\frac{k-1}{k}$ dos dados disponíveis. Em princípio, este classificador final terá um erro inferior aos restantes, visto que foi originado com mais dados.

Por fim, pode-se também recorrer à validação *Holdout*, por ser mais rápida. Esta tem como base a divisão do conjunto de dados em dois conjuntos, um para treino e outro para teste. O modelo é treinado unicamente com o conjunto de treino, e a avaliação do

mesmo é realizado através do conjunto de testes. O modelo resultante é baseado apenas numa porção dos dados disponíveis, sendo este apenas recomendado para um conjunto de dados de grande dimensão.

Existem vários algoritmos que são usados em aprendizagem supervisionada. Em seguida são destacados dois algoritmos: árvores de decisão (Breiman et al. 1984) e *random forests* (Breiman 2001; Ho 1995; Ho 1998).

3.1.1.1 Árvores de decisão

Árvores de decisão, como o nome indica, possui uma estrutura em árvore para classificar observações. Esta estrutura é constituída por nós, ramos e folhas. Cada nó corresponde ao teste de uma característica, sendo os ramos as possíveis respostas e as folhas os nós terminais, onde é atribuído a classe à observação. As árvores começam com um nó topo que se divide em vários ramos, ligando a nós internos. Estes nós consequentemente possuem mais ramos que ligam a outros nós até surgir os nós terminais, folhas, classificando a observação.

É um método rápido e suporta um conjunto de dados de grande dimensão e tem a vantagem de ser facilmente compreendido esquematicamente, como se pode observar no exemplo da figura 3.1.

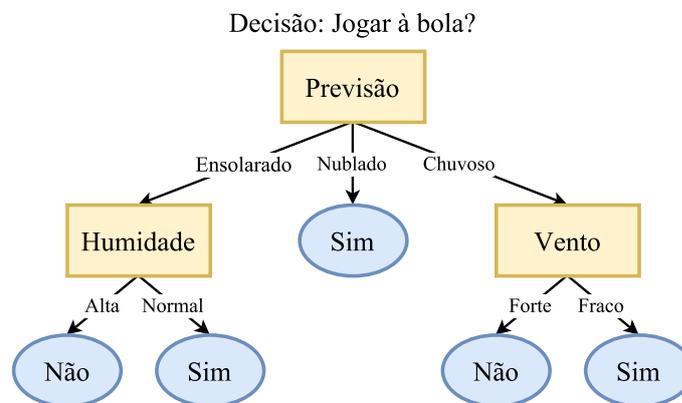


Figura 3.1: Exemplo de uma árvore de decisão.

3.1.1.2 Random Forest

Novamente como o nome indica, *Random forest* é constituído por um conjunto de árvores de decisão, em que cada árvore usa um subconjunto das características que descrevem as observações. No fim, cada árvore possui uma classificação para uma observação e a decisão final é realizada por votação. *Random forest* é um método de *ensemble learning*, que parte da filosofia de que um grupo de classificadores simples podem construir um classificador mais forte (Rokach 2010).

Cada árvore é treinada com um subconjunto amostrado por *bootstrap*. Estas árvores não usam individualmente todas as características presentes no conjunto de treino,

em vez, cada árvore seleciona ou aleatoriamente ou por *bootstrap* as características do conjunto de treino que vão usar para a sua decisão. Por fim, cada árvore classifica as observações através das características selecionadas e a classificação final da *random forest* é decidida por votação de todas as árvores.

Este algoritmo possui a vantagem de obter valores de precisão elevados, com a desvantagem do aumento do tempo de treino em comparação às árvores de decisão. Em relação à fácil interpretação das árvores de decisão, as *random forest* tornam-se mais complicadas de interpretar devido a estas possuírem um grande conjunto de pequenas árvores. No entanto, as *random forests* possuem também como vantagem a correção do hábito das árvores de decisão entrarem em *overfitting* com o seu conjunto de treino (Hastie et al. 2009).

3.1.2 Métricas de avaliação

Para avaliar os resultados obtidos pelo classificador com o conjunto de teste, são calculadas métricas que permitem avaliar a performance do classificador. Nesta secção são apresentadas várias métricas de avaliação que serão usadas nesta dissertação. Antes de passar à enumeração das métricas de avaliação, é importante distinguir os quatro tipos de classificações que um classificador pode retornar:

- **Verdadeiro Positivo (VP):** observação classificada pelo classificador como positiva, sendo a classificação correta;
- **Verdadeiro Negativo (VN):** observação classificada pelo classificador como negativa, sendo a classificação correta;
- **Falso Positivo (FP):** observação classificada pelo classificador como positiva, sendo a classificação incorreta;
- **Falso Negativo (FN):** observação classificada pelo classificador como negativa, sendo a classificação incorreta;

Por exemplo, no caso desta dissertação a situação positiva será a classificação como planta (1) e a situação negativa a classificação como não-planta (0). Para visualização destas observações, é normalmente utilizada uma matriz de confusão, semelhante à apresentada na tabela 3.1. O número 1 representa a classe positiva e o número 0 a classe negativa.

Em relação às métricas de avaliação podemos ter:

- **Precisão:** esta é a medida de avaliação mais intuitiva que indica a probabilidade de o classificador classificar corretamente. É computada pela proporção das observações corretamente classificadas e o total de observações classificadas.

$$Precisão = \frac{VP + VN}{VP + FP + FN + VN} \quad (3.1)$$

Tabela 3.1: Representação das classificações possíveis numa matriz de confusão.

Classe estimada pelo classificador	Classe real	
	1	0
1	VP	FP
0	FN	VN

- **Sensibilidade:** mede a proporção das observações positivas que estão identificadas corretamente, ou seja, indica a probabilidade de uma observação positiva ser classificada corretamente, também denominado como taxa de verdadeiros positivos.

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (3.2)$$

- **Especificidade:** mede a proporção das observações negativas que estão identificadas corretamente, ou seja, indica a probabilidade de uma observação negativa ser classificada corretamente, também denominado como taxa de verdadeiros negativos.

$$\text{Especificidade} = \frac{VN}{VN + FP} \quad (3.3)$$

- **Valor Preditivo Positivo (VPP):** indica a probabilidade de um resultado positivo ser efetivamente positivo.

$$VPP = \frac{VP}{VP + FP} \quad (3.4)$$

- **Valor Preditivo Negativo (VPN):** é o oposto do VPP, ou seja, indica a probabilidade de um resultado negativo ser efetivamente negativo.

$$VPN = \frac{VN}{VN + FN} \quad (3.5)$$

A sensibilidade indica a evitação de falsos negativos, da mesma maneira que a especificidade indica a evitação de falsos positivos. Normalmente, existe um balanço entre estas duas medidas, se queremos aumentar a sensibilidade, a especificidade diminui e vice-versa.

Idealmente, queremos que estas métricas referidas acima tenham os valores o mais alto possível, pois quanto mais alto estas são, significa que existe uma baixa presença de VN ou FN. No entanto, também se usa mais duas métricas, que quantificam a presença de falsos negativos e falsos positivos, estando ligadas à sensibilidade e especificidade respetivamente:

- **Taxa de Falsos Negativos (TFN):** indica a probabilidade de uma observação positiva ser classificada como negativa. Por exemplo, a percentagem de pacientes com a doença *A* mas foram diagnosticados sem a mesma. Corresponde ao inverso da sensibilidade.

$$TFN = 1 - \text{Sensibilidade} = \frac{FN}{VP + FN} \quad (3.6)$$

- **Taxa de Falsos Positivos (TFP):** indica a probabilidade de uma observação negativa ser classificada como positiva. Por exemplo, a percentagem de pacientes sem a doença *A* mas foram diagnosticados com a mesma. Corresponde ao inverso da especificidade.

$$TFP = 1 - \text{Especificidade} = \frac{FP}{VN + FP} \quad (3.7)$$

Visto que queremos que o classificador tenha o maior número de classificações certas, idealmente, a TFP e TFN devem ser o menor possível.

3.2 Speeded-Up Robust Features

Em processamento digital de imagem, o conceito de deteção e extração de características refere-se a métodos cujo objetivo é a extração e avaliação de informação da imagem de modo a determinar se existe alguma característica presente na mesma. A identificação de características é a base de muitos algoritmos e aplicações em processamento digital de imagem, como o registo da imagem, a reconstrução da imagem, a deteção, reconhecimento e seguimento de objetos, entre outros. Estas têm a vantagem de representar conteúdos da imagem para deteção e classificação sem ser necessário recorrer à segmentação da imagem.

As características locais podem ser subconjuntos da imagem, normalmente zonas isoladas, curvas ou regiões conectadas. Uma característica pode ser definida como uma zona de interesse da imagem. Existem vários tipos de características locais: bordas, cantos e regiões de interesse (*blobs*). As bordas são pontos onde existe uma fronteira entre duas regiões da imagem, podendo possuir qualquer forma. Cantos, por sua vez, são pontos específicos das bordas. Regiões de interesse (*blobs*) são zonas que possuem propriedades aproximadamente constantes (por exemplo brilho ou cor), mas diferem da sua vizinhança.

Visto que os métodos de deteção de características locais têm o objetivo de detetar as mesmas características em várias imagens, estes têm que exibir repetibilidade. Isto é, detetar características distintivas e localizáveis em várias imagens. Dado duas ou mais imagens do mesmo cenário, é desejável que a característica seja detetada em todas as imagens, sendo robusta ao ruído e a alterações das condições de visualização.

Para além dos algoritmos de deteção de características locais identificarem certas características nas imagens, é necessário conseguir extrair e representar estas características

de forma invariante à imagem de onde foram detetadas. Alguns métodos de detecção de características incluem um descritor, que é composto por um vetor de características que codifica informação relevante às características de forma a conseguir diferenciar umas das outras, como uma "impressão digital", sendo esta informação invariante sobre transformações na imagem, devendo ser possível encontrar a mesma característica em várias imagens diferentes.

Em suma, o detetor de características é um método que extrai da imagem as localizações das características detetadas, mas não indica nenhuma informação específica acerca das características detetadas. O descritor de características complementa o detetor, extraíndo um vetor de características invariante das imagens em que são detetadas. É com as características extraídas pelo descritor que é possível comparar as características em várias imagens e conseguir por exemplo realizar a reconstrução da imagem ou seguimento de objetos. Um exemplo deste tipo de detetor e descritor é o algoritmo *Speeded-Up Robust Features* (SURF).

O algoritmo SURF (Bay et al. 2008) possui um algoritmo de detecção como um descritor de características SURF. Este algoritmo é invariante em escala e rotação das imagens, podendo ser usado para tarefas de reconhecimento de objetos, registo de imagens e classificação. O SURF foi desenvolvido através da simplificação e aproximação de métodos já existentes, nomeadamente a matriz Hessiana para o detetor e o algoritmo *Scale-invariant feature transform* para o descritor. O algoritmo SURF possui três passos principais: a detecção dos pontos de interesse, descrição da vizinhança local e correspondência (*matching*).

O primeiro passo é a identificação dos pontos de interesse, sendo neste caso regiões da imagem que possuem propriedades aproximadamente constantes (*blobs*). Depois, é extraído um descritor para cada característica contendo informação relativa à vizinhança desse ponto, sendo representado num vetor de características SURF. Por fim, a fase de correspondência consiste na comparação de vetores de características SURF de várias imagens do mesmo cenário, identificando as características presentes em todas as imagens. Com este método, é possível realizar o seguimento de objetos e até a recuperação de imagens através da estimação da transformação geométrica (Duarte 2015; Mora et al. 2013).

3.3 Transformada circular de Hough

A transformada circular de Hough (TCH) (Duda e Hart 1972; Illingworth e Kittler 1987) é uma técnica de extração de características para a detecção de círculos em imagens. É uma adaptação da transformada de Hough (Ballard 1981), que tem como base a transformação de uma imagem digital para o espaço de parâmetros de Hough.

Um círculo é descrito em duas dimensões pela equação:

$$(x - a)^2 + (y - b)^2 = r^2 \quad (3.8)$$

Sendo (a,b) as coordenadas do centro do círculo, r o raio e (x,y) as coordenadas de duas dimensões. O espaço de Hough na transformada circular de Hough deverá ser representado pelos campos a , b e r . No caso do raio ser fixo, o espaço é reduzido a duas dimensões. A essência do método é que para cada pixel pertencente ao contorno do círculo a detetar (pixeis candidatos), é definido um círculo com raio fixo à sua volta. O ponto de interceção de todos os círculos será o ponto central do círculo formado pelos pixeis candidatos, tendo assim detetado o círculo com um raio conhecido à *priori*. A deteção do ponto central funciona por votação, ou seja é usado um vetor de acumuladores para guardar a votação dos vários pontos dos círculos definidos em cada candidato e no final escolhido o ponto mais votado. No caso do raio ser conhecido e fixo, este vetor é constituído por duas dimensões, (a,b) , e uma matriz de acumuladores é calculada. No caso do raio não ser conhecido ou estar contido num intervalo, este vetor possui três dimensões (a,b,r) e teremos uma matriz tridimensional de acumuladores.

Resumidamente, o algoritmo da transformada circular de Hough é constituído pelos seguintes passos:

1. **Calcular o vetor de acumuladores:** os pixeis pertencentes ao objeto são atribuídos como pixeis candidatos e são estes que colocam votações no vetor de acumuladores. Cada pixel candidato realiza uma votação num círculo com um raio fixo à sua volta, tal como representado na figura 3.2(a). No caso do raio estar contido num intervalo, são realizados os mesmos passos, mas para vários círculos com diferentes raios.
2. **Estimação do centro:** os votos dos pixeis candidatos tendem a acumular num ponto do vetor de acumuladores correspondente à zona central do círculo, como se pode verificar no exemplo da figura 3.2(b). O centro é estimado pela deteção dos máximos locais no vetor de acumuladores. A deteção de múltiplos círculos funciona da mesma forma, visto que os máximos locais do vetor de acumuladores corresponderão ao centro de cada círculo.
3. **Estimação do raio:** se o vetor de acumuladores for usado para mais do que um raio, a sua determinação é realizada num passo separado. Aqui pode ser usado, por exemplo, o algoritmo *Two Stage* ou *Phase Coding*. No caso do *Two Stage*, o raio é estimado explicitamente através do centro dos círculos juntamente com histogramas radiais. No caso do método *Phase Coding*, são usados valores complexos no vetor de acumuladores com informação do possível centro do círculo e o raio associado (Atherton e Kerbyson 1999; Yuen et al. 1990)

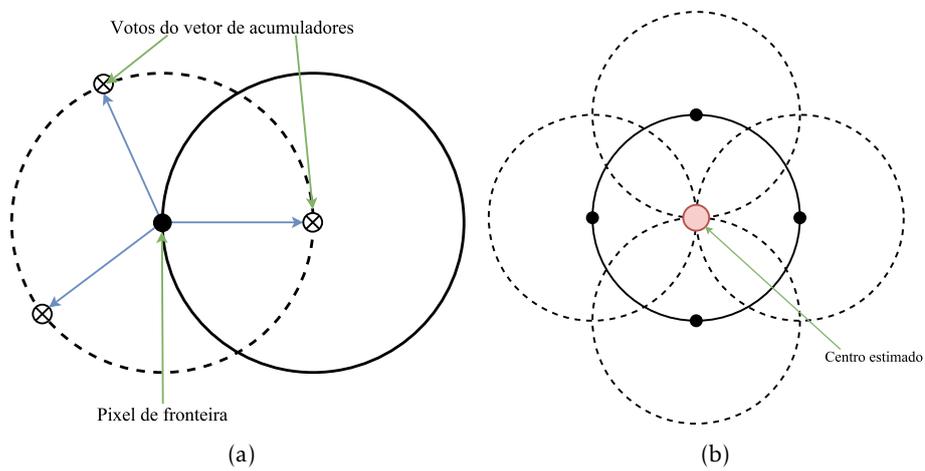


Figura 3.2: Detecção do círculo através da transformada circular de Hough. (a) Plano circular de hough num pixel fronteira. (b) Interseção dos círculos centrados nos pixels de fronteira permite determinar o centro do círculo.

AQUISIÇÃO DE IMAGEM

Ao longo deste capítulo é descrita a primeira etapa desta dissertação, i.e. a aquisição de imagens de plantas *in-vitro*. Inicialmente serão descritos os materiais utilizados na obtenção das imagens, seguindo-se depois a descrição das sessões e tipos de fotografias adquiridas.

Esta etapa foi realizada com o apoio da empresa *Boereboom Invitro Portugal* na disponibilização do laboratório e de culturas de plantas *in-vitro* para aquisição de imagens da evolução das mesmas. *Boereboom invitro Portugal* é uma empresa situada no *Madan Parque* e especializa-se na produção de plantas geneticamente iguais através do método de propagação de plantas *in-vitro*. A propagação *in-vitro* é realizada em laboratório sobre condições estéreis, para que as culturas não sejam invadidas de pragas e doenças ¹.

4.1 Materiais

As plantas monitorizadas ao longo do período da dissertação possuem folhas com uma mistura de regiões verdes e brancas, introduzindo um desafio para a segmentação das mesmas. Todas as plantas monitorizadas estavam com condições de cultura iguais. A aquisição de imagem destas culturas foi realizada numa câmara de fluxo de ar, de modo a manter o ambiente o mais estéril possível. Na figura 4.1 é apresentada a câmara de fluxo de ar com o equipamento fotográfico já preparado, juntamente com os recipientes de plantas *in-vitro*.

As imagens foram captadas no espectro visível e no infravermelho-próximo. Foi usado uma *Nikon D600* DSLR para a captura do espectro visível e uma câmara compacta *Canon*

¹Mais informação acerca da *Boereboom Invitro Portugal* pode ser encontrada em <http://invitro.boereboom.nl/>



Figura 4.1: Câmara de fluxo de ar de onde foi realizado a aquisição de imagem.

Powershot G3 modificada para a captura do espectro infravermelho-próximo. A modificação consistiu na remoção do filtro bloqueante do espectro infravermelho-próximo e colocação de um filtro passa-banda do mesmo espectro. O uso de duas máquinas para a aquisição de imagem de cada espectro causou problemas no processamento da imagem, nomeadamente a introdução de erros no alinhamento das imagens dos dois espectros, que poderão não ser corrigíveis. A opção ideal seria usar apenas uma máquina fotográfica e realizar a aquisição simultânea das imagens em cada espectro. No entanto, o custo de uma máquina que separa os dois espectros e adquire imagens de cada é elevado, o que resultou no descarte desta opção mais fiável.

Para ajudar no processamento e colocação dos recipientes, foi usada uma folha com guias de calibração como fundo de imagem (Figura 4.2). Esta folha possui um círculo central para a colocação dos recipientes, 4 círculos de alinhamento nos cantos, 4 réguas para calibração de dimensão e blocos de escala de cinza e cor para correção de iluminação. Nesta dissertação, apenas considerámos as guias de alinhamento na metodologia proposta. Em cada recipiente foi desenhado uma linha para alinhar com a linha presente no círculo central.

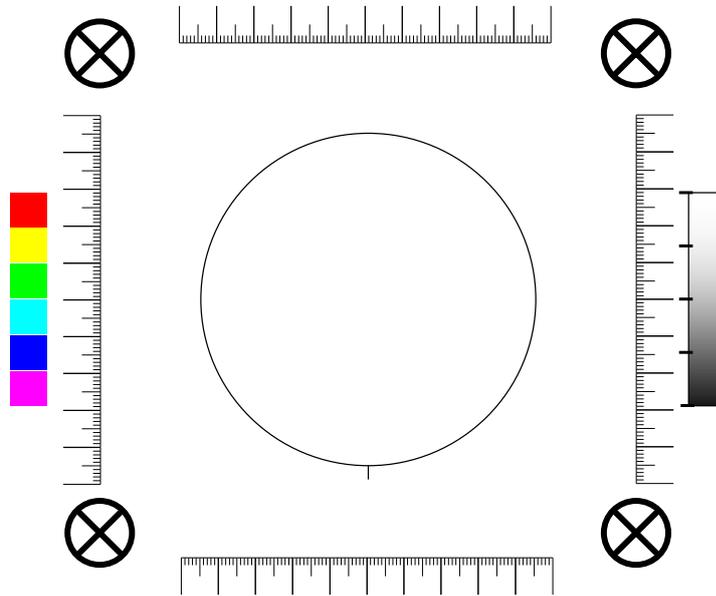


Figura 4.2: Guias de calibração usadas na aquisição de imagem.

4.2 Aquisição

Foram adquiridas imagens de 10 recipientes, devidamente identificadas. As sessões foram realizadas semanalmente durante o mês de Junho e Julho de 2016, sendo que em Setembro também foi realizada uma sessão extra para adquirir o resultado final da propagação *in-vitro*. No total gerou-se 8 sessões para esta variedade, sendo que as primeiras 7 foram realizadas aproximadamente com um espaço de uma semana entre si.

Foram adquiridas em cada sessão imagens dos recipientes com o perfil superior (vista de cima) e inferior (vista de baixo) dos mesmos. O perfil superior foi adquirido no espectro visível e infravermelho-próximo enquanto o perfil inferior foi adquirido apenas no espectro visível à exceção da primeira sessão onde foram obtidas apenas imagens no espectro visível, isto porque a modificação da câmara ainda não estava finalizada. As datas, sessões respetivas e espectros adquiridos estão indicados na tabela 4.1

O controlo do equipamento fotográfico foi realizado por aplicações de computador que comunicavam com as máquinas via USB. A *Nikon D600* foi controlada através da aplicação *digiCamControl*² e a *Canon Powershot G3* através da aplicação *Remote Capture* da *Canon*³. Estas aplicações permitiram configurar os vários parâmetros de aquisição de imagem de cada máquina fotográfica sem necessitar intervenção manual na máquina. Os parâmetros configurados através destas aplicações foram a distância focal, abertura, tempo de exposição, balanceamento de brancos, ISO e formato da imagem. Os seus valores

²<http://digiCamControl.com/>

³http://cpn.canon-europe.com/content/education/infobank/image_download/remote_capture.do

Tabela 4.1: Datas das várias sessões realizadas de aquisição de imagem e espectros captados.

Sessão	Semana	Data	Espectro captado	
			Visível	Infravermelho-próximo
1	0	15/6/2016	×	
2	1	22/6/2016	×	×
3	2	29/6/2016	×	×
4	3	6/7/2016	×	×
5	4	14/7/2016	×	×
6	5	20/7/2016	×	×
7	6	27/7/2016	×	×
8	12	6/9/2016	×	×

estão indicados na tabela 4.2.

A ordem de aquisição de imagem dos recipientes nos vários espectros e perfis foi realizada por tipo de aquisição, de forma a poupar tempo na montagem e desmontagem do equipamento. Começou-se pela aquisição de imagens com o perfil superior dos recipientes no espectro visível, seguindo depois para o perfil inferior e terminando com o perfil superior no espectro do infravermelho-próximo. Este foi o último pois era necessário mudar de máquina fotográfica. As configurações das máquinas fotográficas e do ambiente de aquisição estão indicadas na tabela 4.2.

Do perfil superior no espectro visível, retiram-se 4 imagens por cada recipiente: 2 com o recipiente fechado com a tampa numerada com e sem flash; e 2 com o recipiente aberto com e sem flash. As duas primeiras servem apenas para identificar o recipiente nas imagens onde o mesmo está aberto. No perfil inferior e no perfil superior do espectro infravermelho-próximo adquiriu-se apenas uma imagem por recipiente, pela mesma ordem que no perfil superior. Conjuntos de imagens retiradas de um recipiente de plantas *in-vitro* da segunda sessão são apresentados na figura 4.3, quinta sessão na figura 4.4 e última sessão na figura 4.5.

No fim da aquisição, as imagens foram exportadas do formato *Nikon raw (NEF)* em que foram adquiridas para o formato *JPG*, para poderem ser processadas no método desenvolvido.

4.3 Desafios

Como foi referido anteriormente, o uso de duas câmaras fotográficas para a aquisição de imagem irá trazer desafios no alinhamento entre as imagens dos vários perfis. Mas o maior desafio do alinhamento das plantas vem da própria planta. Como primeiro são obtidas as imagens do perfil superior no espectro visível para todos os recipientes, depois feita a aquisição de imagens no perfil inferior e por fim fotografado o perfil superior no infravermelho-próximo, as folhas e o caule da plantas estarão ligeiramente deslocadas

Tabela 4.2: Configurações de aquisição de imagem usadas para cada perfil.

	Visível		Infravermelho-próximo
	Perfil superior	Perfil inferior	Perfil superior
Máquina Fotográfica	Nikon D600		Canon Powershot G3
Lente	NIKKOR AF-S DX 18-70 mm		Canon 35-140 mm
Distância Focal	70mm		14 mm
Abertura	F/14		F/8
ISO	100		50
Filtro	Nenhum		Hoya R72 <i>Infrared</i>
Formato	<i>nef</i>		<i>crw</i>
Resolução	6016x4016		2272x1704
Tempo de exposição	1/8 s	2 s	2 s
White Balance	Incadescência	Luz do dia	<i>Black and White</i>
Flash	Circular <i>on/off</i>	Nenhum	Nenhum
Luz da câmara de fluxo	Ligada	Desligada	Ligada

relativamente às posições em que estas estavam aquando a aquisição do perfil superior no espectro visível. Isto trouxe problemas no alinhamento das imagens, visto que as plantas não estavam efetivamente nas mesmas posições nas imagens adquiridas nos dois espectros, não sendo possível alinhar completamente estas imagens.

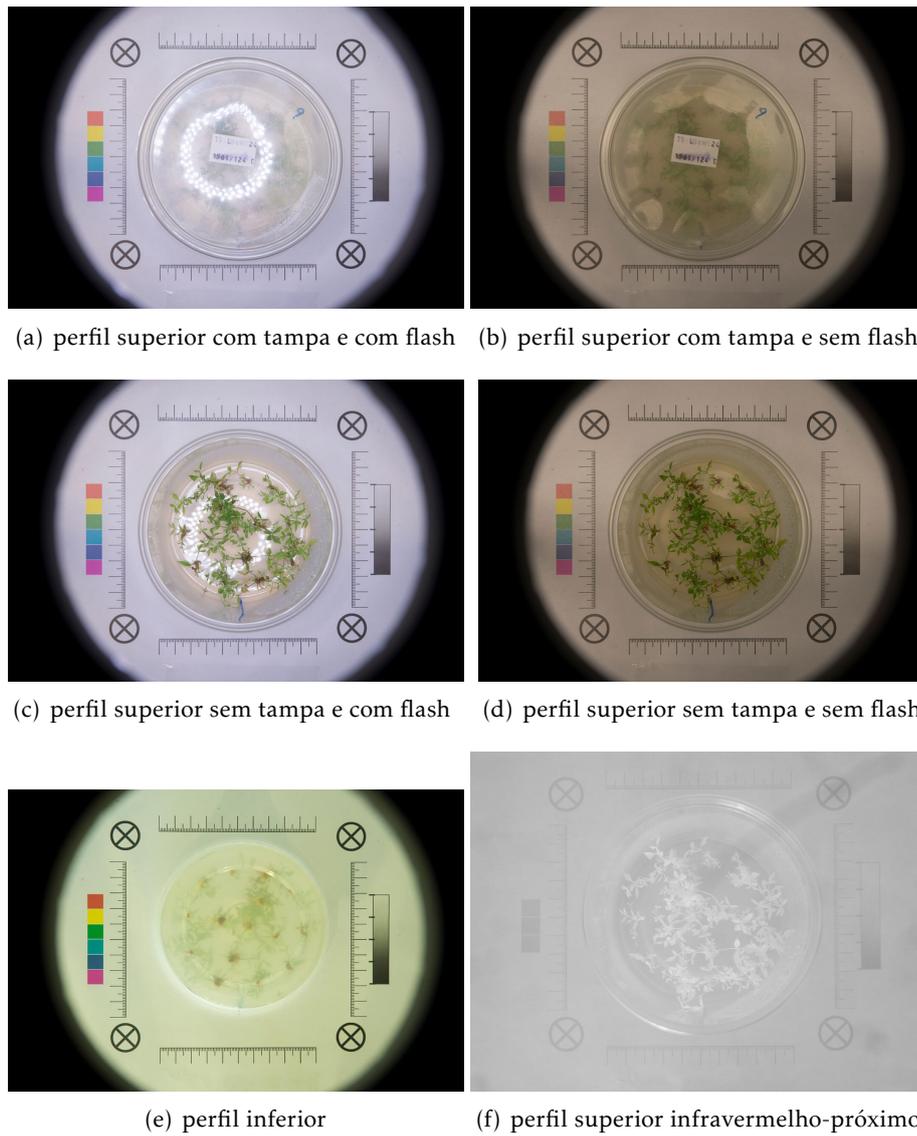


Figura 4.3: Exemplo de imagens adquiridas para um recipiente de plantas *in-vitro* na 2ª sessão.

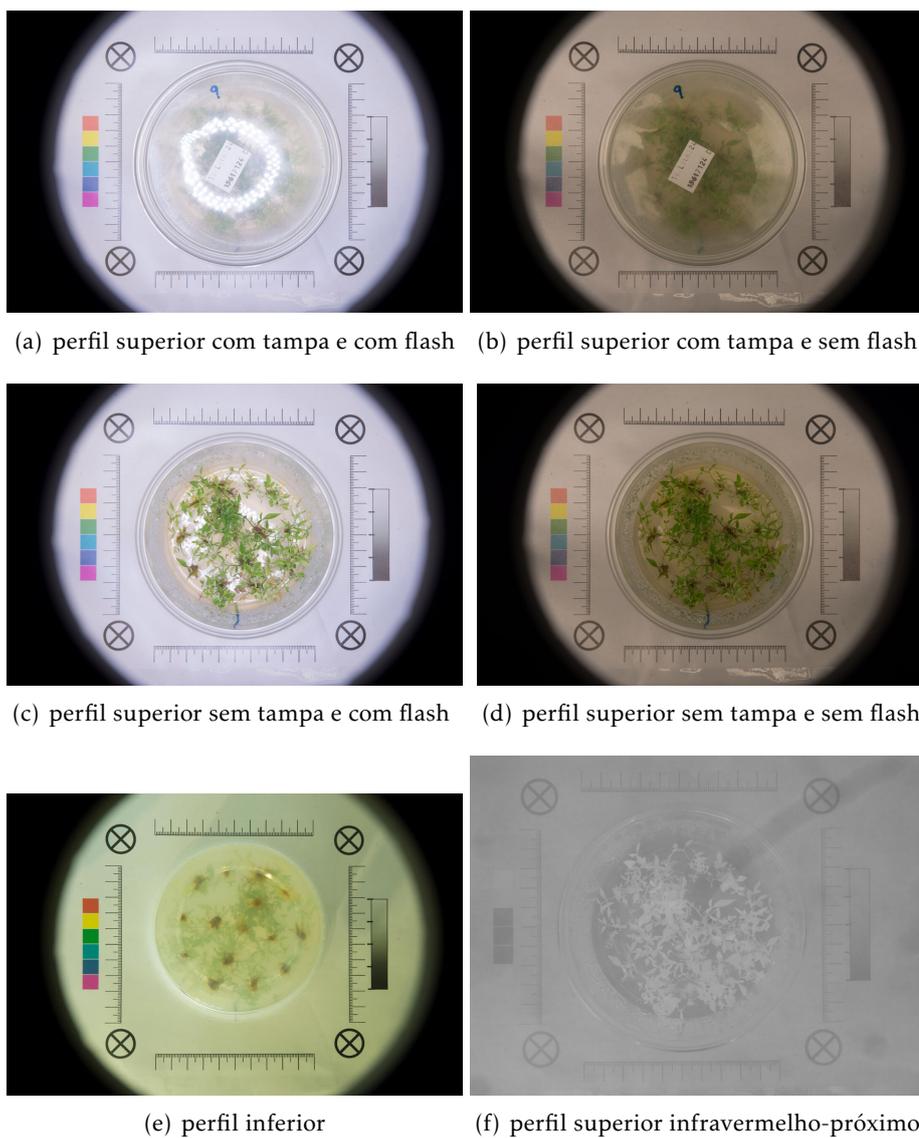


Figura 4.4: Exemplo de imagens adquiridas para um recipiente de plantas *in-vitro* na 5ª sessão.

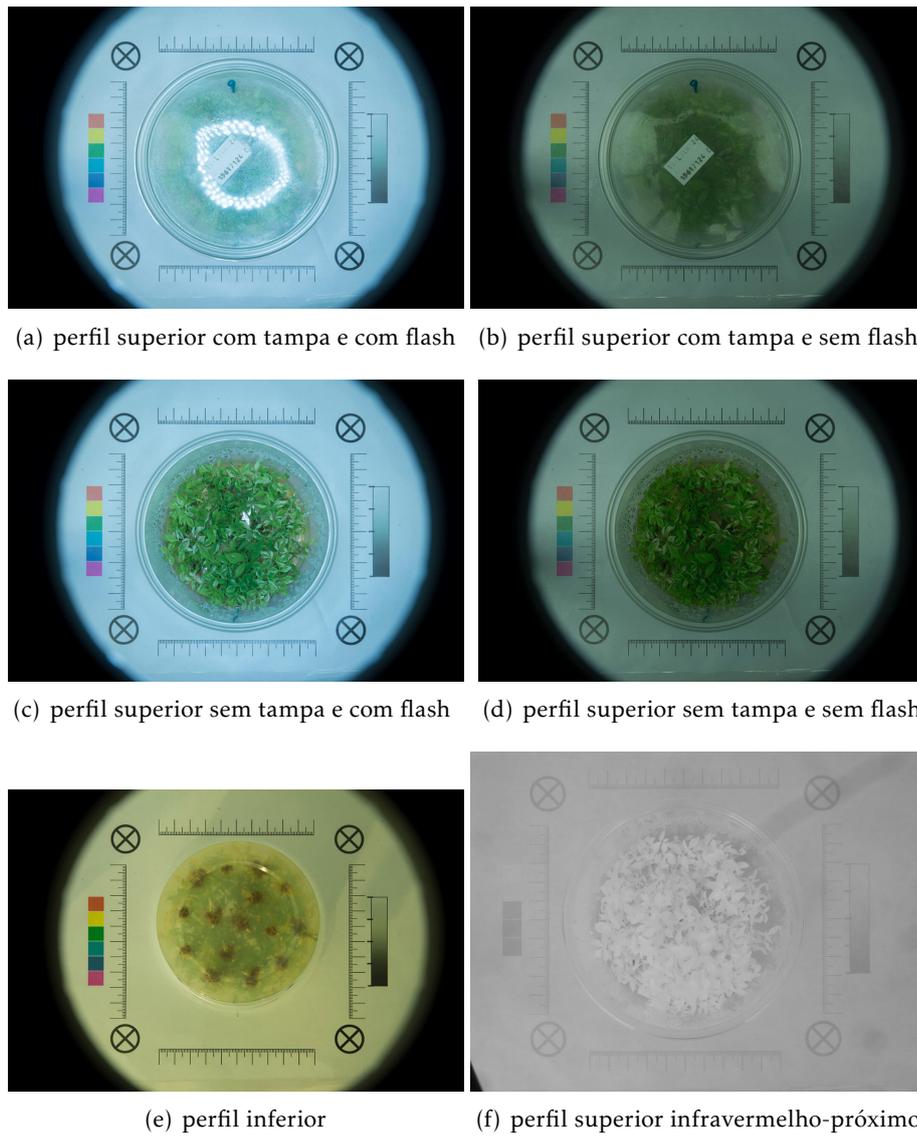


Figura 4.5: Exemplo de imagens adquiridas para um recipiente de plantas *in-vitro* na última sessão.

TRABALHO DESENVOLVIDO

Sendo o objetivo desta dissertação a monitorização do crescimento de plantas, pretendeu-se obter informação da evolução das mesmas, nomeadamente sua área e NDVI médio, através das imagens adquiridas no espectro visível e infravermelho-próximo. Para isso foi necessário processar estas imagens para cada recipiente de modo a extrair estes dados de monitorização. Este processamento dividiu-se em três fases principais: pré-processamento, segmentação e extração de informação.

Durante a aquisição de imagem, vários perfis foram captados: no espectro visível o perfil superior e o perfil inferior e no espectro infravermelho-próximo o perfil superior. No trabalho desenvolvido, o perfil inferior não foi estudado, sendo unicamente utilizadas imagens captadas no perfil superior em ambos espectros. Por isso, para simplicidade, visto que no restante documento serão tratadas apenas as imagens do perfil superior de ambos os espectros, quando forem referidas imagens do espectro visível ou do espectro infravermelho-próximo deverão ser consideradas as imagens do perfil superior. Das imagens do espectro visível captadas no perfil superior, foram utilizadas as imagens adquiridas sem flash, pois as outras possuíam demasiada reflexão nas folhas.

O pré-processamento das imagens é essencial para corrigir e prepará-las para o algoritmo de segmentação. Neste caso, como foram usadas máquinas fotográficas diferentes para cada espectro, é importante implementar métodos que permitam alinhar as imagens adquiridas ao longo do tempo de um recipiente *in-vitro*, tanto as do espectro visível, como as do espectro infravermelho-próximo. O balanceamento de brancos também foi necessário, para colocar todas as imagens com a mesma distribuição de cor. Por fim, como as plantas encontram-se dentro do recipiente, a seleção da região de interesse foi fundamental para simplificar a segmentação, para que os pixels exteriores fiquem marcados sem recorrer a mais processamento. A segmentação das imagens identifica os pixels pertencentes e não pertencentes à planta, sendo este ponto o mais crítico no trabalho, pois para

uma correta estimativa da área e NDVI da planta obviamente é necessário conseguir detectar corretamente todos os pixels. Neste passo foi usada uma *random forest* previamente treinada para classificar os pixels da zona de interesse como planta ou não-planta através de características extraídas das imagens pré-processadas.

Ao longo deste capítulo é descrito o trabalho desenvolvido na dissertação para a monitorização das plantas *in-vitro*, começando por explicar todos os métodos de pré-processamento realizados às imagens, seguindo-se a segmentação das imagens processadas e extração da área e NDVI médio da zona classificada como planta. Todo este trabalho foi desenvolvido em *Matlab*¹, tendo sido criada uma aplicação *GUIDE*, para testar os métodos desenvolvidos em todas as imagens adquiridas de um recipiente. A escolha desta plataforma deveu-se à simplicidade de representar as imagens em matrizes e também à biblioteca de processamento de imagem, *Image Processing Toolbox*², que possui vários métodos de processamento de imagem, facilitando assim o próprio desenvolvimento desta dissertação. Um diagrama geral do método desenvolvido é apresentado na figura 5.1.

Todo o trabalho desenvolvido envolve o processamento de todas as imagens das sessões captadas referentes a um recipiente que é escolhido à *priori* na aplicação, depois é realizado cada passo do pré-processamento a estas imagens, sendo por último realizada a segmentação.

5.1 Pré-processamento de imagem

Como já foi referido, o pré-processamento é a fase inicial do processamento digital de imagem que normaliza as imagens para o processo de segmentação/classificação. Para o passo de segmentação, a zona de interesse corresponde ao interior do recipiente. Por isso, de forma a facilitar a segmentação, é conveniente que a zona exterior seja o menor possível. Pelo exposto, foram desenvolvidos e testados os seguintes métodos para pré-processar as imagens de todas as sessões de um recipiente:

1. Região de interesse: correção do ângulo de orientação da folha e recorte do recipiente *in-vitro* nas imagens do espectro visível e infravermelho-próximo;
2. Ajuste da escala das imagens do espectro visível e do espectro infravermelho-próximo;
3. Registo das imagens do espectro visível e infravermelho-próximo;
4. Balanceamento de brancos nas imagens do espectro visível;
5. Isolamento da zona de interesse (interior do recipiente) em todas as imagens;

Em seguida, são descritos nas próximas secções os algoritmos de pré-processamento.

¹<https://www.mathworks.com/products/matlab.html>

²<https://www.mathworks.com/help/images/index.html>

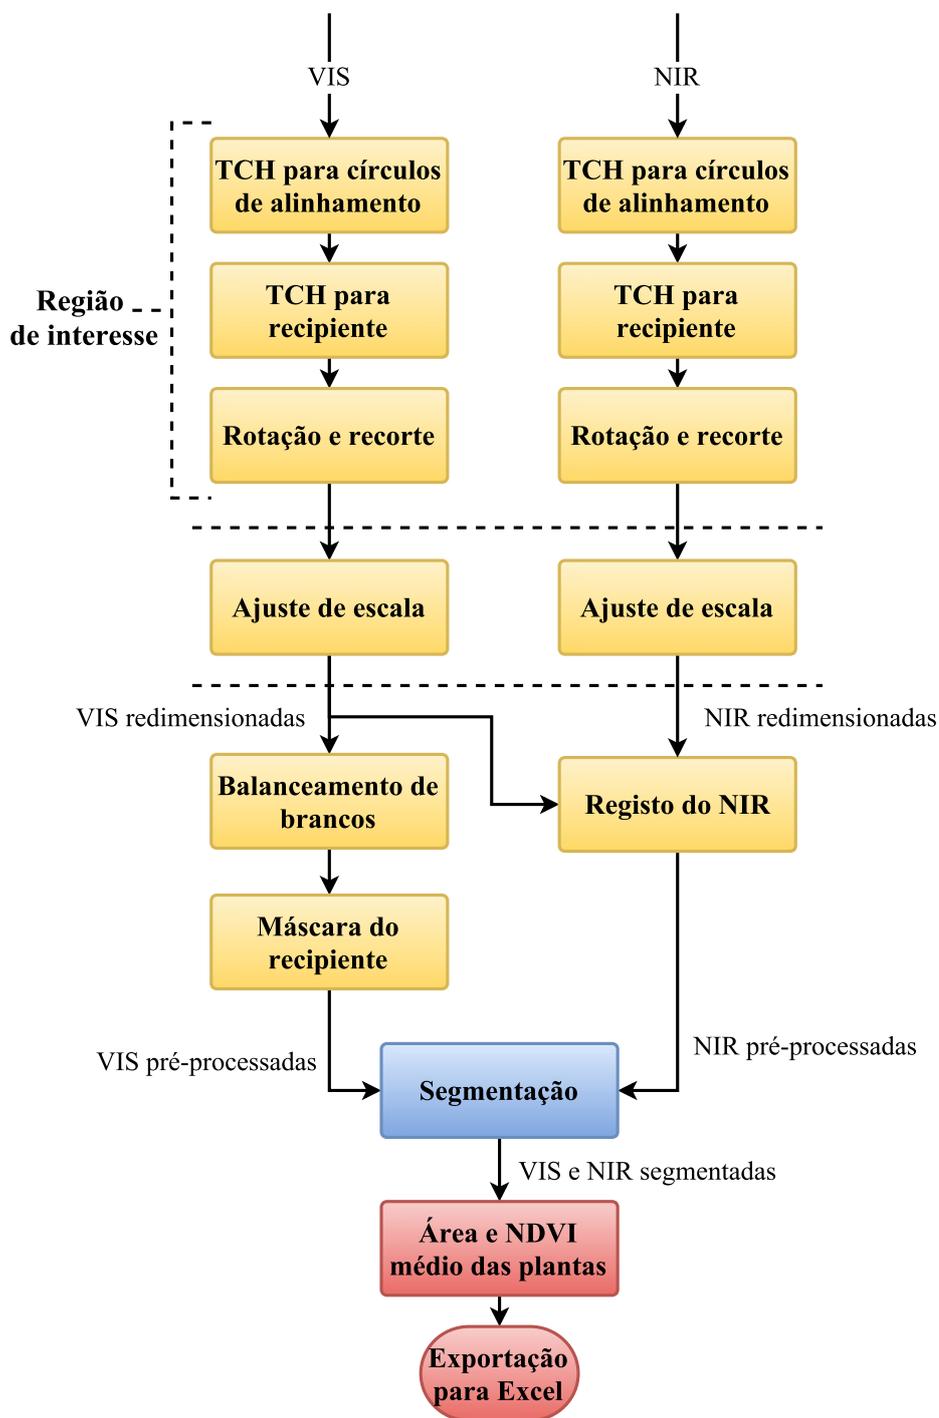


Figura 5.1: Fluxograma do método proposto. A amarelo encontra-se o pré-processamento, a azul a segmentação e a vermelho a extração de informação.

5.1.1 Região de interesse

Como a aquisição de imagem de um recipiente foi realizada ao longo de várias sessões, poderão eventualmente existir pequenas desorientações da guia em cada imagem. Por isso o primeiro passo, antes de identificar o recipiente na imagem, será a correção da orientação e em seguida o recorte do recipiente. Este processo é realizado para as imagens de ambos espetros captados, com diferenças em alguns parâmetros, que serão apresentados mais adiante.

Para corrigir a orientação, recorreremos ao uso dos círculos de alinhamento. Como os quatro círculos formam um retângulo, ao descobrir os seus centros e usando dois destes, é possível estimar a rotação a efetuar, de modo a que cada aresta do retângulo formado pelos círculos fique paralela a um eixo da imagem (arestas superior e inferior ficam paralelas com o eixo x e as arestas laterais com o eixo y). Um exemplo de desorientação é apresentado na figura 5.2 onde está representado o círculo superior (x_1, y_1) e inferior esquerdo (x_2, y_2) desorientados. Com estes dados, a rotação é facilmente calculada através da seguinte fórmula trigonométrica:

$$\alpha = -\arctan\left(\frac{x_1 - x_2}{y_1 - y_2}\right) \quad (5.1)$$

Como o método que aplica a rotação na imagem é realizado no sentido anti-horário, é necessário incluir o sinal negativo na equação 5.1.

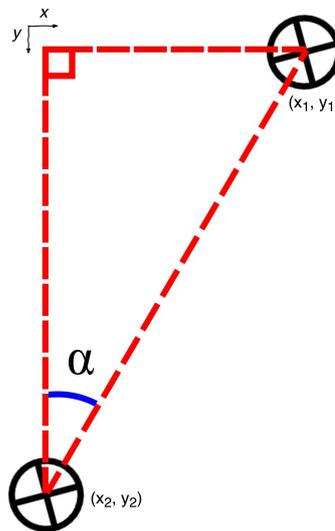


Figura 5.2: Representação da desorientação da guia. O ângulo α corresponde à rotação a realizar à imagem para que esta fique com a guia orientada.

Visto que as guias de alinhamento e o recipiente possuírem uma forma circular, aqui é aplicada a transformada circular de Hough, apresentada na secção 3.3 do capítulo 3, para extrair o centro e raio destes objetos. Este algoritmo é facilmente executado com

o auxílio da biblioteca *Image processing toolbox* através do método *imfindcircles*³. Porém, este é aplicado com um valor de raio ou intervalo de raios, sendo necessário fornecer uma estimativa *a priori*. Como a aquisição de imagem teve como base a colocação do equipamento fotográfico na mesma posição relativamente à guia em todas as sessões, foi possível estimar estes valores de raio. Na resolução adquirida, estimou-se que nas imagens do espectro visível o raio das guias de alinhamento esteja contido no intervalo [160, 240] pixels e o raio do recipiente *in-vitro* esteja contido no intervalo [1260, 1440] pixels. Como as imagens do espectro infravermelho-próximo foram captadas noutra resolução, foi estimado que o raio das guias de alinhamento esteja contido no intervalo [60, 100] pixels e o raio do recipiente *in-vitro* esteja contido no intervalo [560, 620] pixels.

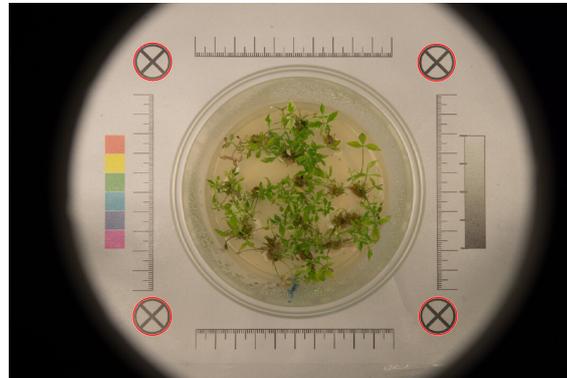
Tendo sido apresentado a base deste primeiro pré-processamento, em seguida é descrito em detalhe o método realizado para o ajuste da orientação e recorte do recipiente *in-vitro*. Este método difere na forma como é aplicado às imagens do espectro visível e do infravermelho-próximo, sendo as diferenças indicadas em seguida.

1. Mantendo uma cópia da imagem inicial, é redimensionada a imagem para metade do seu tamanho e copiada para uma imagem auxiliar. Este passo visa diminuir o tempo computacional.
2. É aplicada uma operação de suavização, usando um filtro de média uniforme com um *kernel* 5×5 à imagem do espectro visível redimensionada, por forma a melhorar os resultados da TCH.
3. O centro e raio de cada círculo de alinhamento é extraído através do uso da transformada de Hough, *imfindcircles*. Este método tem como parâmetro o intervalo de raios esperado, sendo aqui indicados os valores estimados do raio para cada espectro, nomeadamente [80, 120] para o visível e [30, 50] para o infravermelho-próximo. Estes valores correspondem a metade dos valores estimados anteriormente visto que a imagem foi redimensionada para metade do seu tamanho.

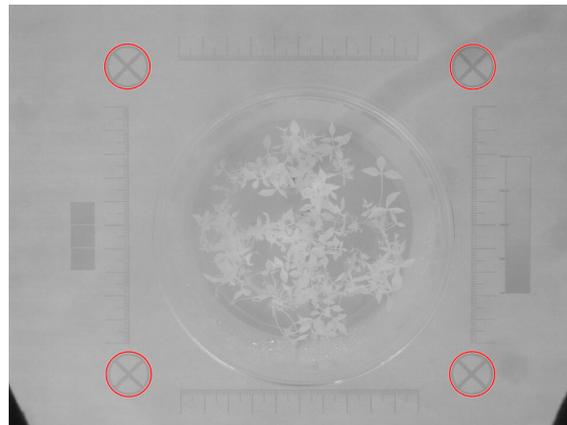
Foram também definidos outros parâmetros deste método, como o *Object polarity*, o *Method* e a *Sensitivity*. O parâmetro *Object polarity* indica se os objetos circulares a detetar são mais claros ou mais escuros que o fundo. *Method* serve para indicar qual o método a aplicar, *Two Stage* ou *Phase Code*, tendo sido selecionado o *Two Stage*, isto porque o *Phase Code* não permitia detetar os círculos. Por fim, o parâmetro *Sensitivity* é o fator de sensibilidade do vetor de acumuladores da transformada circular de Hough, com um valor entre [0, 1]. À medida que se aumenta este valor, são detetados mais objetos circulares, incluindo círculos fracos e parcialmente obscuros, o que pode aumentar o número falsas deteções. Neste caso foi definido um fator de sensibilidade de 0.9.

³<https://www.mathworks.com/help/images/ref/imfindcircles.html>

Com estes parâmetros da TCH definidos, são obtidos os centros e raios dos quatro círculos de alinhamento (figura 5.3), sendo depois ordenados por x e y para separar os círculos da esquerda e direita.



(a) Espetro visível



(b) Espetro infravermelho-próximo

Figura 5.3: Extração dos círculos de alinhamento da guia. Os objetos detetados pela transformada circular de Hough estão marcados como um círculo vermelho.

4. Através dos círculos da esquerda, sendo (x_1, y_1) e (x_2, y_2) respectivamente as coordenadas do centro dos círculos superior e inferior (como representado na figura 5.2), é calculado o ângulo de orientação da imagem, α , através da equação 5.1. Depois, é aplicada à imagem auxiliar uma rotação com interpolação bilinear (Gonzalez e Woods 2008).
5. Para reduzir o espaço de pesquisa da transformada circular de Hough para extrair a localização do recipiente, é necessário recortar a imagem deixando unicamente a zona interior do retângulo formado pelos círculos de alinhamento. Um retângulo é descrito pela posição inicial (x_{min}, y_{min}) , sendo esta o canto superior esquerdo, altura h_r e largura w_r . Estes parâmetros são calculados através das novas localizações dos centros do círculo superior esquerdo (x'_1, y'_1) e inferior direito (x'_4, y'_4) . Como foi aplicada uma rotação à imagem, as localizações extraídas pela transformada

circular de Hough são atualizadas pela equação de rotação (Gonzalez e Woods 2008) em torno do centro da imagem (equação 5.2).

$$\begin{cases} x' = \cos(-\alpha) \times (x - \frac{w}{2}) - \sin(-\alpha) \times (y - \frac{h}{2}) + \frac{w}{2} \\ y' = \sin(-\alpha) \times (x - \frac{w}{2}) + \cos(-\alpha) \times (y - \frac{h}{2}) + \frac{h}{2} \end{cases} \quad (5.2)$$

Uma vez que o recipiente não fica completamente contido no retângulo formado pelos centros dos círculos, foi necessário usar um parâmetro d_r para aumentar o tamanho do retângulo para conter o recipiente por completo. Nas imagens do espectro visível foi usado um valor de $d_r = 100$ e no espectro infravermelho-próximo um valor de $d_r = 50$. As equações dos parâmetros do retângulo são então as seguintes:

$$\begin{cases} x_{min} = x'_1 - d_r \\ y_{min} = y'_1 - d_r \\ w_r = x'_4 - x_{min} + d_r \\ h_r = y'_4 - y_{min} + d_r \end{cases} \quad (5.3)$$

Tendo estes parâmetros, é efetuado o recorte da imagem, obtendo-se a zona interior do retângulo tal como na figura 5.4.

6. Para suavizar as imagens do espectro visível, é aplicado um filtro gaussiano com $\sigma = 3$ por forma a melhorar os resultados da transformada circular de Hough na deteção do recipiente;
7. A extração da localização do centro (x_c, y_c) e raio (r) do recipiente *in-vitro* (figura 5.4) é realizada com a aplicação da transformada de Hough. Para além do intervalo de raio, os restantes parâmetros têm os mesmos valores indicados anteriormente. Como estamos a trabalhar a metade da resolução original, o intervalo do raio estimado para as imagens do espectro visível foi [630, 720] e para o espectro infravermelho-próximo foi [30, 50].
8. Sobre a imagem original é aplicada uma rotação com o ângulo α . Depois, é realizado um recorte (figura 5.5) à imagem original rodada para limitar a zona exterior do recipiente, após uma multiplicação por dois dos parâmetros x_{min}, y_{min}, r, x_c e y_c , para ficarem na escala da imagem original. As equações dos parâmetros do retângulo a recortar são as seguintes:

$$\begin{cases} x_0 = x_c - r - d + x_{min} \\ y_0 = y_c - r - d + y_{min} \\ w_f = h_f = 2 \times (r + d) \end{cases} \quad (5.4)$$

Sendo (x_0, y_0) a posição inicial do recorte, w_f e h_f o comprimento e altura do recorte. O fator d possui um valor de 70 para as imagens do espectro visível e 55 para as

do infravermelho-próximo. Este fator serve para garantir uma margem de segurança dos valores obtidos pela transformada circular de Hough, pois a margem do recipiente possui várias formas circulares.

A média dos raios das guias de alinhamento é calculada e multiplicada por dois para se usar no ajuste de escala.

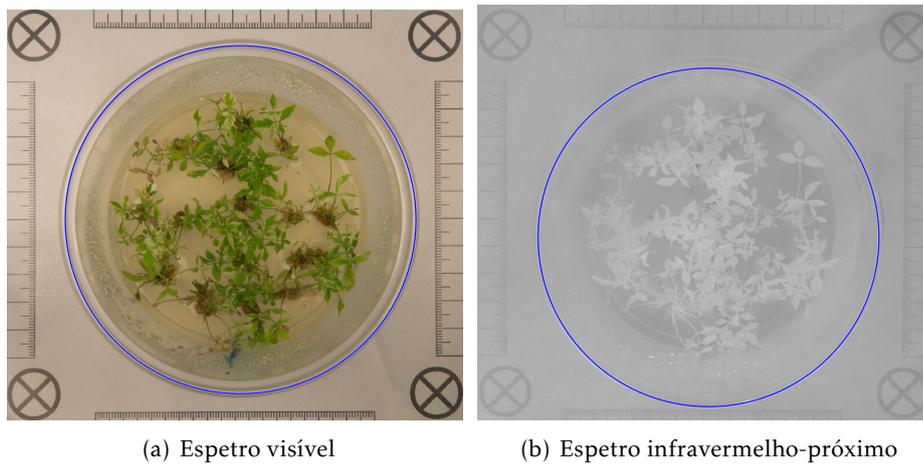


Figura 5.4: Extração do recipiente *in-vitro* através da transformada circular de Hough.

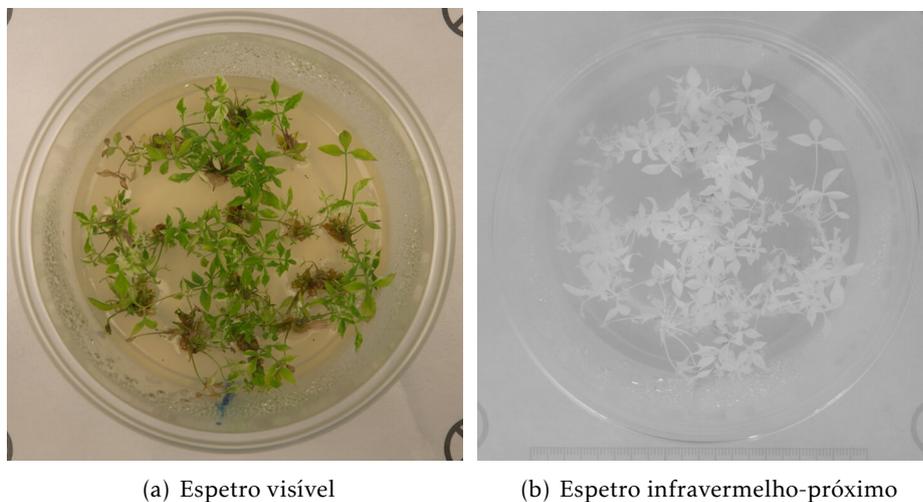


Figura 5.5: Resultado final da correção do ângulo de orientação e recorte do recipiente *in-vitro*.

5.1.2 Ajuste de escala

Tendo as imagens do espectro visível e infravermelho-próximo com o ângulo de orientação corrigido e recortadas até ao limiar do recipiente, torna-se necessário colocar as imagens de ambos espectros na mesma escala. Visto que as imagens adquiridas do espectro visível têm uma resolução de 6016×4016 pixels e as do infravermelho-próximo uma resolução

de 2272×1704 pixels, a mesma planta na mesma sessão irá possuir maior área de pixels na imagem do espectro visível do que na imagem do espectro infravermelho-próximo, o que não é desejável. O que se pretende é que as imagens estejam todas na mesma escala, para uma estimação da área mais correta.

Para isso, é feita uma operação geométrica, nomeadamente o escalamento de todas as imagens para a escala da imagem da primeira sessão do espectro infravermelho-próximo, devido à resolução inferior das imagens deste espectro. Este escalamento é calculado através das médias das guias de alinhamento de cada imagem. Assim, o fator de escala a aplicar a cada imagem S_i é calculado usando a seguinte equação 5.5:

$$S_i = \frac{M_{NIR}}{M_i} \quad (5.5)$$

Sendo M_{NIR} a média das guias de alinhamento da imagem da primeira sessão do espectro infravermelho-próximo, e M_i a média das guias de alinhamento da imagem a escalar. O escalamento foi aplicado com interpolação bilinear. No final deste passo, todas as imagens do recipiente ficam à mesma escala.

5.1.3 Registo das imagens visível e infravermelho-próximo

Com as imagens todas na mesma dimensão e escala, pode-se realizar o alinhamento entre as imagens do espectro visível com a correspondente imagem do espectro infravermelho-próximo. Visto que é necessário detetar zonas de interesse em ambas imagens de cada sessão e com o que foi apresentado na secção 3.2 do capítulo 3, são utilizadas as características locais SURF para extrair zonas de interesse em ambas imagens, de modo a estimar uma transformação geométrica que permita, dentro do possível, alinhar as plantas entre os dois espectros. Este passo é executado em todos os pares de imagens de cada sessão do recipiente *in-vitro*.

Em primeiro lugar, a imagem do espectro visível é convertida para a escala de cinzentos, de forma que a cor não influencie as características, através do índice de vegetação ExGR (secção 2.2.1 do capítulo 2) visto que este realça a zona da planta. Também foi necessário realçar a planta nas imagens do espectro infravermelho-próximo aumentando o contraste da imagem através de uma equalização de histograma da imagem (Gonzalez e Woods 2008).

Em seguida, é aplicado o detetor de características SURF para extrair as localizações das zonas de interesse de ambos espectros. Depois, com estes pontos é utilizado o descritor SURF para obter o vetor de características, que por sua vez é usado para obter as características presentes em ambas imagens, através da correspondência das características da imagem do ExGR do espectro visível com as características da imagem equalizada do infravermelho-próximo. Um exemplo da correspondência das características de ambas imagens é apresentado na figura 5.6. Como se pode observar, tendo a correspondência das características de ambas imagens, é possível estimar a transformação geométrica de uma imagem para a outra. Neste caso a transformação geométrica estimada foi de semelhança.

Esta transformação poderá envolver uma rotação, translação e escalamento, preservando assim a forma das folhas (ao contrário da transformação afim, onde poderá ocorrer uma alteração da forma das folhas). A estimação foi realizada para ser aplicada à imagem do espectro infravermelho-próximo.

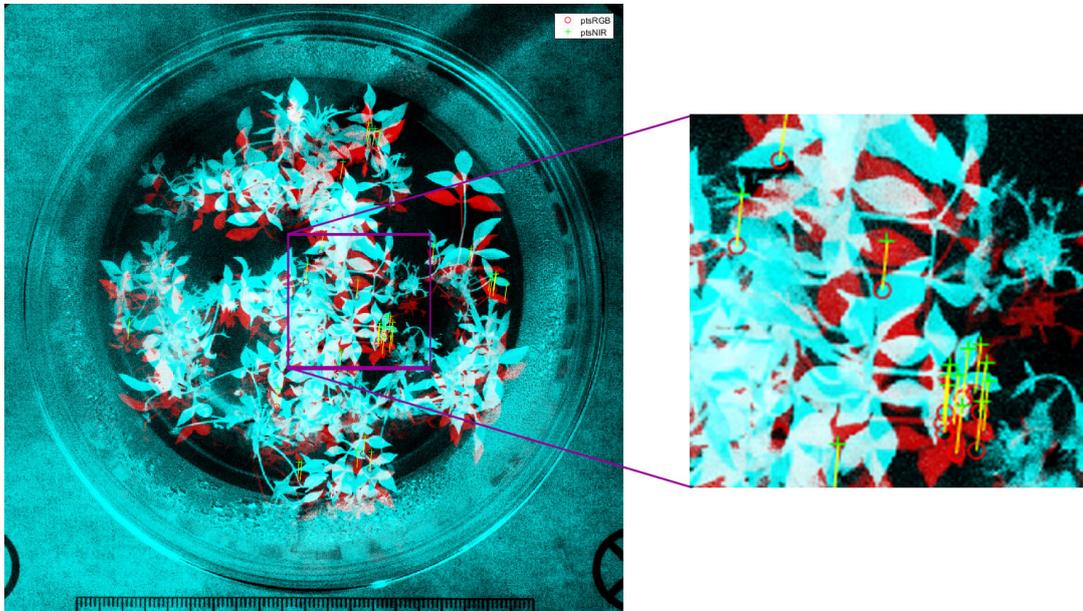


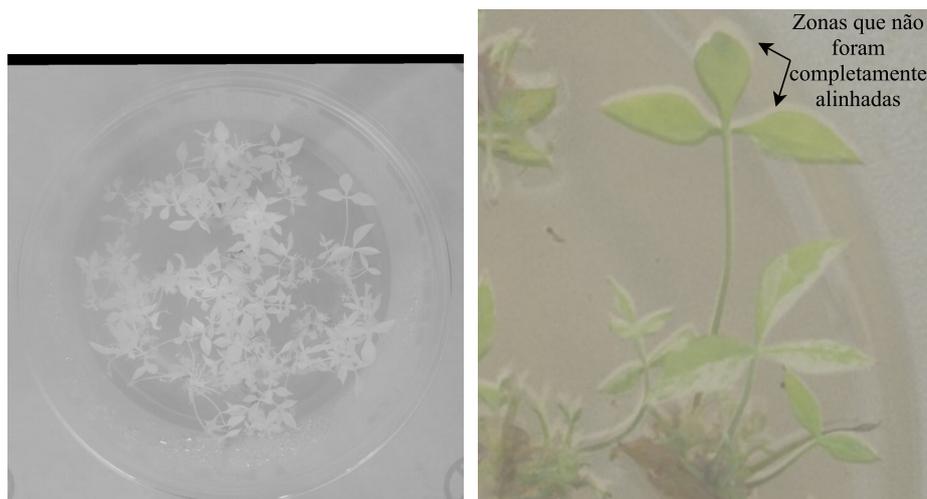
Figura 5.6: Correspondência das características SURF entre as imagens do espectro visível e infravermelho-próximo.

Um exemplo da transformação resultante é exibido na figura 5.7(a). Observando em detalhe e sobrepondo a imagem de ambos espectros na figura 5.7(b), o alinhamento não é perfeito. Este problema já foi referido na secção 4.3 do capítulo 4. Devido à própria forma de como a aquisição de imagem foi realizada, as plantas não se encontram na mesma posição em relação ao recipiente em ambos espectros, pois ao mover os recipientes, várias plantas eventualmente sofreram deslocamentos pequenos, mas suficientes para que estas fiquem em posições minimamente diferentes.

5.1.4 Balanceamento de brancos

Balanceamento de brancos ou *white balance* corresponde a algoritmos de remoção de cores não-realistas, de maneira que um objeto que pareça branco seja mesmo branco na fotografia captada. Estes processos são necessários, porque para um mesmo ambiente, é possível adquirir várias imagens diferentes em nível de composição de cor devido à temperatura de cor da fonte de luz, podendo por exemplo as máquinas digitais produzir imagens com um elenco de cor azul, amarelo, entre outros⁴. Uma técnica é o uso de referências neutras, como por exemplo, cartões de várias cores em escala de cinzentos.

⁴<http://www.cambridgeincolour.com/tutorials/white-balance.htm>



(a) Transformação geométrica de semente (b) Região do par de imagens sobreposta

Figura 5.7: Resultado da transformação geométrica numa imagem (a) e prevalectimento de um certo desalinhamento (b).

No entanto, é necessário ser cauteloso com o ponto de referência em imagens com grande ruído devido à presença de fragmentos de cor.

No nosso trabalho, visto estarmos a usar uma guia com fundo branco, a mesma é usada como ponto de referência branco sendo realizado o seguinte processo para cada imagem do espectro visível:

1. Inicialmente, é apresentada numa janela a imagem atual, sendo pedido ao utilizador a seleção de um ponto de referência branco;
2. Para reduzir os efeitos do ruído, é efetuada uma média uniforme 51×51 , em torno do ponto selecionado no passo anterior;
3. Pretende-se que o ponto de referência branco seja ajustado para a cor branca (componentes RGB a 255), e que os restantes pixels sigam a mesma alteração. Para isso, é efetuado um aumento de contraste da imagem através da seguinte operação em cada canal de cor RGB e aplicada a todos os pixels (Viggiano 2004):

$$p'_i = \frac{255 \times p_i}{w_i} \quad (5.6)$$

Em que i é o canal de cor R , B ou G , p'_i corresponde ao novo valor do pixel no canal de cor i , p_i o valor atual do pixel no canal de cor i , e w_i o valor da média uniforme 51×51 tendo como pixel central o selecionado pelo utilizador.

Na figura 5.8(a) encontra-se a vermelho a zona 51×51 centrada no ponto selecionado e na figura 5.8(b) o resultado do aumento de contraste.

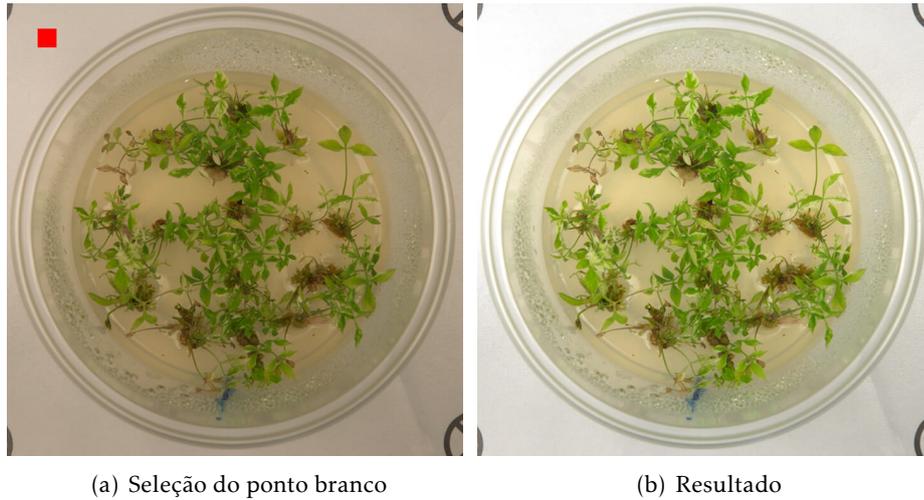


Figura 5.8: Balanceamento de brancos das imagens do espectro visível. À esquerda está a seleção da zona selecionada pelo utilizador como ponto branco. À direita é o resultado do balanceamento de brancos.

5.1.5 Máscara do recipiente

Para terminar o pré-processamento das imagens, falta apenas isolar a região de interesse nas imagens a segmentar. Visto que o objetivo de estudo/segmentação são as plantas, faz sentido que o algoritmo de segmentação classifique unicamente os pixels interiores ao recipiente. Para isso, pretende-se marcar a zona exterior do recipiente para que a segmentação ignore esses pixels. Como as imagens encontram-se centradas no recipiente e o raio do mesmo é conhecido (secção 5.1.1), uma máscara contendo a zona exterior é criada. Através desta máscara, a zona exterior é marcada/pintada de magenta ([255, 0, 255] em RGB) em todas as imagens. Foi escolhido magenta pois é bastante improvável que exista algum pixel pertencente ao recipiente ou meio de cultura ou planta com esta cor. Este passo apenas é realizado nas imagens do espectro visível, visto que estas estão alinhadas com as respetivas imagens do espectro infravermelho-próximo. Um exemplo do resultado do isolamento da zona de interesse é apresentado na figura 5.9.

5.2 Segmentação com Random Forest

Para a segmentação da imagem foi considerado usar um método de *machine learning*. Estes métodos, tal como foi indicado no capítulo 2 são os que obtêm melhores resultados na segmentação das plantas. Para o nosso caso, optámos por usar uma *random forest* para classificar corretamente pixels como pertencentes à planta ou não. Esta escolha deve-se às *random forests* serem menos sensíveis ao *overfitting* e obterem habitualmente melhores resultados que uma simples árvore de decisão, como referido na secção 3.1.1.2 do capítulo 3.



Figura 5.9: Isolamento da zona de interesse nas imagens do espectro visível.

A segmentação é feita em par de imagens, ou seja, o algoritmo recebe a imagem do espectro visível e a sua correspondente do espectro infravermelho-próximo pré-processadas. Admitindo que o pixel na posição (a, b) da imagem do espectro visível e da imagem do espectro infravermelho-próximo referem-se à mesma posição, são extraídas as suas características e a sua classe é determinada. Tendo a segmentação realizada, no final é retornado um par de imagens do espectro visível e infravermelho-próximo em que os pixels não pertencentes à planta estão a preto e os pertencentes à planta estão inalterados, para depois se poder extrair a área da planta e o NDVI médio.

Para aplicar este algoritmo, primeiro foi necessário selecionar quais as características que vão ser extraídas para descrever cada pixel como observação. Depois, através das imagens pré-processadas, é selecionado um conjunto de treino, com os pixels corretamente classificados. Em seguida é feito o treino da *random forest* e adicionado o modelo treinado ao algoritmo de segmentação.

5.2.1 Seleção de Características

A escolha das características usadas para descrever os pixels foi baseada no estudo feito do estado da arte (capítulo 2). No total foram selecionadas 13 características (tabela 5.1), 11 destas características são retiradas da imagem do espectro visível, 1 da imagem do espectro infravermelho-próximo e a restante é a combinação dos dois espectros.

A característica retirada da imagem do infravermelho-próximo é o valor do pixel neste espectro, denominando esta característica como componente NIR (*Near-infrared*).

Da imagem do espectro visível, são retiradas as componentes do espaço de cor RGB e do espaço de cor HSV (*Hue Saturation and Value*). Estes espaços de cor são os mais conhecidos para aplicações em processamento digital de imagem. Apesar da sua maior popularidade, também já foi aplicado para segmentação de plantas o espaço de cor La^*b^* em Bai et al. 2013, por isso decidimos incluir o mesmo. Por fim, são ainda incluídos os índices de vegetação ExGR e CIVE, que segundo o apresentado no estado da arte (capítulo 2), são os que no geral obtiveram melhores resultados em relação aos outros índices.

A restante característica foi a componente NDVI (secção 2.2.2 do capítulo 2) usando a imagem do espectro visível e infravermelho-próximo. O cálculo desta componente para cada pixel é feito através de uma adaptação da equação 2.10, nomeadamente:

$$p_{NDVI} = \left(\frac{p_{NIR} - p_{red}}{p_{NIR} + p_{red}} + 1 \right) \times 127.5 \quad (5.7)$$

Sendo p_{red} a componente vermelha do pixel no espectro visível e p_{NIR} a componente de escala de cinzas do pixel no espectro infravermelho-próximo. Esta fórmula normaliza os valores do NDVI do intervalo $[-1, 1]$ para o intervalo $[0, 255]$, permitindo uma melhor representação visual deste índice.

Tabela 5.1: Características usadas para descrever um pixel no conjunto de dados.

R	G	B	H	S	V	NIR	L	a*	b*	ExGR	CIVE	NDVI
---	---	---	---	---	---	-----	---	----	----	------	------	------

5.2.2 Seleção do conjunto de treino

Como a *random forest* é um algoritmo de aprendizagem supervisionada, foi necessário criar um conjunto de treino já classificado a partir de imagens pré-processadas. Para isso, os conjuntos de imagens de cada recipiente *in-vitro* foram pré-processadas e o resultado guardado em imagens do tipo *PNG*.

Dos 70 pares de imagens visível/infravermelho-próximo, escolhemos 14 para o conjunto de treino. Várias destas foram escolhidas aleatoriamente, enquanto outras foram escolhidas devido à presença de fatores interessantes que se manifestaram ao longo das sessões, em relação à cor do meio de cultura, cor da planta, partículas de água e zonas com retro-reflexão parcial. Foi importante considerar todos estes fatores para incorporar ao conjunto de treino, de modo a que este fique o mais realista possível. A nível do estado do meio de cultura, este inicialmente possui uma cor bastante clara (figura 5.10(c)), mas ao longo do tempo, em certos recipientes, o meio de cultura foi ficando com uma cor mais forte (figura 5.10(e)), indo até nuns casos para uma cor acastanhada (figura 5.10(g)), sendo que tornou-se necessário imagens que cobrissem estes casos. Para o nosso caso de estudo, a planta não é unicamente da tonalidade verde, possuindo zonas brancas nas folhas ou folhas completamente brancas (figura 5.10(a)), não sendo esta distribuição igual em todos os recipientes. Nas últimas sessões, surgiu o aparecimento de partículas de água nas paredes de certos recipientes *in-vitro* (figura 5.10(a)) e em certas aquisições ocorreu

parcialmente retro-reflexões no meio de cultura (figura 5.10(c)), sendo estas observações também importantes de obter para o conjunto de treino.

Para que a qualidade do conjunto de treino seja a melhor possível, em vez de se extrair todos os pixels pertencentes ao interior do recipiente e etiquetar como planta ou não-planta, foram apenas marcados alguns pixels que eram facilmente identificados como pertencentes à planta ou não. Isto permitiu que o conjunto de treino fosse corretamente classificado, pois as zonas de transição de planta para o resto da imagem são demasiado complexas para se classificar. Também contribui para que o conjunto de treino não tenha uma dimensão exagerada.

Esta seleção de pixels para o conjunto de treino foi feita num *software* de edição de imagem. Para os 14 pares escolhidos, foram escolhidas zonas pertencentes à planta e zonas não pertencentes à planta que englobassem todos os fatores descritos anteriormente. Isto foi realizado através da criação de uma imagem do género de uma máscara onde são identificados os pixels (localizações) que vão ser extraídos de cada imagem como planta ou não-planta. Os marcados como planta são marcados a cor vermelha enquanto que a roxo são os marcados como não-planta. O resto do interior foi colocado a preto e o exterior do recipiente mantivemos na mesma cor magenta que estava antes. Exemplos de várias imagens do conjunto de treino e suas respetivas máscaras de pontos estão apresentadas na figura 5.10. Por questões de visualização, o preto foi substituído por branco nas figuras das máscaras de pontos.

5.2.2.1 Extração do conjunto de treino através das máscaras

Tendo as imagens com a máscara de pixels a extrair para o conjunto de treino, foi necessário a partir destas máscaras e das imagens correspondentes, extrair as características e classes para cada pixel marcado e guardar estas observações num ficheiro. Para isto, escrevemos um *script* no *Matlab* para carregar os 14 pares de imagens selecionados e as suas respetivas máscaras para no fim do mesmo devolver um ficheiro *Excel* (.xlsx) tendo uma tabela com o conjunto de treino extraído das imagens.

O processo deste *script* encontra-se esquematizado na figura 5.11. Este funciona num ciclo que em cada iteração abre um par de imagens e a máscara correspondente. Em cada iteração, este primeiro obtém as matrizes com as características das imagens do espectro visível e NIR indicadas na secção 5.2.1. Depois percorre a máscara com a seleção de pixels a extrair e para cada pixel da máscara, verifica se este é vermelho ou roxo. No caso de ser vermelho, é atribuído a classe de planta (1), enquanto roxo é atribuído a classe de não-planta (0). As características do pixel e a sua classe são depois adicionadas como uma nova entrada (linha) na tabela do conjunto de treino. Cada linha desta tabela corresponde a um pixel (observação) e as colunas correspondem às características e classe do pixel. Aqueles que não possuem a cor vermelho ou roxo é porque serão pixels a ignorar, não sendo adicionados à tabela do conjunto de treino. No final, as observações repetidas são filtradas, mantendo-se apenas uma observação destas e a tabela é guardada num ficheiro

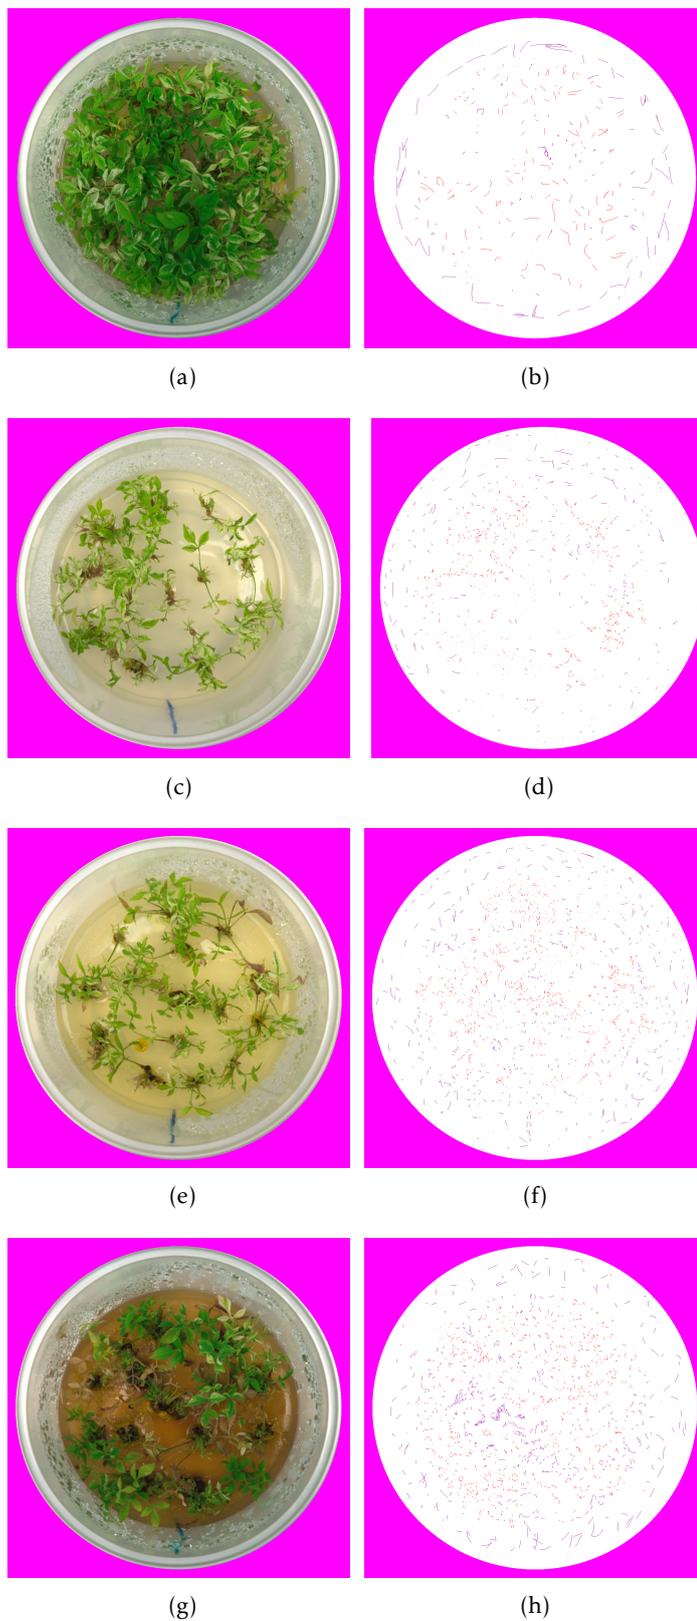


Figura 5.10: Algumas das imagens usadas para extração dos dados de treino (esquerda) e representação da máscara com pontos a extrair (direita).

Excel.

No total foram extraídas 90564 observações: 44459 pertencentes à classe planta e 46105 à classe não-planta.

5.2.3 Treino da Random Forest

Depois de termos extraído o conjunto de treino para um ficheiro *Excel*, uma *random forest* foi treinada com estes dados. Isto foi realizado através da aplicação *Classification Learner*⁵ do *Matlab*. Esta aplicação permite treinar algoritmos de aprendizagem supervisionada com um conjunto de dados e possibilita a extração do modelo treinado para o ambiente *Matlab*, podendo assim incluir o algoritmo treinado em *scripts Matlab*.

O *Classification Learner* carrega um conjunto de dados guardados em ficheiros *Excel* ou dados localizados no *workspace* do *Matlab*. Depois de se definir quais são características, classe e indicar o método de validação, tem-se ao dispor uma grande variedade de métodos de aprendizagem supervisionada a usar para treinar um modelo que classifique os tipos de dados fornecidos. Estes métodos vão desde a vários tipos de árvores de decisão, classificadores de vizinhança, *Support Vector Machines* e classificadores *ensemble*, incluindo a *random forest (bagged trees)*. Para cada método de aprendizagem treinado, devolve a precisão do mesmo e outras métricas de avaliação como matriz de confusão e *Receiver Operating Characteristic (ROC)*, podendo depois exportar os modelos *matlab* do método de aprendizagem treinado para prever novas observações no ambiente do *Matlab* sem ter que se recorrer ao *Classification Learner*. Para o conjunto de dados utilizados nesta dissertação, a *random forest* foi a que obteve no geral melhor avaliação.

O treino da *random forest* inicia-se com o carregamento do ficheiro contendo o conjunto de treino e atribuindo as características e a classe às respetivas colunas. Como método de validação, optou-se pela validação cruzada a k grupos com $k = 5$. Visto os restantes métodos serem *Houldout* ou *Não validar* (usar todo o conjunto como treino e teste de uma só vez) e como o conjunto de dados não é de grandes dimensões, a validação cruzada a k grupos seria a melhor escolha para proteger o modelo contra o *overfitting*. Tendo o conjunto de dados configurado, configurou-se o tamanho da *random forest* para 30 árvores de decisão. Este valor é o *default* e mostrou-se suficiente para esta dissertação. Após a configuração do modelo, é efetuado o treino. A matriz de confusão resultante da fase de treino encontra-se apresentada na tabela 5.2 e as métricas de avaliação obtidas na tabela 5.3. Como se pode observar, o modelo treinado classificou corretamente a maioria do conjunto de dados utilizado, existindo uma baixa percentagem de falsos positivos e falsos negativos. Com isto, obteve-se um classificador com excelentes métricas de avaliação do conjunto de dados utilizado para o treino.

Depois de terminado o treino da *random forest*, o modelo desta foi extraído e guardado num ficheiro *matlab (mat)* para que depois o mesmo seja incorporado no código do algoritmo de segmentação.

⁵<https://www.mathworks.com/help/stats/classificationlearner-app.html>

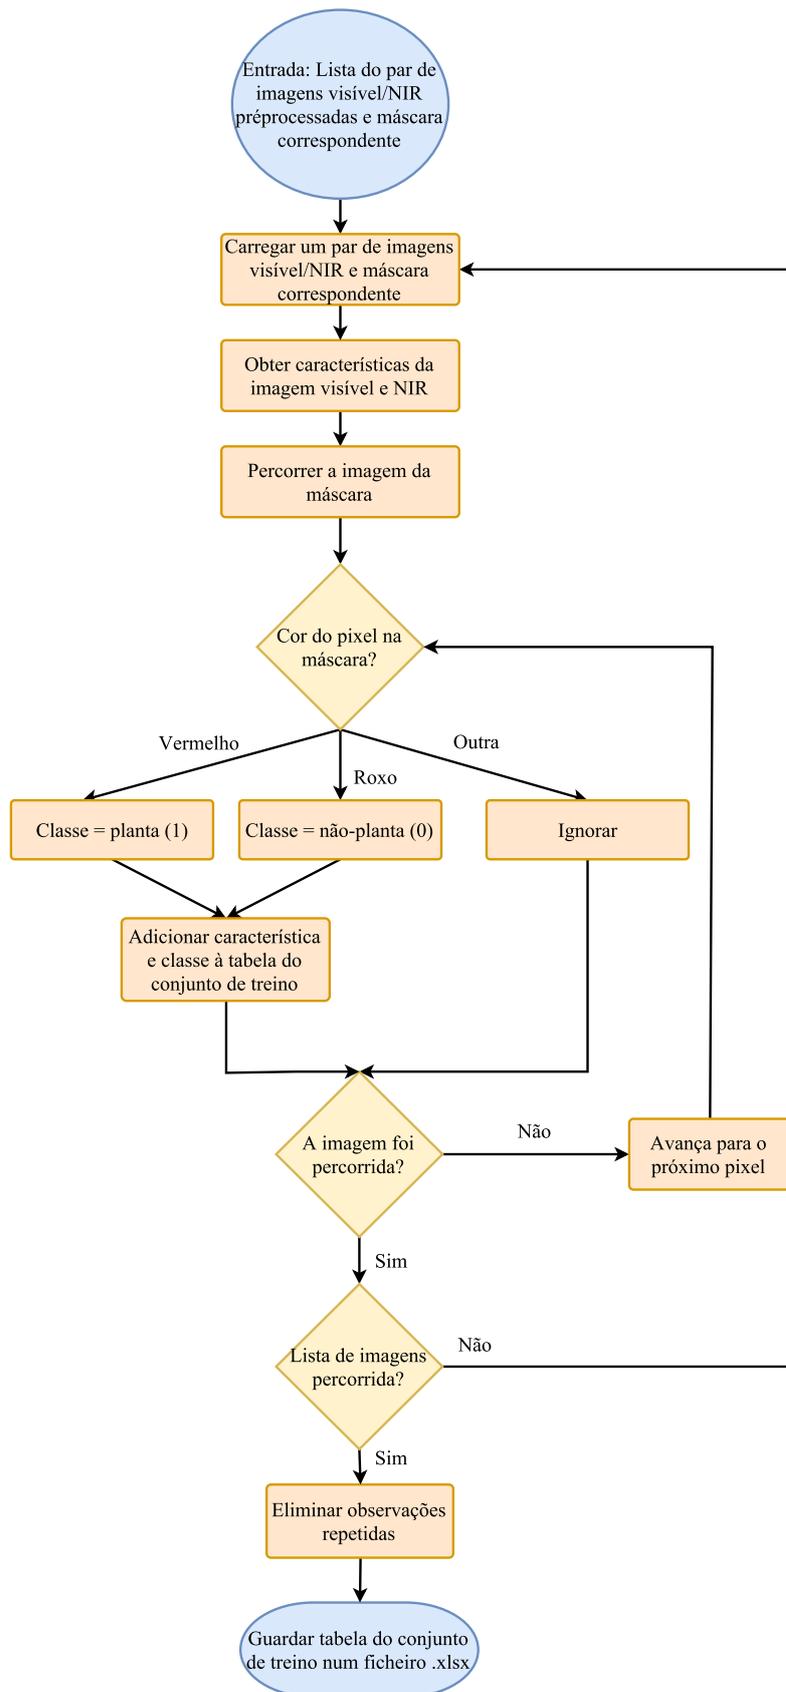


Figura 5.11: Fluxograma do algoritmo de exportação do conjunto de treino do conjunto de imagens seleccionadas com base da máscara de pontos criada.

Tabela 5.2: Matriz de confusão da fase de treino.

		Classe real	
		Planta	Não-planta
Classe Estimada	Planta	48.5%	0.4%
	Não-planta	0.6%	50.5%

Tabela 5.3: Métricas de avaliação da fase de treino.

Precisão	99%
Sensibilidade	98.8%
Especificidade	99.3%
VPP	99.3%
VPN	98.8%
TFN	1.2%
TFP	0.7%

5.2.4 Aplicação da Random Forest

Com o modelo da *random forest* treinado e extraído, aplica-se o algoritmo de segmentação. Este método é executado em cada par de imagens visível/infravermelho-próximo de cada sessão obtida, retornando no final uma matriz com a classe atribuída a cada pixel. Com base nesta matriz, a imagem visível e infravermelho-próximo são filtradas de modo a que os pixels classificados como planta fiquem inalterados e os restantes marcados/pintados a preto.

Na figura 5.12 são ilustrados os detalhes do algoritmo de segmentação que é executado em cada par de imagens visível/infravermelho-próximo. Em primeiro lugar, o modelo da *random forest* é carregado a partir do ficheiro *mat* onde ficou guardado. Em seguida, a imagem é percorrida pixel a pixel, sendo verificado se o mesmo pertence ao exterior do recipiente, através da cor magenta ([255, 0, 255] em RGB) na imagem do espectro visível. No caso do pixel pertencer ao exterior, este é classificado com o valor -1. No caso de o pixel pertencer ao interior, as suas características são extraídas, nomeadamente as componentes RGB, HSV, La^*b^* , NIR (valor do pixel na imagem infravermelho-próximo) e índices ExGR, CIVE e NDVI, sendo introduzidas na *random forest* para classificação. Se o pixel for classificado como planta, é atribuída a classe 1 e no caso de não-planta a classe 0. No final, com a matriz de classes retornada, esta é aplicada no par de imagens visível e infravermelho-próximo para que todos os pixels classificados como exterior (-1) ou não-planta (0) sejam colocados a preto. Os pixels pertencentes à planta mantêm-se com os mesmos valores RGB (figura 5.13).

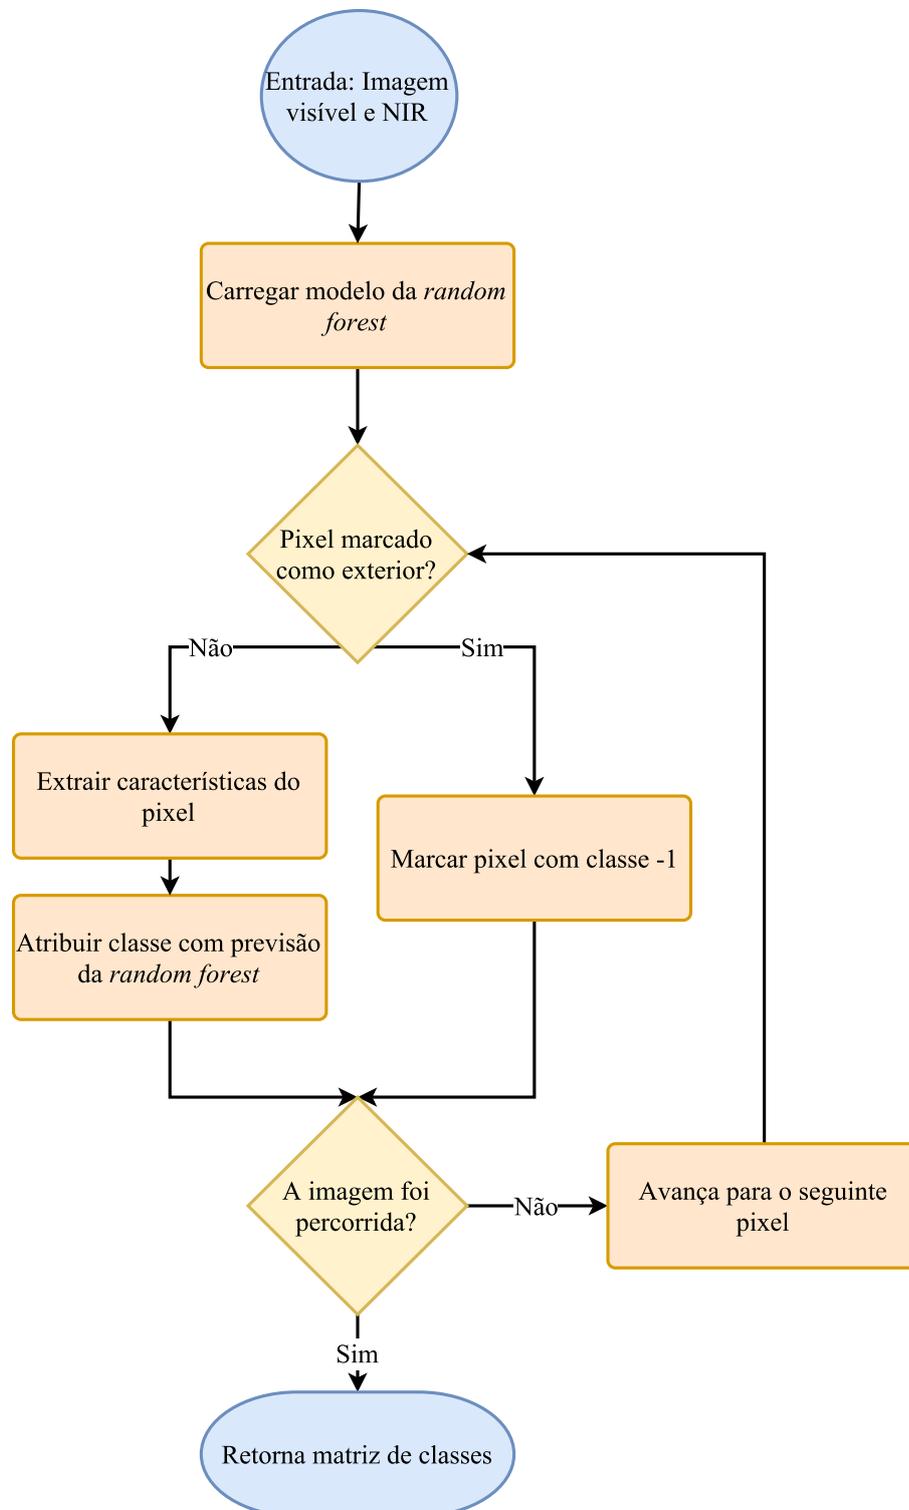


Figura 5.12: Fluxograma do algoritmo de segmentação.

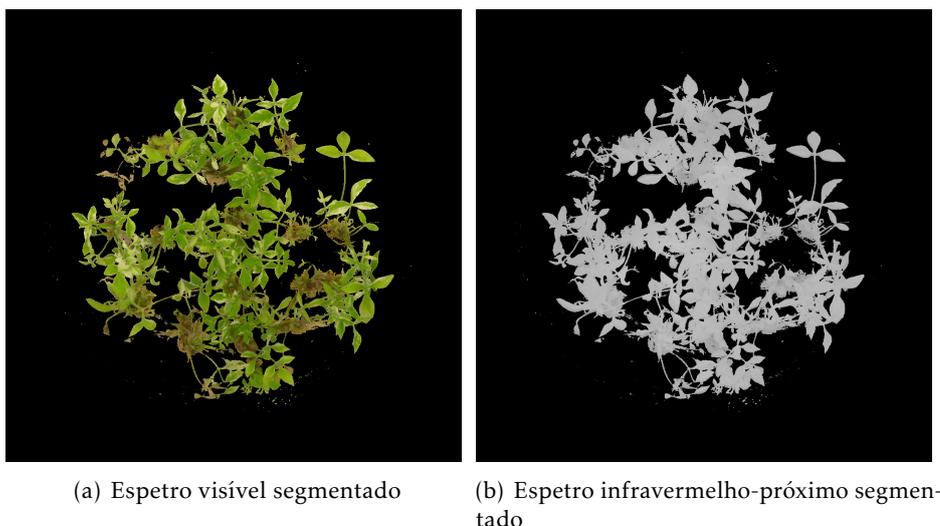


Figura 5.13: Resultado da segmentação com a *random forest*, com os pixels classificados como não-planta e exteriores a preto.

5.3 Extração de Informação

Tendo as imagens de um recipiente devidamente segmentadas, é estudada a evolução da área das plantas e o NDVI médio. A área é uma medida que permite retirar informação acerca do crescimento das plantas de um recipiente *in-vitro*. A estimação do NDVI médio das plantas de um recipiente permite obter uma representação da vitalidade das plantas. Estes dados são obtidos por sessão, sendo depois guardados num ficheiro *Excel* para futura análise da evolução, identificado com o número do recipiente. A tabela *Excel* possui a estrutura apresentada na tabela 5.4.

O cálculo da área da planta para cada sessão foi realizado através da contagem dos pixels marcados como classe planta (1). Esta área não corresponde à área real da planta, visto esta ser obtida pela observação do perfil superior do recipiente, existindo ao longo da evolução da planta sobreposição das folhas.

Para o NDVI médio, que também é calculado por sessão, como se considera apenas a zona da planta, a média é calculada usando os valores NDVI dos pixels classificados como planta. Para isso é calculado o índice NDVI para todos os pixels pertencentes à planta através da equação 5.7 e calculado o valor médio desse conjunto de pixels.

Tabela 5.4: Esquema da tabela extraída da evolução da área e NDVI médio por sessão de um recipiente *in-vitro*.

Planta	Sessão	Área	NDVI médio
--------	--------	------	------------

5.4 Protótipo de monitorização

Para testar o método proposto nesta dissertação para o processamento de imagem aqui descrito, foi desenvolvido um protótipo em forma de aplicação *GUIDE* do *matlab*. Esta aplicação fornece uma interface gráfica de utilizador que possibilita carregar as imagens do espectro visível e infravermelho-próximo adquiridas ao longo das sessões de um recipiente. Este protótipo também permite observar as várias imagens de cada sessão, bem como os resultados de cada passo do processamento de imagem e a extração dos resultados da área e NDVI médio.

O aspeto gráfico da aplicação é apresentado na figura 5.14. Como se pode constatar, esta aplicação possui duas figuras onde é apresentado o par de imagens do espectro visível e infravermelho-próximo de um recipiente numa certa sessão (no caso da figura 5.14 corresponde ao recipiente 19 na sessão 6). Uma barra horizontal está colocada na zona inferior da aplicação para escolher o par de imagens que são apresentadas de acordo com a sessão selecionada. Barras verticais também estão ao dispor para percorrer as imagens resultantes de cada operação (*step*) efetuada, sendo a última imagem a segmentação das plantas. À direita, encontram-se disponíveis as operações de processamento de imagem descritas anteriormente. Estas estão divididas em dois grupos: o pré-processamento e a segmentação. Em seguida são descritos os métodos executados por cada botão:

- *Save step* - Guarda todas as imagens de todas as sessões da operação visualizada na interface gráfica;
- *Open images* - Carrega as imagens adquiridas no perfil superior de ambos espectros do recipiente *in-vitro* indicado nos dados de entrada *Number*, *Nº Sessions* e *1º NIR session*;
- *Find Box Visible* - Executa o método de correção da orientação da folha e recorte do recipiente, descrito na secção 5.1.1, para as imagens do espectro visível;
- *Find Box NIR* - Executa o método de correção da orientação da folha e recorte do recipiente, descrito na secção 5.1.1, para as imagens do espectro infravermelho-próximo;
- *Visible & NIR scaling* - Executa o ajuste de escala, descrito na secção 5.1.2;
- *Align Visible and NIR* - Executa o registo das imagens, descrito na secção 5.1.3;
- *White balance* - Executa o balanceamento de brancos, descrito na secção 5.1.4;
- *Filter Box* - Executa o método da máscara do recipiente, descrita na secção 5.1.5;
- *Random Forest* - Executa o método de segmentação, descrito na secção 5.2.4;
- *Export Area and NDVI* - Obtém a área e o NDVI médio das plantas de cada sessão e guarda num ficheiro Excel tal como descrito na secção 5.3.

5.4. PROTÓTIPO DE MONITORIZAÇÃO

Estes botões foram colocados pela ordem que devem ser executados (à exceção do *Save step* que pode ser executado em qualquer altura).

Tendo os métodos desenvolvidos e a aplicação GUIDE realizada, esta foi carregada para todos os recipientes *in-vitro* monitorizados durante a aquisição de imagem. No final do processamento das imagens de cada recipiente, a área de planta e NDVI médio foram extraídos através do *Export Area and NDVI*.

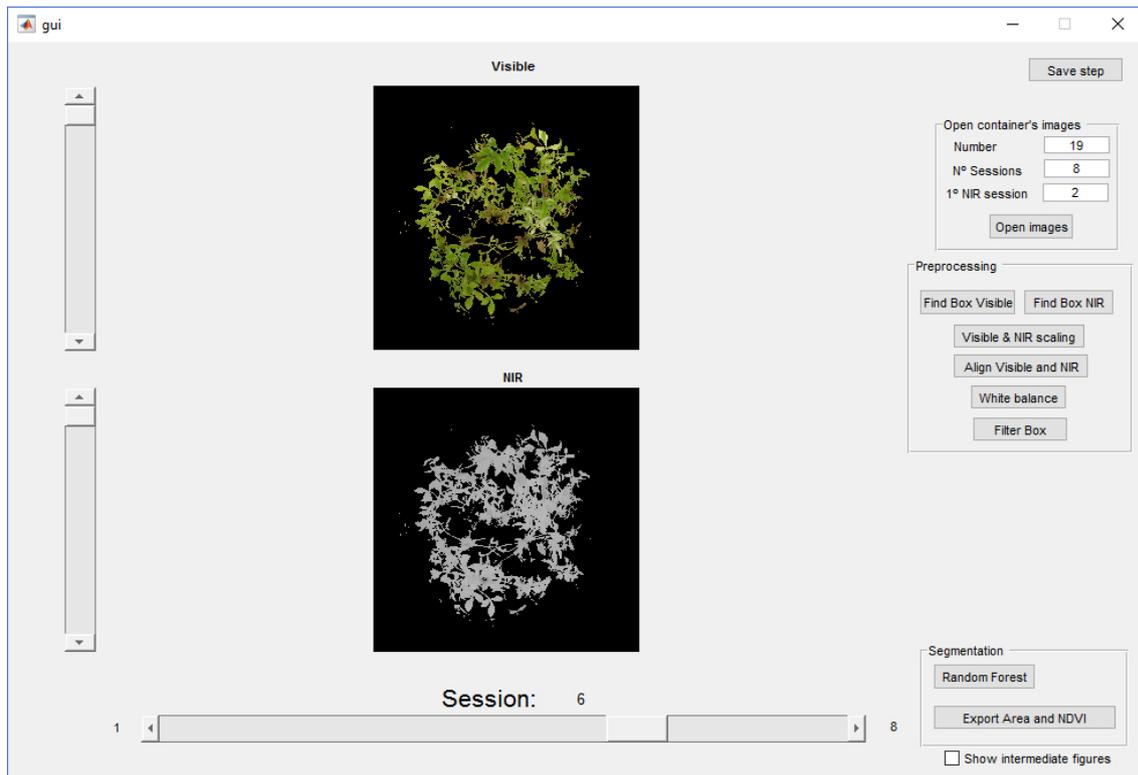


Figura 5.14: *Screenshot* da aplicação desenvolvida.

VALIDAÇÃO E RESULTADOS OBTIDOS

Neste capítulo é apresentada a validação da metodologia, os resultados obtidos da segmentação das plantas e a estimação da evolução da área e NDVI médio das plantas *in-vitro* para o conjunto de recipientes adquiridos na aquisição de imagem. De forma a validar os resultados obtidos, foi criado um conjunto de imagens usado como referência (*ground truth*) com a classificação real dos pixels. As imagens deste conjunto são comparadas com as obtidas na segmentação para avaliar o método desenvolvido, sendo também traçada a evolução da área e NDVI médio das plantas de um recipiente.

6.1 Validação da metodologia proposta

A validação envolveu a avaliação das imagens segmentadas pelo método proposto comparando com a segmentação real das mesmas, assim como a comparação da evolução da área e NDVI médio da planta.

6.1.1 Ground truth

De modo a podermos validar a segmentação pela *random forest*, foi necessário compará-la com uma segmentação real. *Ground truth* é um termo usado em várias áreas de investigação para referir a informação que é recolhida por observação direta em vez de informação recolhida por inferência. No caso na área de visão computacional, *ground truth* corresponde à classificação real dos pixels das imagens. No caso desta dissertação, corresponde a uma distinção entre pixels pertencentes à planta e os restantes. Esta tarefa é morosa e fastidiosa de se realizar corretamente, pois é necessário classificar manualmente todos os pixels, sendo particularmente difícil a distinção dos pixels nas margens da planta.

A criação do *ground truth* foi realizada através de uma segmentação manual a um conjunto de imagens pré-processadas usando um editor de imagem. Neste editor foi

usada a ferramenta *lasso tool*, que facilita a criação da segmentação manual, mas não deixando de ser uma tarefa exaustiva e morosa. Como as imagens pré-processadas do espectro visível e infravermelho-próximo estão alinhadas, a segmentação manual envolveu apenas a imagem do espectro visível (figura 6.1).

Como pretendemos também validar a estimação da evolução da área da planta e o seu NDVI médio, seleccionámos um recipiente para segmentar manualmente todos os seus pares de imagens, podendo assim determinar a evolução real das plantas do recipiente. O recipiente selecionado foi o número 20, pois foi um dos que obteve uma maior evolução, como será apresentado na secção 6.2. Para complementar a validação do método de segmentação, para além das imagens do recipiente 20, foram selecionadas aleatoriamente outras 7 imagens. Todas as imagens que foram usadas para o *ground truth* estão apresentadas na tabela 6.1 com a respetiva identificação do recipiente e sessão. Na figura 6.1 encontram-se exemplos da segmentação manual realizada.

Tabela 6.1: Imagens usadas para o *ground truth*.

Recipiente	Sessões
7	2
8	8
9	5
11	3
16	6
17	4
18	7
20	2-8

6.1.2 Validação da metodologia

A validação da metodologia consistiu na avaliação do método desenvolvido através das métricas referidas anteriormente na secção 3.1.2 capítulo 3, nomeadamente *Precisão*, *Sensibilidade*, *Especificidade*, *VPP* e *VPN*. No caso desta dissertação, a classe positiva corresponde à classe planta e a negativa à não-planta. Isto corresponde a que os falsos positivos sejam os pixels classificados como planta, mas sendo na realidade não-planta e falsos negativos os pixels classificados como não-planta, mas sendo na realidade planta. Os pixels exteriores ao recipiente (marcados a magenta) não são avaliados.

A obtenção das métricas consistiu em comparar as imagens segmentadas manualmente do *ground truth* com a segmentação pela *random forest*, tendo sido calculada para cada imagem a sua matriz de confusão e obtenção das métricas de avaliação. No final, foram obtidos os valores médios de cada métrica e respetivo desvio médio para as imagens analisadas, os quais estão apresentados na tabela 6.2. Como se pode observar, os valores obtidos de precisão, sensibilidade, especificidade e valores preditivos apresentam uma baixa taxa de erro.

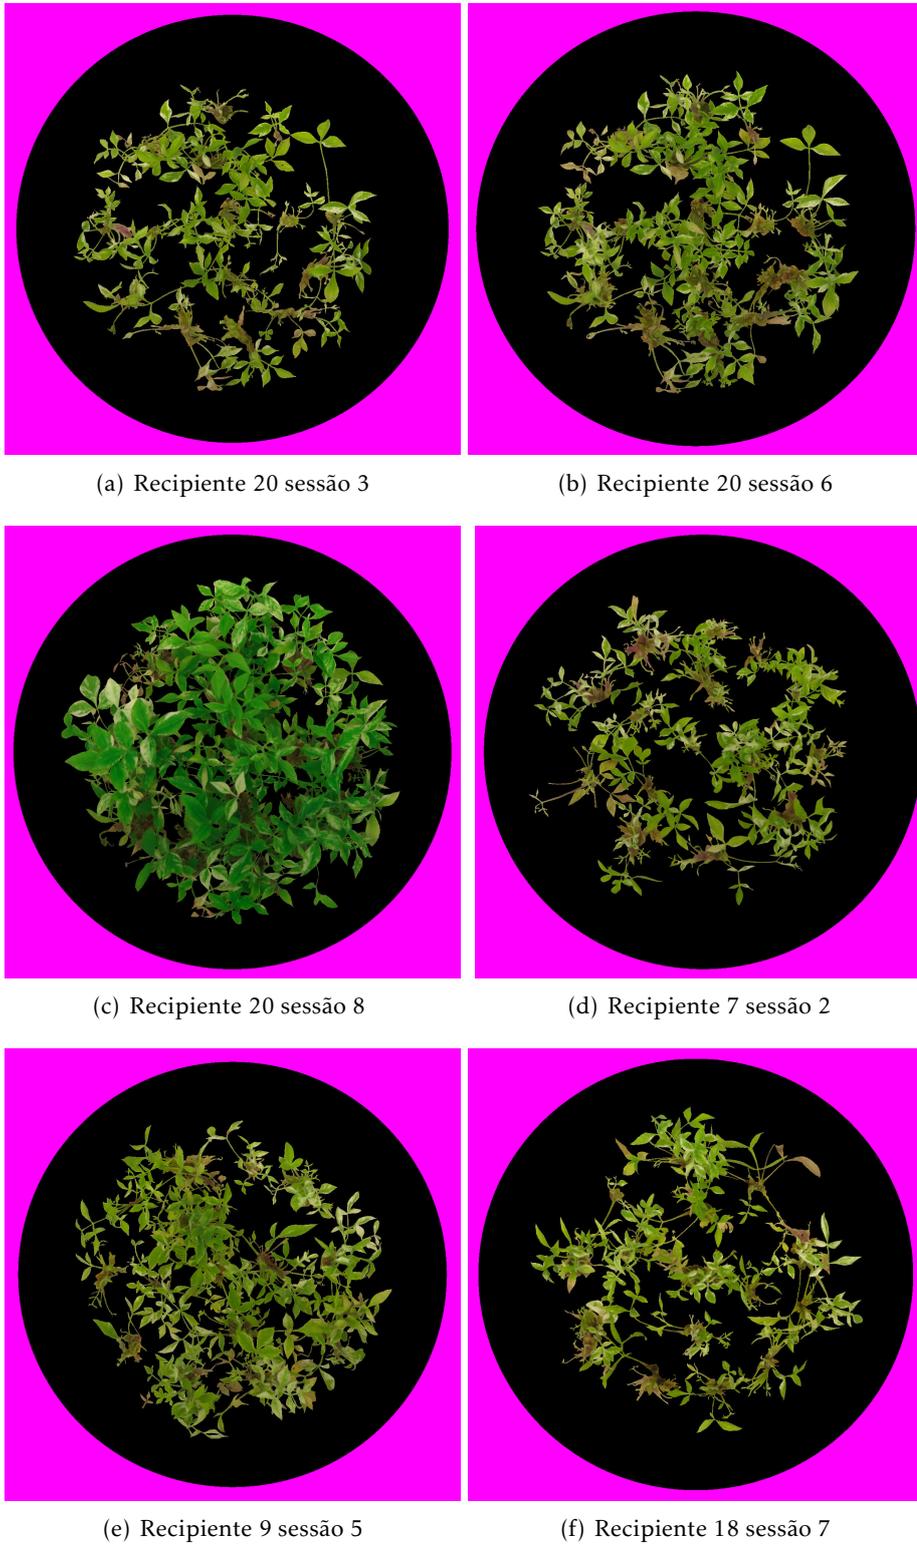


Figura 6.1: Exemplo de imagens da segmentação realizada manualmente para o *ground truth*.

Tabela 6.2: Valores médios das métricas de avaliação para o método desenvolvido dos pixels interiores do recipiente.

Métrica	Média	Desvio Médio
Precisão	96.9%	0.5%
Sensibilidade	96.8%	1.6%
Especificidade	96.9%	0.8%
VPP	89.2%	3.4%
VPN	99.0%	0.6%
TFN	3.2%	1.6%
TFP	3.1%	0.8%

Para analisar a localização dos falsos positivos e falsos negativos, estes foram assinalados em várias imagens segmentadas. Na figura 6.2 estão apresentados vários resultados da segmentação do nosso método e na figura 6.3 as imagens de comparação com o *ground truth* correspondentes, com os falsos positivos detalhados a vermelho e os falsos negativos a verde. Como se pode observar, tanto os falsos positivos como falsos negativos têm maior incidência na fronteira da planta com o meio de cultura, com maior ocorrência nos falsos positivos. Uma vez que a segmentação manual não é perfeita, estes erros podem ser devidos a uma incorreta segmentação manual.

No entanto, existem outros falsos positivos e falsos negativos reais para além dos casos da fronteira (figura 6.3). Em certas imagens existe a ocorrência de falsos positivos ao redor do recipiente devido à presença de partículas de água que foram classificadas como plantas, pois em certas partículas de água, a refletividade no espectro infravermelho-próximo foi significativa. Outros casos de falsos positivos e falsos negativos devem-se à distinção entre a raiz e o meio de cultura e zonas secas das plantas. Por fim, comparando as imagens segmentadas pelo método proposto e as segmentadas manualmente, verifica-se que o método proposto teve uma boa performance na classificação das zonas brancas da planta.

6.1.3 Validação da Área e NDVI médio

Para validar o cálculo das área e NDVI médio estimados da planta e a sua evolução, recorreremos ao cálculo destas medidas a partir das imagens do *ground truth* do recipiente 20 tal como foi referido anteriormente. O gráfico da figura 6.4 mostra a evolução da área da planta estimada e a área da planta real. Neste caso, verificamos que a linha de tendência segue a mesma taxa crescimento, com a diferença da área estimada ser ligeiramente superior à real, embora estas se tenham aproximado na quinta semana. Em resumo, verifica-se que o nosso método possui uma boa estimação da área, apesar da sua ligeira sobre-estimação.

Da mesma forma que se avaliou o cálculo da área da planta, na figura 6.5 é apresentado um gráfico com a evolução dos NDVI médios estimado e real da planta. Neste caso, o

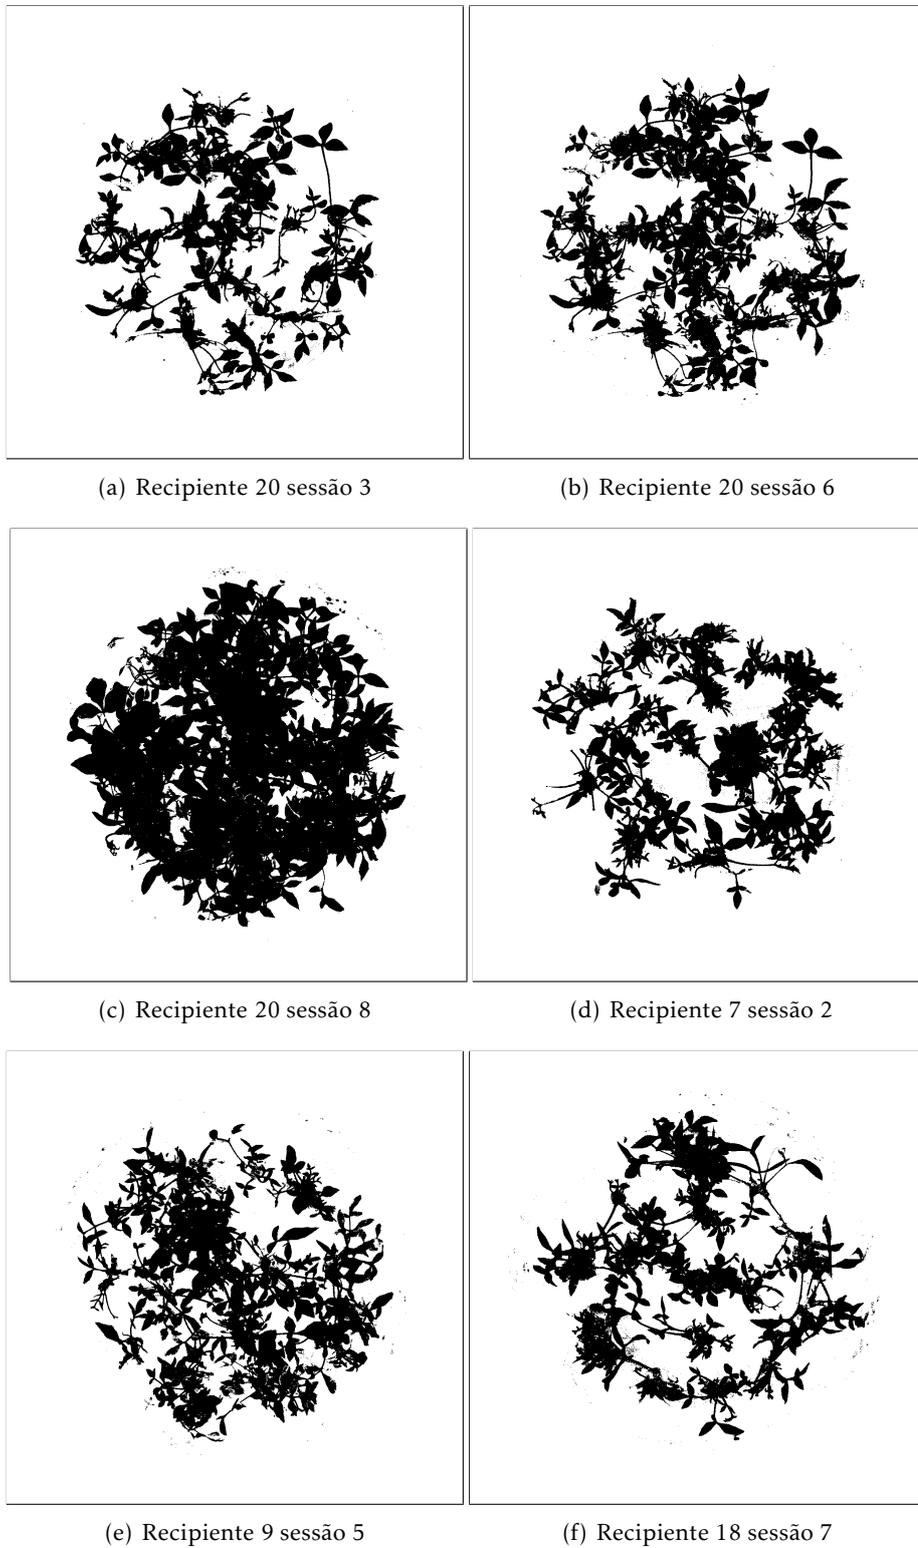


Figura 6.2: Exemplo de imagens da segmentação realizada pela *random forest*.

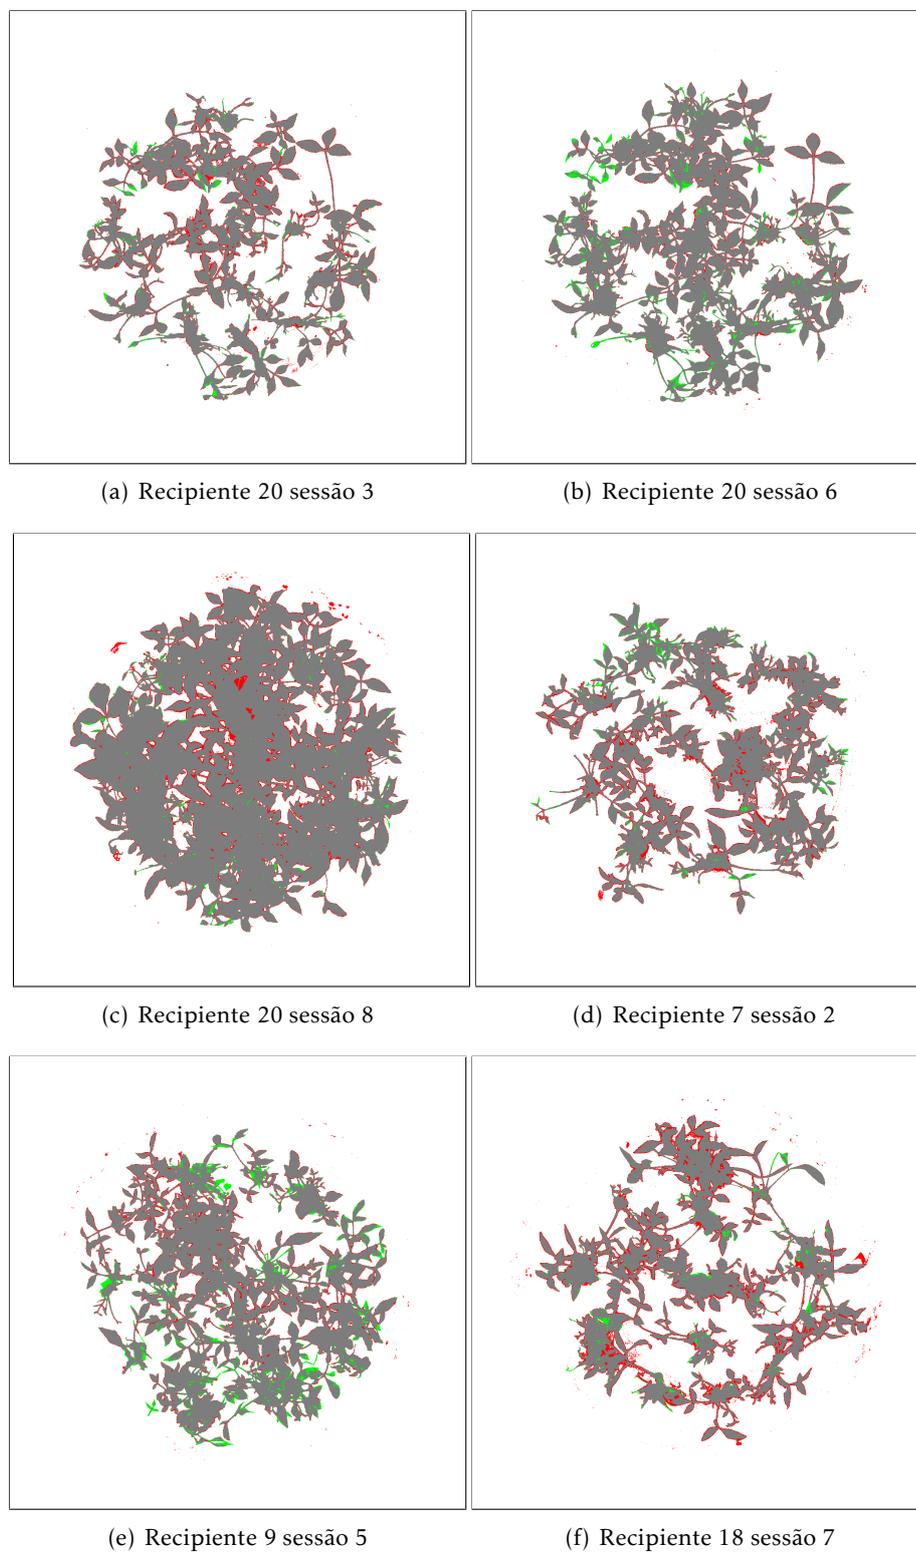


Figura 6.3: Exemplo de imagens da comparação da segmentação da *random forest* com o *ground truth* com indicação de falsos positivos a vermelho e falsos negativos a verde.

que foi observado na área também é verificado no NDVI médio. O NDVI médio estimado segue a tendência de crescimento do NDVI médio real, tendo no geral também uma sobre-estimação, mas obtendo valores bastantes semelhantes em várias semanas.

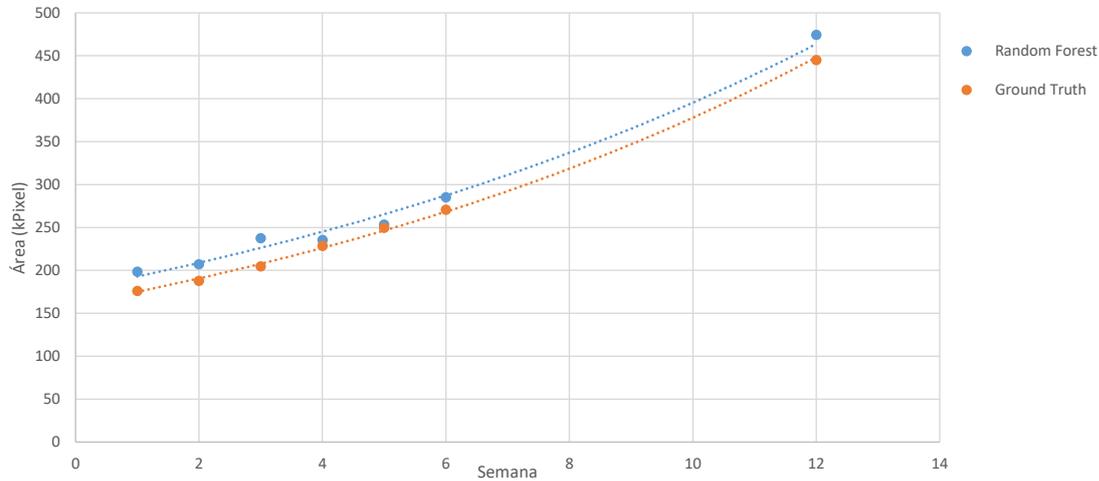


Figura 6.4: Comparação da evolução da área estimada pelo do método desenvolvido com a área determinada pelo *ground truth* do recipiente 20.

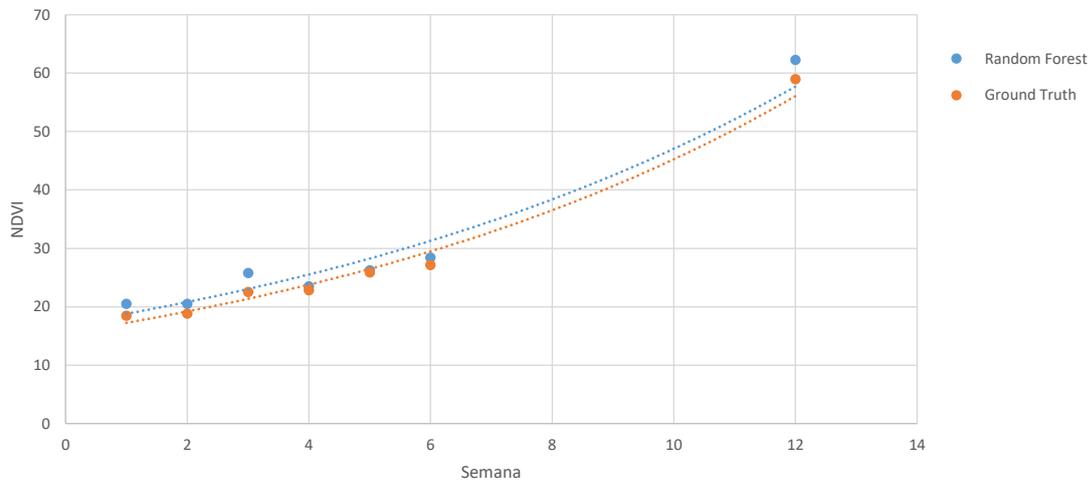


Figura 6.5: Comparação da evolução do NDVI médio estimado pelo do método desenvolvido com o NDVI médio determinado pelo *ground truth* do recipiente 20.

6.2 Resultados

Durante o desenvolvimento do trabalho, na fase de aquisição foram adquiridas imagens de vários recipientes de culturas de plantas *in-vitro*. Apesar de terem as mesmas condições de cultura, os recipientes mostraram resultados diferentes ao longo do tempo. Nomeadamente, houve recipientes onde as plantas cresceram consideravelmente (figura 6.6),

outras em que este crescimento foi pequeno, e ainda houve um caso em que as plantas do recipiente secaram (figura 6.7). No final do período de cultura também existiram diferenças a nível da cor do meio de cultura de cada recipiente que se deve à acumulação de subprodutos da cultura.

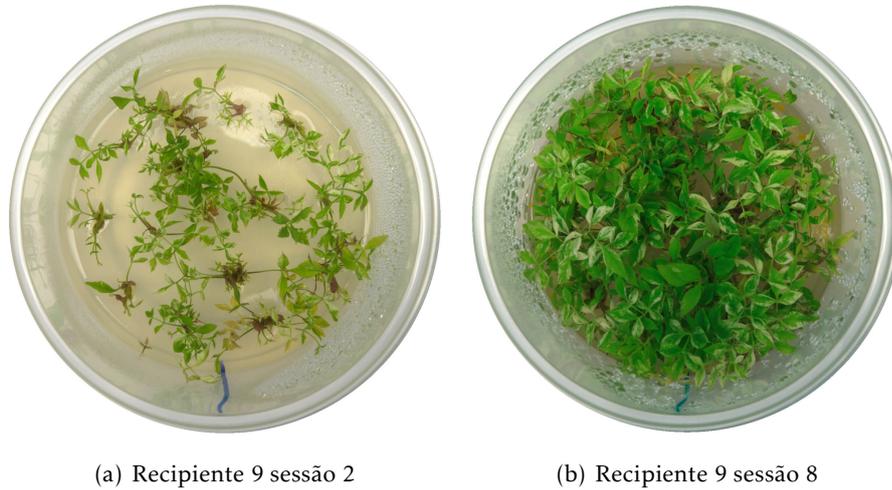


Figura 6.6: Segunda e última semana do recipiente 9. Este recipiente registou o terceiro maior crescimento.

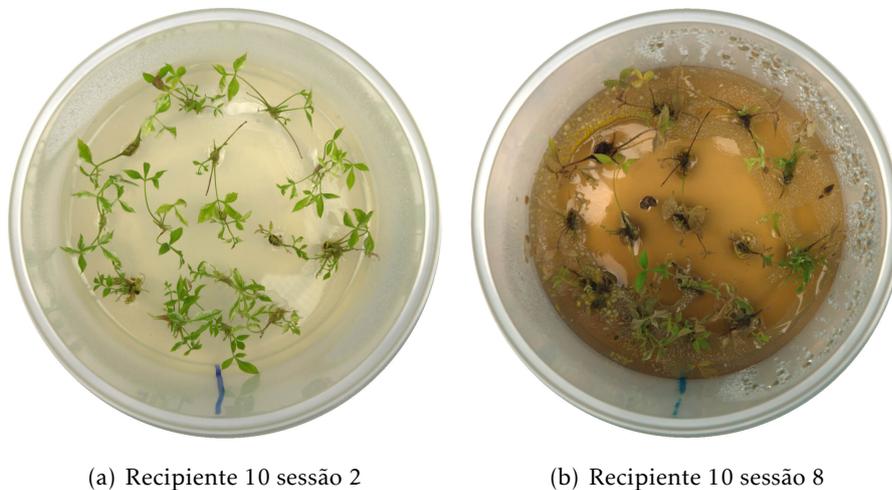


Figura 6.7: Segunda semana e última semana do recipiente 10. Neste recipiente as plantas morreram.

Através da aplicação desenvolvida, foram processadas todas as imagens de cada recipiente e foram extraídas a área e NDVI médio da planta segmentada. A segmentação e a extração de informação não foram realizadas na primeira sessão devido à ausência de imagens do espectro infravermelho-próximo. Na figura 6.8 encontram-se as segmentações obtidas às imagens do recipiente 16. Com os dados da área e NDVI médio da planta extraídos de cada recipiente, foi traçada a evolução dos mesmos para cada recipiente ao

longo das semanas.

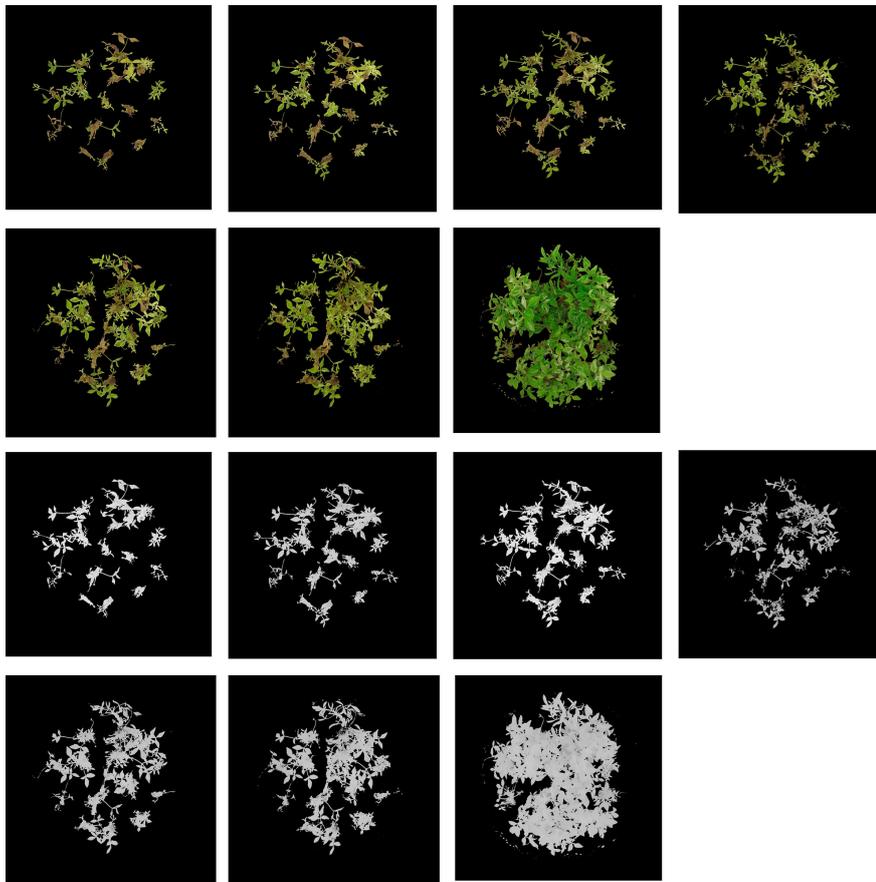


Figura 6.8: Imagens visíveis e infravermelho-próximo segmentadas do recipiente 16.

Na figura 6.9 é apresentada a evolução da área das plantas de cada recipiente *in-vitro* ao longo das semanas. Analisando a estimação da área das plantas pelo método proposto, a taxa de crescimento variou entre os mesmos recipientes, tendo uns um bom crescimento, outros com um baixo crescimento e até morte da planta. Na tabela 6.3 encontra-se a taxa de crescimento da área das plantas de cada recipiente entre a semana 1 e semana 12, obtido pela equação 6.1, onde V corresponde ao valor da área ou NDVI médio.

$$Taxa\ de\ crescimento = \frac{V_{12} - V_1}{V_1} \quad (6.1)$$

Ao analisar a taxa de crescimento das plantas *in-vitro*, temos em destaque a evolução do recipiente 16 que mostrou maior taxa de crescimento em área. Em seguida segue-se a evolução em área os recipientes 20, 9, 11 e 8. Os restantes obtiveram uma evolução inferior em especial o recipiente 10 que registou uma evolução negativa, uma vez que as plantas deste recipiente morreram. Com isto confirmamos que para as mesmas condições de culturas, obtivemos vários resultados no crescimento das plantas *in-vitro*.

A evolução do NDVI médio das plantas de cada recipiente *in-vitro* é detalhado no gráfico da figura 6.10 e a sua taxa de crescimento está também apresentado da tabela 6.3.

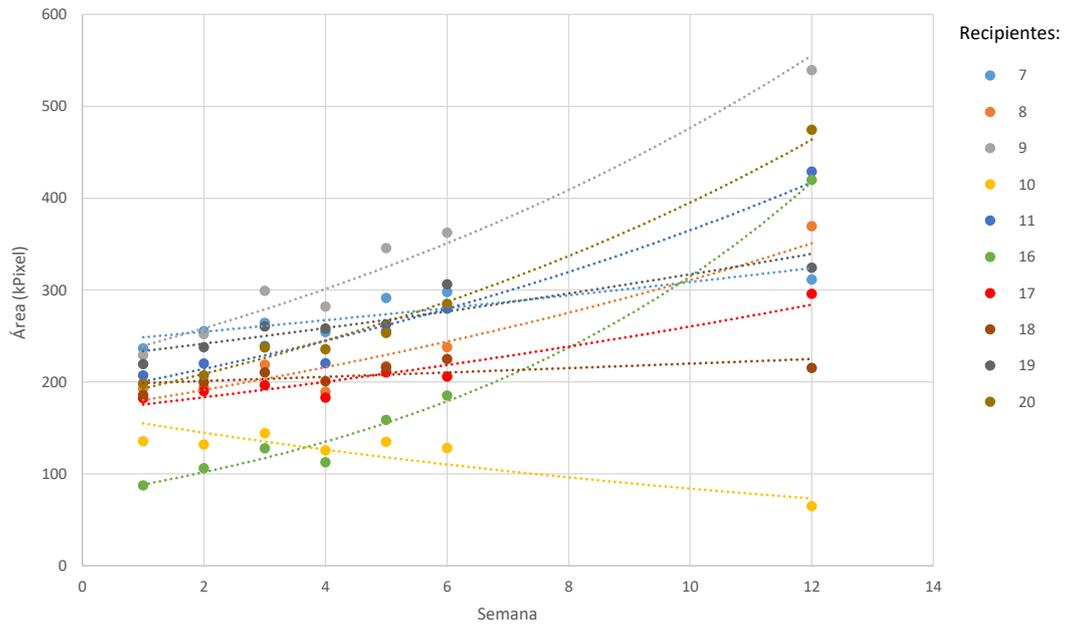


Figura 6.9: Estimação da evolução da área dos vários recipientes ao longo das semanas.

Verificamos que a taxa de crescimento das plantas acompanhou a taxa de crescimento da vitalidade das plantas dada pelo NDVI médio. Nos casos de maior crescimento das plantas em área, verificou-se também um grande crescimento no seu NDVI médio, pela mesma ordem. Ou seja, o recipiente 16 foi o que obteve novamente maior taxa de crescimento de NDVI médio, seguindo para os restantes na mesma ordem que foi obtida na área. Os recipientes cujas plantas *in-vitro* não mostraram grande evolução em área, o mesmo se verificou na evolução do NDVI médio. Para o caso do recipiente 10, onde se verificou a morte das plantas *in-vitro*, a sua evolução do NDVI médio foi negativa, indicando assim uma perda da vitalidade das plantas.

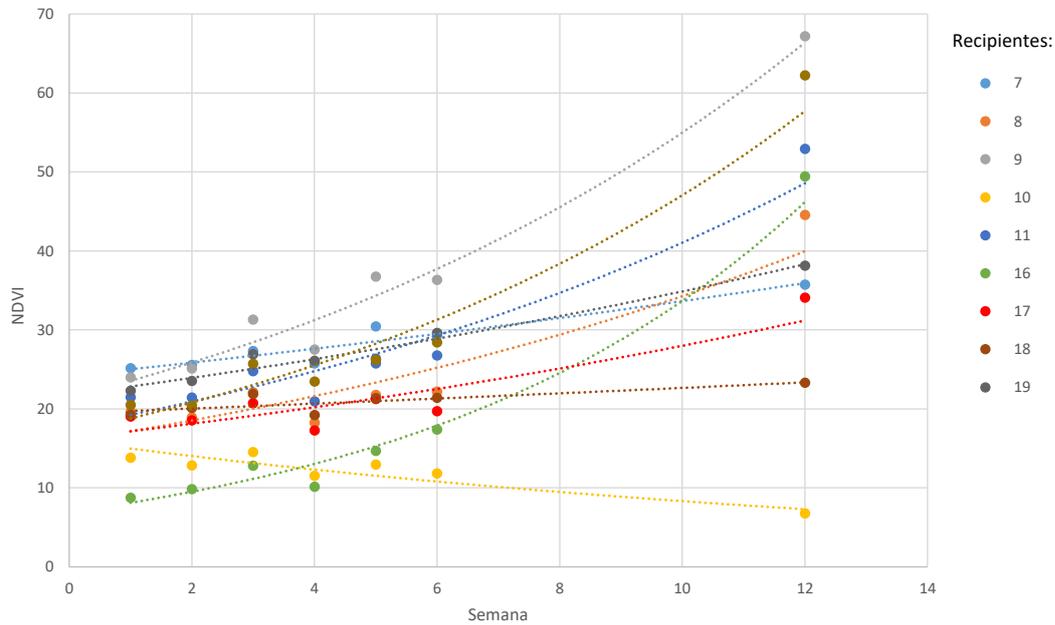


Figura 6.10: Estimação da evolução do NDVI médio dos vários recipientes ao longo das semanas.

Tabela 6.3: Taxa de crescimento da área e NDVI médio de cada recipiente entre a semana 1 e 12, ordenados do maior para o menor.

Recipiente	Evolução	
	Área (%)	NDVI médio (%)
16	380.53	463.07
20	138.87	203.71
9	135.28	180.06
11	106.90	146.30
8	91.47	126.71
17	62.32	79.81
19	47.76	70.89
7	31.63	42.21
18	15.81	21.02
10	-52.07	-51.03

CONCLUSÃO E TRABALHO FUTURO

7.1 Conclusão

Esta dissertação teve como objetivo o desenvolvimento de um conjunto de métodos de processamento digital de imagem para realizar o estudo da evolução de culturas de plantas *in-vitro*. Com os métodos desenvolvidos, é possível estimar a área e NDVI médio das plantas de um recipiente *in-vitro* e com isto traçar a sua evolução ao longo do tempo. Assim, especialistas podem realizar estudos para avaliar a performance da produção de plantas *in-vitro* em diferentes condições de crescimento, de modo a melhorar a produção para cada espécie.

Antes de desenvolver os métodos para a monitorização dos recipientes *in-vitro*, foram adquiridas imagens dos mesmos. Aquisição de imagem foi feita de vários recipientes de culturas de plantas *in-vitro* para realizar um estudo sobre as mesmas e desenvolver os métodos de processamento digital de imagem a partir destas imagens. Foram adquiridas ao longo de várias sessões de aquisição, imagens do espectro visível e infravermelho-próximo, através de máquinas fotográficas distintas. O primeiro espectro foi obtido tanto num perfil superior do recipiente como inferior, enquanto que o infravermelho-próximo foi obtido num perfil superior do recipiente. O uso das duas máquinas trouxe um grande desafio no alinhamento das imagens do espectro visível e infravermelho-próximo, não tendo sido totalmente ultrapassado pois não foi possível alinhar completamente os pares de imagens. Isto deveu-se ao movimento das plantas dentro dos recipientes *in-vitro* entre a aquisição do espectro visível e infravermelho-próximo. Só depois é que se realizava o mesmo processo o espectro infravermelho-próximo. Ao mover os recipientes entre a aquisição das imagens do espectro visível e infravermelho-próximo, ocorreram pequenas deslocações das folhas e caules, mudando em certas regiões a sua localização relativamente ao recipiente.

Os métodos de pré-processamento de imagem, segmentação e extração de informação

foram desenvolvidos em *matlab*, tendo os mesmos sido disponibilizados através de uma interface de utilizador para a análise de todas as imagens adquiridas. O pré-processamento de imagem foi usado para corrigir problemas de orientação, escala, alinhamento entre a imagem do espectro visível e infravermelho-próximo e isolamento do recipiente *in-vitro*. Para isso, este pré-processamento corrige a orientação das imagens e recorta a imagem à zona do recipiente. Depois, todas as imagens sofrem um ajuste de escala, de modo a que a área estimada em pixels esteja normalizada entre imagens. Para corrigir o alinhamento entre os pares de imagens visível e infravermelho-próximo recorreu-se ao uso das características locais SURF. Este passo não corrigiu completamente o alinhamento, pois apesar de várias regiões ficarem alinhadas corretamente, em outras regiões isto não acontece devido ao deslocamento das plantas entre a aquisição de cada espectro. Por fim, foi realizada uma correção de contraste nas imagens do espectro visível e o exterior do recipiente marcado com a cor magenta de modo a que o algoritmo de segmentação não apresente estes pixels à *random forest*.

Depois deste pré-processamento, as imagens foram segmentadas através de uma *random forest* treinada com um conjunto de treino selecionado manualmente. A escolha das características teve como base o estudo efetuado no estado da arte, nomeadamente em vários trabalhos realizados com o objetivo de segmentar plantas. Com esta segmentação, estimámos a evolução da área das plantas de cada recipiente e o seu NDVI médio.

A validação do método realizada a partir do *ground truth* criado manualmente mostrou que o trabalho permitiu alcançar uma boa performance com uma precisão de 96.9%, e uma taxa de falsos positivos de 3.1% e de falsos negativos de 3.3%. Muitas das ocorrências de falsos positivos e falsos negativos encontram-se na fronteira entre as plantas e o meio de cultura. Estima-se que pode ser devido à dificuldade em segmentar manualmente estas regiões, e o método proposto pode ter classificado corretamente estas regiões mas o nosso *ground truth* não possui uma classificação credível nestas zonas. Na validação da área e NDVI médio estimados, verificou-se que os valores encontram-se próximos dos valores obtidos pelo *ground truth*, com a mesma tendência de crescimento.

A nível de resultados obtidos da área de planta estimada e NDVI médio em cada recipiente, aconteceram situações de grande ou baixo crescimento e até morte das plantas. Contudo, verificou-se que a taxa de crescimento da planta acompanhou a taxa de crescimento da vitalidade da planta dada pelo NDVI médio. Como a planta está crescer, a sua área saudável também aumenta, levando ao incremento do valor médio do NDVI da mesma. No caso da planta que morre, como a área saudável diminui, o NDVI médio irá também diminuir e foi o que se verificou.

7.2 Trabalho futuro

Apesar dos resultados positivos na validação do nosso método, o trabalho desenvolvido nesta dissertação pode ser melhorado em vários aspetos e também receber novas funcionalidades.

7.2.1 Melhorar aquisição de imagem

Como era de esperar, a aquisição de imagem realizada provocou vários desafios e uma necessidade de pré-processamento de imagem mais complexo. Seria interessante o uso de uma máquina fotográfica que adquira e separe no mesmo instante o espectro visível do infravermelho-próximo em duas imagens. Com isto, o problema do alinhamento das imagens deixaria de existir, tornando desnecessário realizar o processo de alinhamento entre as duas imagens, reduzindo assim o pré-processamento.

7.2.2 Mais casos de estudo

Para podermos definitivamente retirar conclusões e comparar a performance da aplicação, seria interessante adquirir mais imagens de recipientes *in-vitro* em diferentes condições de cultura.

Com isto, também seria definitivamente interessante desenvolver métodos para estudar o perfil inferior obtido e adquirir outras vistas do recipiente, pois a área adquirida através do perfil superior é uma estimativa pessimista. Isto é, como as folhas ficam sobrepostas umas às outras à medida que vão crescendo, através do perfil superior acabamos por obter uma estimação da área inferior à real da planta.

7.2.3 Aumentar o ground truth

Apesar dos valores bastantes positivos das métricas de avaliação na validação do nosso método, é necessário aumentar o tamanho do conjunto *ground truth*, senão até segmentar manualmente todas as imagens para validar o nosso método com todos os recipientes usados. Este trabalho não foi possível realizar nesta dissertação, pois este processo é bastante moroso e exaustivo, visto que há grande quantidade de imagens adquiridas.

7.2.4 Afinar método desenvolvido

Pensando no tempo de execução de cada passo do pré-processamento, estes métodos poderão eventualmente ser melhorados de forma a que os mesmos durem menos tempo a executar. Um exemplo é a aplicação da transformada circular de Hough. As imagens inicialmente possuem uma grande zona a preto devido à objetiva usada, levando assim a um aumento no tempo de execução da transformada circular de Hough. Melhorias a isto são possíveis de se realizar, seja na redução da dimensão da imagem como um recorte inicial desta zona a preto para diminuir o tempo de execução.

Outro melhoramento que poderá ser realizado, é a inserção da fase de treino na interface do utilizador. A *random forest* foi treinada separadamente na aplicação *classification learner* do *matlab*, com o modelo a ser extraído. No entanto, esta aplicação permite também a extração de um *script* que realiza o processo de treino, tendo como parâmetros o conjunto de treino e retornando depois o modelo treinado. Seria interessante adicionar a

opção na interface do utilizador de poder treinar o método supervisionado, ficando este depois carregado na interface do utilizador.

7.2.5 Testar outros algoritmos de machine learning

Nesta dissertação aplicámos *random forest* para classificar corretamente pixels pertencentes à planta. No entanto, existem outros métodos de aprendizagem supervisionada e até não-supervisionada que poderão ser interessantes estudar e comparar com o desempenho obtido pela *random forest*. Podendo também ser incorporado na interface do utilizador a possibilidade de escolher qual o método de *machine learning* a executar para segmentar as imagens.

BIBLIOGRAFIA

- Atherton, T. J. e D. J. Kerbyson (1999). "Size invariant circle detection". Em: *Image and Vision Computing* 17.11, pp. 795–803. ISSN: 0262-8856. DOI: 10.1016/S0262-8856(98)00160-7.
- Bai, X. D., Z. G. Cao, Y Wang, Z. H. Yu, X. F. Zhang e C. N. Li (2013). "Crop segmentation from images by morphology modeling in the CIE L*a*b* color space". Em: *Computers and Electronics in Agriculture* 99, pp. 21–34.
- Ballard, D. H. (1981). "Generalizing the Hough transform to detect arbitrary shapes". Em: *Pattern Recognition* 13.2, pp. 111–122. ISSN: 0031-3203. DOI: 10.1016/0031-3203(81)90009-1.
- Barbedo, J. G. A. (2016). "A review on the main challenges in automatic plant disease identification based on visible range images". Em: *Biosystems Engineering* 144, pp. 52–60. DOI: 10.1016/j.biosystemseng.2016.01.017.
- Barbedo, J. G. A., L. V. Koenigkan e T. T. Santos (2016). "Identifying multiple plant diseases using digital image processing". Em: *Biosystems Engineering* 147, pp. 104–116. DOI: 10.1016/j.biosystemseng.2016.03.012.
- Bay, H., A. Ess, T. Tuytelaars e L. Van Gool (2008). "Speeded-Up Robust Features (SURF)". Em: *Computer Vision and Image Understanding* 110.3, pp. 346–359. ISSN: 10773142. DOI: 10.1016/j.cviu.2007.09.014.
- Breiman, L. (2001). "Random Forests". Em: *Machine Learning* 45.1, pp. 5–32. ISSN: 1573-0565. DOI: 10.1023/A:1010933404324.
- Breiman, L., J. Friedman, C. J. Stone e R. A. Olshen (1984). *Classification and regression trees*. CRC press.
- Burgos-Artizzu, X. P., A. Ribeiro, M. Guijarro e G. Pajares (2011). "Real-time image processing for crop/weed discrimination in maize fields". Em: *Computers and Electronics in Agriculture* 75.2, pp. 337–346.
- D. M. Woebbecke, G. E. Meyer, K. Von Bargen e D. A. Mortensen (1995). "Color Indices for Weed Identification Under Various Soil, Residue, and Lighting Conditions". Em: *Transactions of the ASAE* 38.1, pp. 259–269. ISSN: 2151-0059. DOI: 10.13031/2013.27838.
- Duarte, D. (2015). "Recuperação de imagem aérea usando fusão temporal de imagens". Master Thesis. FCT-UNL.

- Duda, R. O. e P. E. Hart (1972). "Use of the Hough Transformation to Detect Lines and Curves in Pictures". Em: *Commun. ACM* 15.1, pp. 11–15. ISSN: 0001-0782. DOI: 10.1145/361237.361242.
- Efron, B. e R. Tibshirani (1997). "Improvements on Cross-Validation: The 632+ Bootstrap Method". Em: *Journal of the American Statistical Association* 92.438, pp. 548–560. DOI: 10.1080/01621459.1997.10474007.
- Gonzalez, R. C. e R. E. Woods (2008). *Digital Image Processing*. 3ª ed. Pearson, p. 954. ISBN: 9780131687288.
- Guerrero, J. M., G Pajares, M Montalvo, J Romeo e M Guijarro (2012). "Support Vector Machines for crop/weeds identification in maize fields". Em: *Expert Systems with Applications* 39.12, pp. 11149–11155.
- Guijarro, M, G Pajares, I Riomoros, P. J. Herrera, X. P. Burgos-Artizzu e A Ribeiro (2011). "Automatic segmentation of relevant textures in agricultural images". Em: *Computers and Electronics in Agriculture* 75.1, pp. 75–83.
- Guo, W., U. K. Rage e S. Ninomiya (2013). "Illumination invariant segmentation of vegetation for time series wheat images based on decision tree model". Em: *Computers and Electronics in Agriculture* 96, pp. 58–66.
- Hague, T, N. D. Tillett e H Wheeler (2006). "Automated Crop and Weed Monitoring in Widely Spaced Cereals". Em: *Precision Agriculture* 7.1, pp. 21–32. DOI: 10.1007/s11119-005-6787-1.
- Hamuda, E., M. Glavin e E. Jones (2016). "A survey of image processing techniques for plant extraction and segmentation in the field". Em: *Computers and Electronics in Agriculture* 125, pp. 184–199. DOI: 10.1016/j.compag.2016.04.024.
- Hastie, T., R. Tibshirani e J. Friedman (2009). *The Elements of Statistical Learning*. Springer Series in Statistics. New York, NY: Springer New York. ISBN: 978-0-387-84857-0. DOI: 10.1007/978-0-387-84858-7.
- Ho, T. K. (1995). "Random decision forests". Em: *Proceedings of 3rd International Conference on Document Analysis and Recognition*. Vol. 1, 278–282 vol.1. DOI: 10.1109/ICDAR.1995.598994.
- Ho, T. K. (1998). "The random subspace method for constructing decision forests". Em: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 20.8, pp. 832–844. ISSN: 0162-8828. DOI: 10.1109/34.709601.
- Huete, A, K Didan, T Miura, E. P. Rodriguez, X Gao e L. G. Ferreira (2002). "Overview of the radiometric and biophysical performance of the MODIS vegetation indices". Em: *Remote Sensing of Environment* 83.1–2, pp. 195–213. DOI: 10.1016/S0034-4257(02)00096-2.
- Illingworth, J e J Kittler (1987). "The Adaptive Hough Transform". Em: *IEEE Transactions on Pattern Analysis and Machine Intelligence* PAMI-9.5, pp. 690–698. ISSN: 0162-8828. DOI: 10.1109/TPAMI.1987.4767964.
- Kataoka, T, T Kaneko, H Okamoto e S Hata (2003). "Crop growth estimation system using machine vision". Em: *Advanced Intelligent Mechatronics, 2003. AIM 2003. Proceedings*.

- 2003 IEEE/ASME International Conference on. Vol. 2, b1079–b1083 vol.2. DOI: 10.1109/AIM.2003.1225492.
- Li, L., Q. Zhang e D. Huang (2014). “A Review of Imaging Techniques for Plant Phenotyping”. Em: *Sensors* 14.11, pp. 20078–20111. DOI: 10.3390/s141120078.
- Lobet, G., X. Draye e C. Périlleux (2013). “An online database for plant image analysis software tools”. Em: *Plant Methods* 9.1, pp. 1–8. DOI: 10.1186/1746-4811-9-38.
- MacIntyre, H. L., T. M. Kana, T. Anning e R. J. Geider (2002). “Photoacclimation of photosynthesis irradiance response curves and photosynthetic pigments in microalgae and cyanobacteria”. Em: *Journal of Phycology* 38.1, pp. 17–38. DOI: 10.1046/j.1529-8817.2002.00094.x.
- Markwell, J., J. C. Osterman e J. L. Mitchell (1995). “Calibration of the Minolta SPAD-502 leaf chlorophyll meter”. Em: *Photosynthesis Research* 46.3, pp. 467–472. DOI: 10.1007/BF00032301.
- Menesatti, P, F Antonucci, F Pallottino, G Rocuzzo, M Allegra, F Stagno e F Intrigliolo (2010). “Estimation of plant nutritional status by Vis-NIR spectrophotometric analysis on orange leaves [Citrus sinensis (L) Osbeck cv Tarocco]”. Em: *Biosystems Engineering* 105.4, pp. 448–454.
- Meyer, G. E. e J. C. Neto (2008). “Verification of color vegetation indices for automated crop imaging applications”. Em: *Computers and Electronics in Agriculture* 63.2, pp. 282–293.
- Meyer, G. E., T. W. Hindman e K. Laksmi (1999). “Machine vision detection parameters for plant species identification”. Em: *Proc. SPIE*. Vol. 3543, pp. 327–335. DOI: 10.1117/12.336896.
- Meyer, G. E., J. C. Neto, D. D. Jones e T. W. Hindman (2004). “Intensified fuzzy clusters for classifying plant, soil, and residue regions of interest from color images”. Em: *Computers and Electronics in Agriculture* 42.3, pp. 161–180.
- MODIS. URL: <http://modis.gsfc.nasa.gov/> (acedido em 18/07/2016).
- Mohanty, S. P., D. P. Hughes e M. Salathé (2016). “Using Deep Learning for Image-Based Plant Disease Detection”. Em: *Frontiers in Plant Science* 7. ISSN: 1664-462X. DOI: 10.3389/fpls.2016.01419.
- Mohri, M. (2012). *Foundations of Machine Learning*. MIT Press. ISBN: 9780262018258.
- Mora, A., J. M. Fonseca e R. Ribeiro (2013). “Real-time image recovery using temporal image fusion”. Em: *2013 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*. IEEE, pp. 1–5. ISBN: 978-1-4799-0022-0. DOI: 10.1109/FUZZ-IEEE.2013.6622539.
- Otsu, N. (1979). “A threshold selection method from gray level histograms”. Em: *{IEEE} Trans. Systems, Man and Cybernetics* 9, pp. 62–66. DOI: 10.1109/TSMC.1979.4310076.
- Rokach, L. (2010). “Ensemble-based classifiers”. Em: *Artificial Intelligence Review* 33.1, pp. 1–39. ISSN: 1573-7462. DOI: 10.1007/s10462-009-9124-7.
- Samuel, A. L. (1959). “Some Studies in Machine Learning Using the Game of Checkers”. Em: *IBM Journal of Research and Development* 3.3, pp. 210–229. ISSN: 0018-8646. DOI: 10.1147/rd.33.0210.

- Smedt, F. D., I. Billauws e T. Goedemé (2011). “Neural Networks and Low-Cost Optical Filters for Plant Segmentation”. Em: *International Journal of Computer Information Systems and Industrial Management Applications (IJCISIM)* 3, pp. 804–811.
- Su, C.-H., C.-C. Fu, Y.-C. Chang, G. R. Nair, J.-L. Ye, I.-M. Chu e W.-T. Wu (2008). “Simultaneous estimation of chlorophyll a and lipid contents in microalgae by three-color analysis”. Em: *Biotechnology and Bioengineering* 99.4, pp. 1034–1039. DOI: 10.1002/bit.21623.
- Tillett, R. D., F. R. Brown, N. J. B. McFarlane, C. M. Onyango, P. F. Davis e J. A. Marchant (1990). “Image-guided robotics for the automation of micropropagation”. Em: *Intelligent Robots and Systems '90. 'Towards a New Frontier of Applications', Proceedings. IROS '90. IEEE International Workshop on*, 265–270 vol.1. DOI: 10.1109/IROS.1990.262396.
- Torres-Sánchez, J, J. M. Peña, A. I. de Castro e F López-Granados (2014). “Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV”. Em: *Computers and Electronics in Agriculture* 103, pp. 104–113.
- Viggiano, J. A. S. (2004). “Comparison of the accuracy of different white-balancing options as quantified by their color constancy”. Em: *Electronic Imaging 2004*. International Society for Optics e Photonics, pp. 323–333.
- Weier, J. e D. Herring (2000). *Measuring Vegetation (NDVI & EVI)*. URL: <http://earthobservatory.nasa.gov/Features/MeasuringVegetation/> (acedido em 18/07/2016).
- Woebbecke, D. M., G. E. Meyer, K. Von Bargen e D. A. Mortensen (1993). “Plant species identification, size, and enumeration using machine vision techniques on near-binary images”. Em: *Proc. SPIE*. Vol. 1836, pp. 208–219. DOI: 10.1117/12.144030.
- Wu, Y. Y., X. Y. Yang, P. P. Li e Z Liang (2009). “The technique of the acquiring dynamic information on the growth of plantlets in vitro”. Em: *2009 International Conference on Future BioMedical Information Engineering (FBIE)*, pp. 13–16. DOI: 10.1109/FBIE.2009.5405855.
- Yadav, S. P., Y. Ibaraki e S Dutta Gupta (2010). “Estimation of the chlorophyll content of micropropagated potato plants using RGB based image analysis”. Em: *Plant Cell, Tissue and Organ Culture (PCTOC)* 100.2, pp. 183–188. DOI: 10.1007/s11240-009-9635-6.
- Yao, X, W. Du, S. Feng e J. Zou (2010). “Image-based plant nutrient status analysis: An overview”. Em: *Intelligent Computing and Intelligent Systems (ICIS), 2010 IEEE International Conference on*. Vol. 1, pp. 460–464. DOI: 10.1109/ICICISYS.2010.5658601.
- Ye, M., Z. Cao, Z. Yu e X. Bai (2015). “Crop feature extraction from images with probabilistic superpixel Markov random field”. Em: *Computers and Electronics in Agriculture* 114, pp. 247–260.
- Yu, Z., Z. Cao, X. Wu, X. Bai, Y. Qin, W. Zhuo, Y. Xiao, X. Zhang e H. Xue (2013). “Automatic image-based detection technology for two critical growth stages of maize: Emergence and three-leaf stage”. Em: *Agricultural and Forest Meteorology* 174–175, pp. 65–84.

- Yuen, H., J. Princen, J. Illingworth e J. Kittler (1990). "Comparative study of Hough Transform methods for circle finding". Em: *Image and Vision Computing* 8.1, pp. 71–77. ISSN: 02628856. DOI: 10.1016/0262-8856(90)90059-E.
- Zheng, L., J. Zhang e Q. Wang (2009). "Mean-shift-based color segmentation of images containing green vegetation". Em: *Computers and Electronics in Agriculture* 65.1, pp. 93–98.
- Zheng, L., D. Shi e J. Zhang (2010). "Segmentation of green vegetation of crop canopy images based on mean shift and Fisher linear discriminant". Em: *Pattern Recognition Letters* 31.9, pp. 920–925.
- Zheng, S., S. Jayasumana, B. Romera-Paredes, V. Vineet, Z. Su, D. Du, C. Huang e P. H. S. Torr (2015). "Conditional Random Fields as Recurrent Neural Networks". Em: *The IEEE International Conference on Computer Vision (ICCV)*.

