



INSTITUTO
UNIVERSITÁRIO
DE LISBOA

Sistema de Análise de Stress Hídrico para Aplicação em Vinha Suportado por Drones

João Francisco Diogo Almeida Lopes Martins

Mestrado em Engenharia de Telecomunicações e Informática

Orientador:

Prof. Dr. Pedro Joaquim Amaro Sebastião, Professor Auxiliar,
ISCTE – Instituto Universitário de Lisboa

Co-Orientador:

Prof. Dr. António Sérgio Lima Raimundo, Assistente Convidado,
ISCTE – Instituto Universitário de Lisboa

Novembro, 2020



TECNOLOGIAS
E ARQUITETURA

Departamento de Ciências e Tecnologias da Informação

Sistema de Análise de Stress Hídrico para Aplicação em Vinha Suportado por Drones

João Francisco Diogo Almeida Lopes Martins

Mestrado em Engenharia de Telecomunicações e Informática

Orientador:

Prof. Dr. Pedro Joaquim Amaro Sebastião, Professor Auxiliar,
ISCTE – Instituto Universitário de Lisboa

Co-Orientador:

Prof. Dr. António Sérgio Lima Raimundo, Assistente Convidado,
ISCTE – Instituto Universitário de Lisboa

Novembro, 2020

Agradecimentos

Gostaria de agradecer à minha família e à minha namorada pelo apoio e confiança constantes. Desempenharam um papel muito importante, pois contribuíram para que eu me sentisse sempre motivado e empenhado.

Um grande agradecimento ao meu orientador, Professor Pedro Sebastião, todo o apoio e transmissão de conhecimentos, no meu trabalho e na vida pessoal, sempre disponível para ajudar e incentivando-me a fazer mais e melhor.

Ao meu co-orientador, António Raimundo, estou muito grato pela sua disponibilidade e pelos seus conselhos que foram importantíssimos para o desenvolvimento desta dissertação.

Um grande obrigado à Skyverse, ao Ricardo Silva e ao António Raimundo, foram sem dúvida fundamentais na fase da recolha das imagens térmicas, ao emprestarem o drone e a câmara térmica para sobrevoar as vinhas e ainda se deslocaram ao local para a recolha dos dados. Permitiram assim que esta dissertação fosse possível de realizar.

Ao Eng. Nuno Ramalho, quero agradecer o incansável apoio, pois esteve sempre disponível para colaborar. O Eng. foi o contacto para termos acesso às vinhas fotografadas, mostrou sempre disponibilidade e prontidão para que este trabalho fosse concluído com sucesso. Acompanhou o dia da recolha dos dados do início ao fim.

Quero agradecer aos meus colegas Rodrigo Cortesão, Miriam Batista, João Monge, Mariana Barros, Daniel Fernandes e João Pavia pelo companheirismo, ajuda e conselhos que me deram ao longo desta jornada.

Aos meus amigos de longa data, quero agradecer a amizade, confiança e apoio que sempre me deram.

Resumo

Atualmente, a Inteligência Artificial (IA) e o sub-campo *Machine Learning* (ML) estão em constante desenvolvimento e procura por parte de diferentes áreas científicas. Neste caso, ocorreu uma fusão entre a IA e a agricultura, especificamente na vertente da viticultura.

Esta dissertação apresenta um sistema composto por um drone com uma câmara térmica acoplada, que foi usada para sobrevoar vinhas, para obter fotografias (imagens) térmicas. Estas imagens contêm leituras de temperatura da vinha e do solo em cada pixel, de modo a analisar as regiões que contêm valores baixos de temperatura, que representam zonas com alta concentração de humidade.

O objetivo deste trabalho é implementar um algoritmo de *Machine Learning* para detetar e localizar áreas de humidade nas imagens térmicas. Este sistema tem duas características principais: a alta resolução da câmara térmica, pois permite saber exatamente a temperatura em qualquer local da imagem; A utilização de um algoritmo de *Machine Learning* para classificar as regiões automaticamente com excesso de níveis de humidade.

Após a realização de vários testes, o algoritmo obteve resultados na ordem dos 82% de precisão, o que demonstrou uma performance satisfatória para o alcance do objetivo proposto.

Esta classificação é muito útil na agricultura de precisão, a fim de otimizar os recursos hídricos usados na rega da cultura agrícola, poupando assim água, energia e colaborando com uma atitude em prol da sustentabilidade e na tomada de decisão dos agricultores.

Palavras-chave: Drone, Imagens térmicas, Redes Neurais Convolucionais, Detecção de Humidade, Poupança de Água, Viticultura.

Abstract

The Artificial Intelligence (AI) and the Machine Learning (ML) subfield are currently in constant development and demand from different scientific areas. In this case, a merger between AI and agriculture took place, specifically in the field of viticulture.

This dissertation presents a system composed by a drone with an attached thermal camera, which was used to fly over vineyards taking thermal images. These images contain vine and soil temperature readings on each pixel, in order to analyse the regions containing low temperature values, which show areas with a high concentration of humidity.

The objective of this work is to implement a Machine Learning algorithm to detect and locate areas of humidity in thermal images. This system has two main features: the high resolution of the thermal camera, as it allows to know exactly the temperature anywhere in the image area; and the use of a Machine Learning algorithm to automatically classify regions with an excess of humidity levels.

After several tests, the algorithm obtained results of around 82% accuracy, which showed a satisfactory performance in achieving the proposed objective.

This classification is very useful in precision agriculture, in order to optimise the water resources used in crops irrigation, thus saving water and energy and it contributes to an attitude towards sustainability and supports farmers' decision making.

Keywords: Unmanned Aerial Vehicle (UAV), Thermal Images, Convolutional Neural Network, Humidity Detection, Water saving, Viticulture.

Conteúdo

Agradecimentos	iii
Resumo	v
Abstract	vii
Lista de Figuras	xiii
Lista de Tabelas	xv
Lista de Acrónimos	xvii
Capítulo 1. Introdução	1
1.1. Motivação e Enquadramento	1
1.2. Objetivos	1
1.3. Questões de Investigação	2
1.4. Métodos de Investigação	2
Capítulo 2. Estado de Arte	5
2.1. Agricultura e Viticultura de Precisão	5
2.2. Componentes do Sistema	10
2.2.1. Veículo Aéreo Não Tripulado - VANT ou Drone	10
2.2.2. Sensores de deteção	11
2.3. Análise e Processamento de Imagem	12
2.3.1. Visão Computacional	12
2.3.2. <i>Machine Learning</i>	13
2.3.2.1. Redes Neurais Artificiais - RNA	14
2.3.2.2. <i>Deep Learning</i>	14
2.3.3. Algoritmo para Deteção de Humidade	16
Capítulo 3. Análise de Stress Hídrico	19
3.1. Importância da análise ao stress hídrico	19
3.2. Sensor - Câmara Térmica	19

3.3. Drone - <i>Quadcopter</i>	20
Capítulo 4. Detecção Automática de Humidade Suportada em Redes Neurais Convolucionais	25
4.1. Redes Neurais Convolucionais	25
4.1.1. <i>Dataset</i>	26
4.1.2. Parâmetros de Configuração da RNC	26
4.1.2.1. Função Perda - <i>Loss Function</i>	27
4.1.2.2. Exatidão	27
4.1.2.3. Otimização	28
4.1.2.4. <i>Batch Size</i>	28
4.1.2.5. Número de Épocas	28
4.1.2.6. <i>Learning Rate</i>	28
4.1.2.7. Data Augmentation	29
4.1.2.8. Função de Ativação	30
4.1.3. Tipos de Arquitetura de RNC	30
4.1.3.1. <i>MobileNet</i>	31
4.1.3.2. <i>ResNet</i>	31
4.1.3.3. <i>Inception</i>	31
4.1.4. Detetores	32
4.1.4.1. <i>SSD - Single Shot MultiBox Detector</i>	32
4.1.4.2. <i>Faster R-CNN</i>	32
4.1.4.3. <i>YOLO - You only look once</i>	33
Capítulo 5. Testes e Resultados	35
5.1. Recolha dos dados	35
5.2. Tratamento dos dados	37
5.2.1. <i>Input</i> da Rede	37
5.2.2. Configuração da RNC	38
5.2.2.1. Classificação Manual: <i>LabelImg</i> e <i>FLIR Tools</i>	38
5.2.2.2. Ferramentas: <i>TensorFlow</i> e <i>Keras</i>	39
5.2.2.3. Parâmetros: Detetor e Modelo	41
5.2.3. Treino da RNC	42
5.3. Resultados	43
5.3.1. Performance Final	43

5.3.2. Reconstrução 2D do terreno analisado	45
5.4. Poupança de Água	45
Capítulo 6. Conclusão	47
6.1. Principais Conclusões	47
6.2. Trabalho Futuro	49
Referências	51
Apêndice A. Registo do dia da recolha de dados	57
Apêndice B. Artigo da Dissertação	59

Lista de Figuras

2.1	Diagrama de Vantagens da Utilização da VP	7
2.2	Exemplo de Drone de Asa fixa	11
2.3	Exemplo de Drone Multi-motor	11
2.4	Espectro Electromagnético	12
2.5	Etapas da Visão Computacional	13
2.6	Composição de uma Rede Neuronal	15
2.7	Funcionamento de uma Rede Neuronal Convolutacional	15
2.8	Funcionamento de uma Rede Neuronal Recorrente	16
3.1	Ilustração do Processo que Ocorre no Terreno	19
3.2	Importância da Análise ao stress Hídrico na Viticultura	22
3.3	<i>Skyverse</i> - Câmara Térmica - <i>FLIR Vue Pro R</i>	23
3.4	Fotografia das videiras/solo com as Temperaturas Representadas através de diferentes cores	23
3.5	<i>Skyverse</i> - Drone <i>Quadcopter</i>	24
4.1	Zonas seleccionadas com os tons de azul escuro	25
4.2	<i>Underfitting e Overfitting</i>	29
4.3	Função de Ativação	30
4.4	<i>Mobilenet e SSD</i>	33
4.5	Detetor <i>Faster R-CNN</i>	33
5.1	Localização de Lisboa e Ponte de Sor - Distância 140km	36
5.2	Vinha A-1	36
5.3	Vinha A-2	37
5.4	Vinha B	38
5.5	Imagem classificada com as zonas de humidade excessiva delimitadas por <i>bounding boxes</i>	39
5.6	Imagem ilustrativa do critério para a classificação	40
5.7	Construção do Modelo Final	41

Lista de Figuras

5.8	Gráfico representativo da curva de aprendizagem do algoritmo	42
5.9	Resultados da avaliação à performance final do algoritmo	43
5.10	Deteção e localização efetuada pelo algoritmo numa imagem térmica	44
5.11	<i>Non Maximum Suppression</i>	45
5.12	Reconstrução 2D de uma das áreas fotografadas	46
6.1	Dados da Vinha	47
6.2	Litros de água gastos anualmente numa vinha com 50 ha	48
A.1	Drone em voo	57
A.2	Drone em voo sobre uma das vinhas	57
A.3	Drone em posição de aterragem e descolagem	58
A.4	Drone em posição de aterragem e descolagem sobre um tapete	58
A.5	Paisagem de uma das vinhas fotografadas	58
A.6	Mecanismo de controlo do drone composto por um <i>tablet</i> e um comando .	58
B.1	Artigo - Página 1	59
B.2	Artigo - Página 2	60
B.3	Artigo - Página 3	61
B.4	Artigo - Página 4	62
B.5	Artigo - Página 5	63

Lista de Tabelas

2.1 Comparação de sensores	11
3.1 Características da câmara térmica	20
3.2 Características do drone	20

Lista de Acrónimos

AP	Agricultura Precisão
BCE	Binary Cross Entropy
CCE	Categorical Cross Entropy
DL	Deep Learning
FPS	Frame Por Segundo
GPS	Global Positioning System
GNSS	Global Navigation Satellite System
IMU	Inertial Measurement Unit
IA	Inteligência Artificial
ML	Machine Learning
MP	Mega Pixel
NIR	Near Infra Red
NMS	Non Maximum Suppression
RGB	Red Green Blue
RNA	Rede Neuronal Artificial
RNR	Rede Neuronal Recorrente
RNC	Rede Neuronal Convolutacional
RPN	Region Purposal Networks
SSD	Single Shot Multibox
SVM	Support Vector Machine
TF	Tensor Flow
VANT	Veículo Aéreo Não Tripulado
VC	Visão Computacional
VP	Viticultura Precisão

Lista de Acrónimos

Wi-Fi

Wireless Fidelity

WSN

Wireless Sensor Networks

YOLO

You Only Look Once

CAPÍTULO 1

Introdução

1.1. Motivação e Enquadramento

A tecnologia está cada vez mais presente em todas as ações do nosso quotidiano com o objetivo de auxiliar o ser humano na ação em questão. Presentemente, a tecnologia está acessível a todas as classes sociais, existe uma necessidade e exigência de atualização e especialização por parte do ser humano com a preocupação de evoluir.

Um Veículo Aéreo Não Tripulado (VANT ou drone) é um instrumento da tecnologia aérea/exatidão que está em crescente desenvolvimento em vários setores da economia, mais precisamente no setor da agricultura-viticultura. Este dispositivo, em conjunto com sensores específicos (câmaras térmicas, multiespectrais e hiperespectrais), ao sobrevoar as fileiras das vinhas, proporciona uma análise alternativa ao solo e uma visão de um determinado ângulo, o que não seria executável com os métodos tradicionais.

A falta de controlo sobre as vinhas, as dificuldades no controlo de doenças e pragas, a aplicação excessiva de fitofármacos, o uso excessivo de recursos hídricos e ausência do mesmo, a produção pouco otimizada e o desperdício monetário, são as principais razões para os problemas existentes atualmente na viticultura. Contudo, com o auxílio de drones e de sensores adicionais associados a algoritmos inteligentes, os desafios deste setor podem ser (de forma eficaz e eficiente) resolvidos. Esta configuração permite baixar os custos operacionais, conseguindo-se obter alta resolução espacial de imagens, permitindo também obter imagens, não só do espectro visual como do espectro infravermelho e uma alta flexibilidade operacional.

1.2. Objetivos

Esta dissertação visa desenvolver um sistema inteligente, suportado por um drone e um sensor específico, nomeadamente uma câmara térmica que irá sobrevoar as fileiras das vinhas com a finalidade de recolher dados (imagens térmicas). Numa fase posterior, procede-se à análise e processamento das imagens e desenvolveu-se um algoritmo de inteligência artificial irá classificar e localizar zonas de humidade excessiva que se encontrem

Capítulo 1. *Introdução*

na vinha. O objetivo deste sistema consiste em avaliar as videiras e o solo tendo em conta as seguintes situações:

- Análise de stress hídrico;
- Detecção de regiões com excesso de água;
- Análise comparativa na poupança de água.

Para se conseguir atingir este objetivo geral pretende-se desenvolver o seguinte conjunto de objetivos específicos:

- Configuração do sensor para otimização de *input* para o algoritmo;
- Desenvolvimento de um algoritmo eficiente de análise/detecção para apoio à decisão;
- Validação do algoritmo;

Atendendo aos aspetos supra apresentados, será possível monitorizar e controlar a produção vitícola ao nível do stress hídrico através da sua avaliação, ou seja, controlar a quantidade de água que uma vinha necessita e por outro lado, que não exista excesso de água colocando em risco a qualidade da produção.

1.3. Questões de Investigação

Com o objetivo de validar esta contribuição científico-académico, considerando as questões da solução proposta, apresentam-se as seguintes questões de investigação.

- Existem riscos associados a esta solução ? Se sim, quais? ;
- Quais são as metodologias e ou ferramentas que melhor se adequam para desenvolver o sistema proposto? ;
- Será que a solução adotada a nível dos sensores utilizados irá permitir alcançar os objetivos propostos? .

1.4. Métodos de Investigação

- Identificar o problema
 - Esta etapa passa por investigar os problemas que os proprietários das vinhas possuem quando estão perante casos de stress hídrico. Haverá a necessidade de definir o que é que constitui um problema para os produtores, que neste caso será identificar e localizar as zonas que contém excesso de humidade.
- Identificar tecnologias que irão resolver o problema

Capítulo 1. *Introdução*

- Perante o ponto anterior, este passo permite fazer um levantamento das possíveis tecnologias existentes que são excelentes candidatas a resolver o problema supra apresentado.
- Desenvolvimento e implementação de um sistema de deteção e análise de stress hídrico
 - Após identificadas e escolhidas as tecnologias, este item servirá para proceder à criação de uma solução, que consiste no desenvolvimento do sistema a implementar de modo a cumprir com os objetivos propostos nesta dissertação.
- Apoio à tomada de decisão do viticultor
 - A solução proposta permitirá ajudar um possível agricultor na resolução de problemas relacionados com a água disponibilizada à sua vinha com base nos resultados do sistema desenvolvido.

CAPÍTULO 2

Estado de Arte

2.1. Agricultura e Viticultura de Precisão

A agricultura é responsável pela utilização de uma parte significativa dos recursos hídricos disponíveis em todo o mundo (cerca de 70%) [1]. Em Portugal, existem 189.000 ha de vinha e é a 4^a maior área de vinha da Europa. Representa 2% do território nacional e contribui com um volume de negócios para o país de 1282 M€. A indústria do vinho tem um enorme impacto para o desenvolvimento económico de Portugal. Um dos grandes fatores que afeta negativamente o setor do vinho é o stress hídrico, que corresponde ao excesso ou défice de água em determinadas zonas da vinha. Uma vinha desidratada irá ter uma quebra na produção de fruto, por outro lado uma vinha com excesso de água terá problemas sanitários, uma vez que as doenças desenvolvem-se melhor em ambientes mais húmidos. O stress hídrico está inteiramente relacionado com a produção da vinha e com a qualidade da uva [2] [3].

Na Europa, uma das abordagens tradicionais para detetar e localizar humidade ou a ausência da mesma é colocar sensores remotos em torres sobre os campos agrícolas, em que a principal limitação é a posição fixa a partir da qual os dados são recolhidos. Também são usadas aeronaves ou satélites, mas a resolução temporal e espacial limita a sua utilidade para avaliações agrícolas [1]. Uma tecnologia já bastante usada na agricultura é a criação de *Wireless Sensor Networks* (WSN), que consiste em colocar vários sensores no terreno, esses mesmos sensores enviam os dados recolhidos (por exemplo: valores de temperatura, humidade e pressão) para uma plataforma *online*, onde o agricultor tem acesso [4]. As WSN são dispendiosas e não são práticas quando se trata de grandes áreas, pois é necessário colocar uma grande quantidade de diferentes tipos de sensores para cobrir a área desejada e as várias particularidades do terreno [5] [6].

O avanço da tecnologia exige que o ser humano não fique estagnado no tempo, na medida em que este procure sempre uma solução o mais precisa e exata possível para os seus problemas. No setor da viticultura é de grande importância fazer um acompanhamento contínuo a fim de detetar zonas com stress hídrico, para que se possa agir oportunamente o quanto antes, no sentido de corrigir estas alterações ao nível da humidade, controlando

as variações dos níveis de água na vinha, de modo a que a produtividade seja afetada o menos possível. Existe então a necessidade de recorrer a sensores altamente sofisticados acoplados a drones, de forma a conseguir uma análise pormenorizada e detalhada com vista a potencializar a produção agrícola [5] [7].

A agricultura de precisão (AP) consiste em executar bem, na altura e tempo certos, na quantidade certa e no local exato. Hoje em dia, a alta tecnologia está a crescer e está a ganhar o seu espaço na vertente da agricultura, na medida em que já se consegue detetar inúmeras variáveis ao nível do clima, humidade, solo, estado vegetativo, necessidades das plantas, doenças e rendimento final [8] [9].

A fusão entre agricultura e a tecnologia vieram superar as limitações que existem nos métodos tradicionais, que por vezes são ineficientes para atender aos requisitos da cultura agrícola [10]. A AP permite gerir e analisar ao mais ínfimo pormenor a produção agrícola, desde a plantação em geral, à planta em si e ao fruto. Com a ajuda dos drones e dos sensores, consegue-se examinar com mais detalhe as folhas de uma videira e o solo onde esta se encontra plantada. O principal objetivo da AP é desenvolver estratégias de controlo e gestão que usam a tecnologia para obter informações, que por sua vez irão ajudar a tomada de decisão para a monitorização dos campos cultivados, com a meta de otimizar o produto final [1] [9] [11].

Utilizando técnicas inovadoras, é possível aplicá-las no âmbito da AP de modo a tornar os processos convencionais em processos mais eficientes, sustentáveis, eficazes e de rápida implementação. Estas medidas permitem ao utilizador final a deteção de zonas com stress hídrico, uma tomada de decisão assertiva, diminuir custos e consequentemente aumentar a produtividade [9] [12].

Viticultura de Precisão

A viticultura define-se pela ciência que estuda o cultivo da uva/vinha. A uva tem como finalidades a produção de vinho, a produção de néctares, consumo de uva de mesa e a produção de uva passa. Agregando a tecnologia ao ramo da viticultura, gera-se o conceito viticultura de precisão (VP), e que permite a implementação de um conjunto de métodos tecnológicos e desenvolvidos para responder à necessidade de maximizar o potencial enológico do território nacional e otimizar os consumos agronómicos da vinha, a fim de minimizar os custos e proteger a sustentabilidade ambiental.

Épocas críticas de stress hídrico poderão causar uma enorme quebra na produção final. Uma vinha sem os níveis mínimos de humidade começa a perder a folha, com ausência de

folha o processo de fotossíntese não irá ocorrer, e como consequência, não há produção de fruto. Por outro lado, se a vinha apresentar excessos de humidade, irá estar sujeita ao aparecimento de problemas sanitários nas suas plantas, pois as doenças desenvolvem-se e disseminam-se, mais rapidamente, em ambientes húmidos [3] [6] [13] [14].

A Figura 2.1 pretende esquematizar as vantagens da utilização da VP:

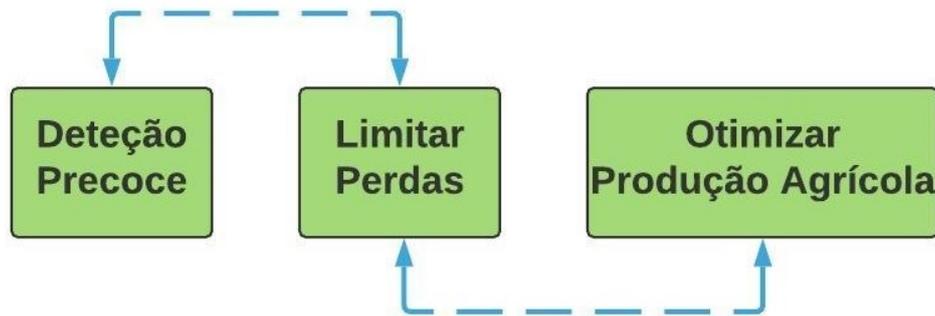


FIGURA 2.1. Diagrama de Vantagens da Utilização da VP

Em alguns países, os sistemas de VP são já amplamente utilizados, verificando-se mesmo casos nos quais a VP é aplicada para um tratamento muito personalizado das plantações, como por exemplo, a colocação de identificadores individuais, em cada videira. Estes sistemas resumem-se a múltiplos sensores ligados em rede. Tal como referido, o controlo e localização de zonas com stress hídrico, baseada em redes de sensores, é muita dispendiosa e pouco prática [15].

Um dos métodos de VP recorre à utilização de drones, que quando equipados com sensores de elevada precisão, é possível sobrevoar as culturas agrícolas e conseguir uma visão geral sobre os campos, o que é fundamental para uma análise específica e diferenciada. Processando as imagens geradas pelos sensores, consegue-se localizar o pretendido, de modo a controlar-se as zonas afetadas, com o objetivo de prevenir o quanto antes, mitigando os seus efeitos secundários.

Neste caso específico, é possível baixar os níveis de humidade ou repor os níveis mínimos desta variante, conforme a necessidade da vinha. A análise e controlo da humidade da vinha é a base para se conseguir regar na altura certa, com a quantidade certa e a duração certa [3] [16].

Utilizando a tecnologia da informação, é importante avaliar a variabilidade e diferenciação dos terrenos com exatidão, p.ex quanto ao nível da humidade. É uma boa prática

a irrigação em zonas específicas, tendo por base a necessidade real da cultura. Este mecanismo permite fazer uma otimização da água que é de extrema importância para a redução de custos (energia) do agricultor e para a sustentabilidade ambiental [10] [17] .

Seguem-se as etapas deste processo:

- Recolha de dados
- Processamento de dados
- Análise dos resultados
- Operação específica no terreno (Irrigação localizada)

Ambas as soluções (redes de sensores e análise via drone) são 2 métodos de VP. A vantagem que a utilização de drones tem, quando comparada com a solução de rede de sensores, é a não colocação de sensores localizados evitando assim gastos acrescidos, recursos humanos e tempo dispensado. A utilização de um drone permite sobrevoar uma área num curto espaço de tempo garantindo a recolha das imagens térmicas da vinha. O drone, por não necessitar de sobrevoar a grandes altitudes, permite obter imagens com uma maior resolução. A única desvantagem que o drone apresenta é a necessidade de vários voos para "cobrir" áreas maiores, pois a bateria utilizada permite um voo de aproximadamente 15 minutos [1].

A utilização dos drones equipados com os sensores de elevada precisão apresenta diversas vantagens na recolha de informação:

- Rápido de utilizar;
- Não destrutiva;
- Solução económica;
- Não intrusiva;
- Alta resolução espacial e temporal;
- Alta flexibilidade na aquisição de imagem;
- Fácil de transportar.

Atualmente, já existem várias empresas em Portugal a atuar nesta área. Através de mapas obtidos de imagens via satélite, é possível obter informações pormenorizadas dos campos cultivados possibilitando aos agricultores saber com rigor a quantidade de vegetação que está nos campos. Estes mapas, exibidos com códigos de cores, revelam o resultado da recolha de informação ao nível dos fatores ambientais, físicos e culturais que poderão prejudicar a cultura.

Numa perspetiva de *Internet of things*, existem projetos desenvolvidos direcionados para o possível uso de soluções móveis, comunicações sem fios, redes de sensores e imagens/vídeos digitais que utilizam um sistema de coordenadas georeferenciado, por exemplo, *Global Positioning System (GPS)* que suporta a tomada de decisão do agricultor em tempo real, seja qual for o lugar que este se encontre. No ano de 2010, uma empresa colocou mais de 1800 de sensores para verificar o nível de humidade do solo em vários locais e participou no controlo de regas automáticas. Os autores de [18], propõem a arquitetura de uma rede de sensores sem fios numa estufa de hortaliças, de modo a controlar-se a monitorização ambiental, ao nível da temperatura, humidade e iluminação. Também já existe uma rede de sensores sem fios que controlam as operações de um sistema de irrigação [4] [19].

Em [10], agregou-se uma rede de sensores sem fios a um drone. Este sistema foi aplicado para controlar uma das alterações climáticas - a geada. Uma particularidade deste sistema prende-se com o facto, de o drone ser a estação base móvel que assim garantirá a comunicação com os *clusters* (sensores espalhados pelo terreno).

Ao nível dos drones, em França,[20] [21] [22] usou-se um drone que transportava uma câmara multiespectral com o objetivo de encontrar zonas contaminadas na videira pela doença específica *Flavescence Dorée*. Utilizou-se uma Rede Neuronal Artificial (RNA) para classificar a doença. Investigadores da Universidade Federal de Viçosa (Brasil) utilizaram uma câmara térmica suportada por um drone com a finalidade de analisar a utilização das imagens térmicas para a localização de zonas infetadas por doenças nas produções agrícolas [5]. Em [6], investigou-se imagens áreas de videiras contaminadas captadas através de uma câmara *Red Green Blue (RGB)*. Neste método, os autores combinaram a utilização de uma RNA com imagens que continham diversos espaços de cores e índices de vegetação com o interesse de encontrarem sintomas de doenças nas plantas.

Em [23] e [24], sobrevoou-se e examinou-se videiras com o intuito de aumentar a eficiência da vigilância contra as pragas de insetos e detetar a doença *Filoxera* (doença muito comum nas vinhas) nas videiras. Este processo realizou-se com o auxílio de câmaras multiespectrais e hiperespectrais. No [22], utilizou-se uma câmara multiespectral para avaliar o estado da planta, onde também foi usada uma câmara RGB de alta resolução espacial para encontrar zonas sem vida (locais onde a planta já não produz fruto) nas videiras. Todas as câmaras estavam acopladas a um drone.

Existem estudos que comprovam que os drones são muito úteis na área da engenharia civil para a construção de mapas 3D, para fins de vigilância e inspeção [25] [26].

2.2. Componentes do Sistema

2.2.1. Veículo Aéreo Não Tripulado - VANT ou Drone

Os veículos aéreos não tripulados (VANT ou drone) são uma tecnologia bastante versátil. Na atualidade estão a ser cada vez mais utilizados em diversas áreas, tais como: proteção e vigilância da costa marítima, vigilância de florestas, cobertura de filmagens de eventos, mapeamento cartográfico de terrenos e entretenimento, entre outras. Existem programas de software desenvolvidos para se comunicar com o drone, com o objetivo do utilizador ter uma interface onde possa ler os dados recolhidos e também ter uma comunicação fiável com o drone [27].

Existem 2 diferentes modelos de drones, cada um deles tem a sua forma de descolar e aterrar, aerodinâmica e modo de atuar:

- **Asa fixa:** Este tipo de drones possuem uma aerodinâmica que nenhum outro modelo tem. Possuem 2 asas que facilitam bastante o cruzamento com o vento. Devido a esta própria característica conseguem atingir maiores velocidades e planar sem perder muita altura. Isso permite que haja um menor consumo de energia e muito mais autonomia para voos longos. Devido ao grande alcance, são mais utilizados para fins militares. Os drones de asa fixa descolam e aterram horizontalmente e não conseguem planar em determinadas posições como os outros drones [28];
- **Multi-motor:** Este drone não tem asas e consegue planar no ar parado (*hovering*), ao invés dos drones de asa fixa. A forma como se comporta é semelhante a um helicóptero, descolam-se e aterram verticalmente. Fazendo uma comparação com drones de asa fixa, estes voam em velocidades mais baixas mas têm um maior controlo de ação, o que é uma excelente particularidade. Devido a terem vários motores, consomem mais energia e têm menos autonomia. Os drones mais comuns deste tipo são os *tricopter*, *quadcopter*, *hexacopter* e *octocopter* [28].

Nas Figuras 2.2 e 2.3 apresentam-se os dois tipos de configuração de drones:

Qualquer configuração mencionada acima possui um conjunto de sensores integrados e instalados que permitem o correto controlo e comunicação do drone. São sensores de medição de inércias *Inertial Measurement Unit (IMU)*, que consistem em giroscópios e acelerómetros; sensores de navegação, tais como *Global Navigation Satellite System*



FIGURA 2.2. Exemplo de Drone de Asa fixa [28]



FIGURA 2.3. Exemplo de Drone Multi-motor [28]

(*GNSS*) e bússola; e módulos de comunicação, que podem utilizar diversas tecnologias, tais como *Wireless Fidelity (Wi-Fi)* e redes celulares (3G/4G) [28].

O drone que se irá utilizar é do tipo multi-motor, devido à análise pormenorizada que se pretende efetuar para a deteção de zonas com humidade nas videiras/solo. Não será necessário grandes altitudes de voo, no entanto será essencial bastante controlo e estabilidade do drone.

2.2.2. Sensores de deteção

Para se proceder à deteção de humidade foi necessário identificar alguns sensores. Porém, todos estes sensores possuem leituras diferentes e por sua vez têm comportamentos distintos na análise de imagens. A Tabela 2.1 apresenta uma comparação entre os vários tipos de sensores no que diz respeito às suas especificações:

TABELA 2.1. Comparação de sensores

Câmaras	Sony A6300	Flir Vue Pro	Micasense RedEdge-M
Espectro	Visível	Infravermelho	NIR, RedEdge, Visível
Resolução	25 MP	0.3 MP	—
Amostragem	30 FPS	9 FPS	1 P/S
Dimensão	120 x 66.9 x 48.8	57.4 x 44.4	87 x 59 x 45
Peso	404 g	113.4 g	231.9 g

A câmara Sony A6300, por se tratar de uma câmara RGB, apenas permite captar imagens do espectro visível. Visto que é imprescindível a deteção de temperaturas, de modo a identificar-se as zonas com humidade excessiva, onde as mesmas não são detetáveis a olho humano, esta câmara não é suficiente para o projeto de investigação.

A câmara multiespectral *Micasense RedEdge-M*, funcionando numa gama espectral diferente quando comparada com as câmaras RGB e de infravermelhos, ao emitir pulsos de radiação nos espectros electromagnéticos NIR (*Near Infrared* - limiar do espectro infravermelho) e *RedEdge* (limiar da banda do vermelho) consegue detetar, através do índice de refletância, uma doença ou anomalias que estejam a afetar a videira. Esta câmara é bastante sofisticada, contudo não cumpre os requisitos deste projeto.

Quanto à câmara térmica *Flir Vue Pro R*, esta já consegue detetar para além do espectro do visível. São usadas para detetar focos de calor ou ausência do mesmo (radiação no espectro do infravermelho). Isto traduz-se em análises de humidade dos solos e stress hídrico. Desta forma a câmara térmica reúne os requisitos pretendidos.

Atendendo a todos estes sensores, pode-se concluir que é necessário a utilização de uma câmara térmica para analisar o stress hídrico nas videiras, de modo a poder atingir os objetivos propostos.

A Figura 2.4 mostra o espectro electromagnético:

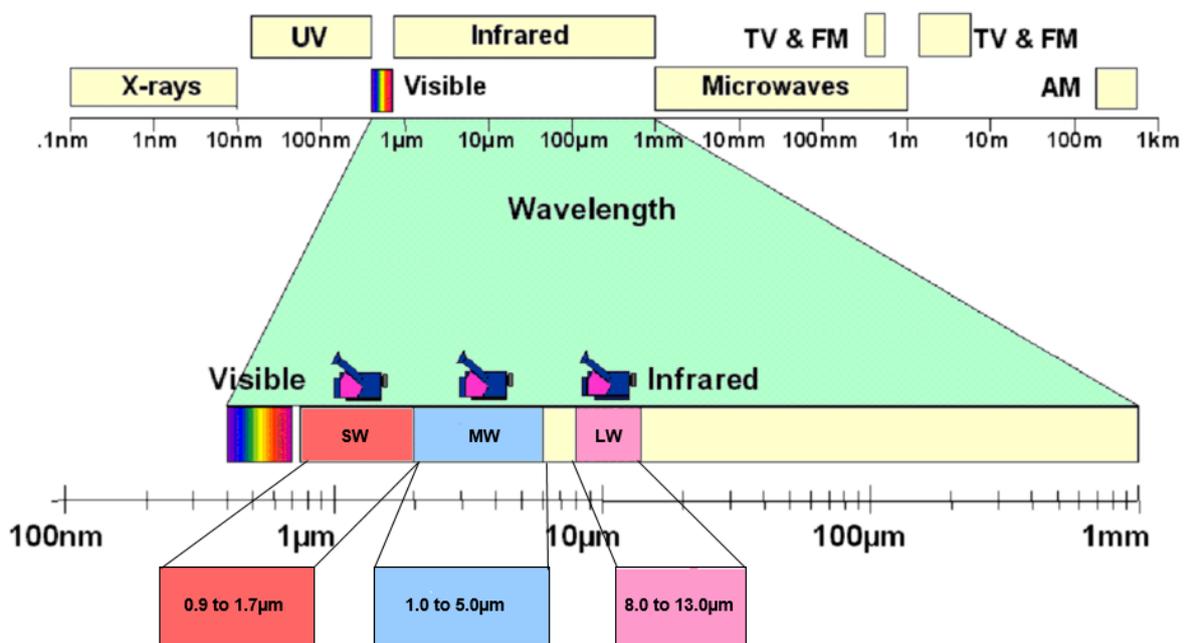


FIGURA 2.4. Espectro Electromagnético [29]

2.3. Análise e Processamento de Imagem

2.3.1. Visão Computacional

A visão computacional (VC) baseia-se na “visão” de máquinas e robôs, destina-se a investigar hipóteses e métodos, com o objetivo de recolher informações relevantes a partir de uma determinada imagem. Esta área da ciência tem como finalidade elaborar modelos computacionais idênticos ao campo visual humano que permitem diferenciar, alterar e examinar objetos que fazem parte da imagem, ou seja, partindo de imagens para alcançar modelos-tipo [30] [31]. O objetivo da VC é compreender o conteúdo das imagens digitais. Esta interpretação implica a extração de uma descrição da imagem, que pode ser um objeto, uma descrição de texto, um modelo tridimensional, entre outras.

A VC é distinta do processamento de imagens, uma vez que o processamento de imagens é o processo de criar uma nova imagem a partir de uma imagem existente, simplificando ou aprimorando o conteúdo de alguma forma. Este processo não se preocupa em perceber o conteúdo de uma imagem [32].

Na Figura 2.5 observa-se as etapas de um sistema de VC:

- **Aquisição** - Captura da imagem;
- **Pré-Processamento** - Retirar falhas e imperfeições;
- **Segmentação** - Dividir a imagem em regiões, consoante o que queremos detetar;
- **Extração de atributos** - Extrair atributos nas áreas segmentadas;
- **Identificação** - Identificação de padrões;
- **Banco de dados** - Relatório com as observações e os dados obtidos;

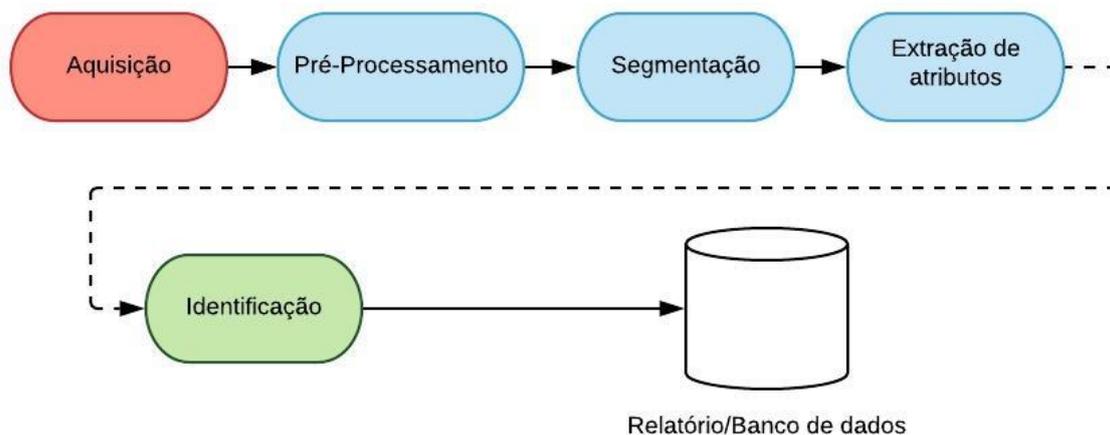


FIGURA 2.5. Etapas da Visão Computacional [33]

2.3.2. *Machine Learning*

O conceito *Machine Learning* (ML) é um sub campo da Inteligência Artificial, que se define pelo objetivo de fornecer conhecimento aos sistemas digitais através de dados e observações. Esse conhecimento adquirido permite que os sistemas identifiquem padrões e tomem decisões com uma mínima intervenção humana. ML é baseado em algoritmos que conseguem aprender com dados, por si mesmo, sem depender de programação baseada em regras [34] [35] [36].

Estes sistemas são úteis para os humanos porque, devido ao seu grande poder computacional de processamento, são capazes de encontrar mais rapidamente modelos em

grandes dados. ML é uma ferramenta que pode ser usada para melhorar a capacidade dos seres humanos de resolver problemas sobre uma vasta gama de problemas, desde ajudar a diagnosticar doenças até chegar a soluções para as alterações climáticas globais [34] [35] [36].

A maioria das indústrias que trabalham com uma grande quantidade de dados reconhecem a utilidade da tecnologia da ML, desde serviços financeiros, segurança pública e serviços públicos, setor dos transportes, automação industrial, setor da saúde e da energia [34].

2.3.2.1. Redes Neurais Artificiais - RNA. As RNA descrevem-se pela ciência cognitiva aplicada à teoria da aprendizagem de sistemas tecnológicos. As RNA são compostas por um conjunto de métodos que têm a capacidade de reconhecer relações, padrões e características comuns num determinado conjunto de dados através de um processo que se compara à forma de como o cérebro humano executa as suas tarefas. As RNA são constituídas por vários "neurónios", designados "nós". Estes são constituídos por uma função matemática que armazena e classifica os dados recebidos de acordo com critérios específicos. Uma RNA contém várias camadas de nós interligados. Um "nó" combina a entrada de dados com um conjunto de coeficientes, para que seja atribuído um grau de relevância aos dados em relação à tarefa que o algoritmo está a aprender [37] [38] [39]. Na Figura 2.6, apresenta-se o funcionamento interno de uma rede neuronal multi-camada que apresenta 3 nós na sua camada de *input*, 8 nós na camada intermédia e 2 nós na camada de *output*. Este exemplo de arquitetura de rede neuronal poderia ser usada, por exemplo, para efetuar classificações binárias (p.ex para a área da saúde, poder classificar células como cancerosas / não cancerosas).

2.3.2.2. Deep Learning. O conceito *Deep Learning* (DL) é o nome que caracteriza várias RNA interligadas, define-se como um sub campo da ML que correlaciona algoritmos baseados na estrutura e função do cérebro humano [41].

Deep Learning tem a capacidade de recolher e captar as características relevantes dos dados automaticamente. O termo *deep* refere-se ao número elevado de camada ocultas que as RNC contém. Este conceito caracteriza-se pela exatidão que consegue alcançar e também pela grande capacidade de resolver problemas complexos, no que diz respeito à extração de características em imagens [40] [42].

As Redes Neurais Convolucionais (RNC) é um dos algoritmos mais utilizados para DL, visto que tem a capacidade de aprender a executar tarefas de classificação diretamente

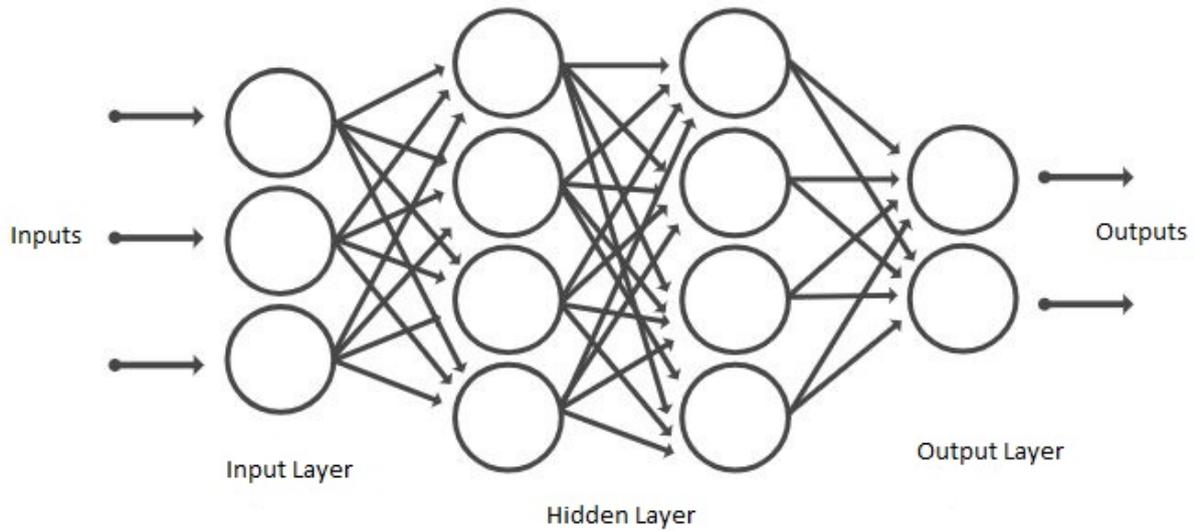


FIGURA 2.6. Composição de uma Rede Neuronal [40]

de imagens, vídeos, textos ou sons. Estas tem a capacidade de produzir os filtros de forma autónoma, conseguindo identificar padrões bastante pormenorizados que se ajustam a imperfeições e modificações geométricas [31] [43].

Na Figura 2.7 encontra-se representado o funcionamento de uma rede neuronal convolucional:

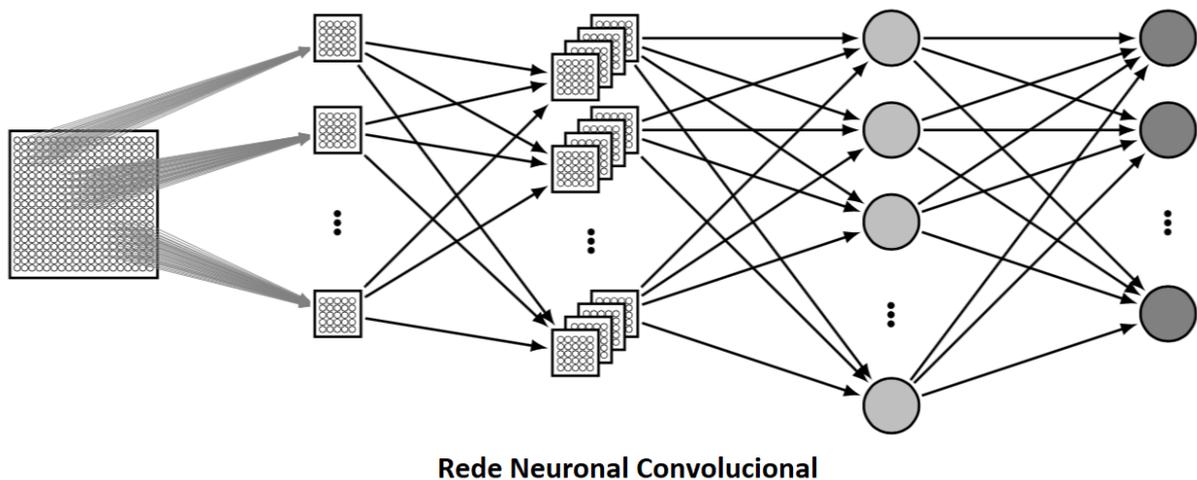


FIGURA 2.7. Funcionamento de uma Rede Neuronal Convolucional [44]

As Redes Neurais Recorrentes (RNR) são denominadas recorrentes devido a executarem a mesma tarefa, pelo menos 2 vezes, para cada elemento de uma sequência. Estas possuem uma memória que guarda informação sobre o que foi já calculado até ao

momento [45]. As RNR são diferentes das RNC pelo ciclo de informação estar sempre interligado às suas decisões anteriores em cada tarefa. Esta informação é guardada ao longo da sequência e irá afetar o processamento de cada novo elemento, fazendo um paralelismo com o ser humano, a memória e as suas vivências ao longo da vida irão afetar-lhe as suas próximas ações. [46].

As RNR são utilizadas para reconhecer padrões em sequências de dados, como texto, caligrafia, voz ou dados de séries numéricas.

Na Figura 2.8 encontra-se representado o funcionamento de uma rede neuronal recorrente:

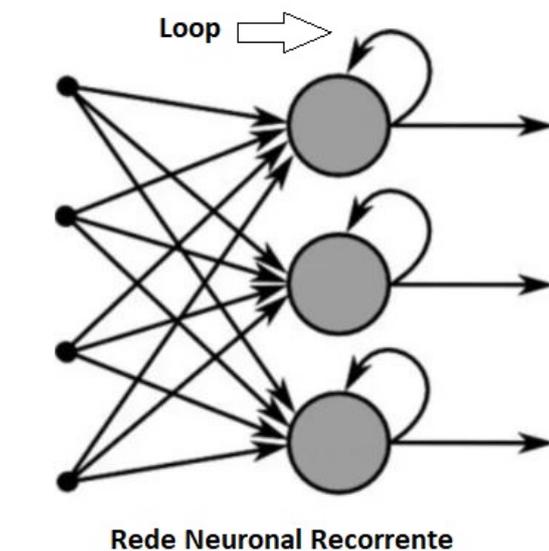


FIGURA 2.8. Funcionamento de uma Rede Neuronal Recorrente [46]

2.3.3. Algoritmo para Detecção de Humidade

Numa fase posterior à recolha dos dados captados pelos sensores, que por sua vez estão acoplados ao drone, procede-se à análise e interpretação das imagens. Uma das vertentes da visão computacional é o reconhecimento, e que consiste na identificação de padrões, formas e cores com o intuito de obter a informação pretendida. Esta vertente vai ao encontro do objetivo desta dissertação, que consiste na deteção e identificação de regiões com humidade excessiva na vinha. Este método recorre à análise das imagens capturadas pelos sensores, processando as mesmas através da utilização de algoritmos de inteligência artificial especialmente treinados para a classificação e localização de objetos em imagens. Neste caso o objeto a identificar tem o nome de "humidade". Deste modo, é

possível apresentar ao agricultor o estado da sua produção, permitindo também ajudá-lo nas posteriores tomadas de decisão [30] [31].

Em [6], utilizou-se uma RNC para se detetar se a planta estava doente ou sadia, entre outros parâmetros. Esta classificação de imagens fez-se com base em características extraídas da rede convolucional, tais como variações de cor e textura.

Nesta dissertação utilizou-se uma RNC, devido a estas redes serem vantajosas para o reconhecimento de padrões e imagens, quando comparadas com outro tipo de funcionamento de redes. As RNC possuem uma extrema capacidade de aprendizagem de padrões e tem uma grande flexibilidade no que diz respeito às variações de detalhes dos dados que se pretende localizar. Este tipo de rede neuronal (RNC) é indicado para projetos que envolvam VC [47] [48].

CAPÍTULO 3

Análise de Stress Hídrico

3.1. Importância da análise ao stress hídrico

As culturas agrícolas dependem essencialmente de luz solar, de água e dos nutrientes presentes no solo. É fundamental a deteção de zonas/períodos de stress hídrico, de modo a poder corrigir-se o quanto antes as oscilações dos níveis de água. O stress hídrico representa um desequilíbrio entre a entrada de água na planta pelas raízes e a saída de água devido à transpiração. Este acontecimento poderá causar distúrbios metabólicos, tais como: quebra no crescimento vegetal, alteração da composição da uva e dificuldade na absorção dos nutrientes do solo. É de extrema importância a análise do solo ao nível da humidade para evitar acumulação de humidade e evitar perdas de água, de modo a que a qualidade do fruto não seja afetada e que não haja desperdícios de água e monetários, Figura 3.1 [16] [17] [49] [50].



FIGURA 3.1. Ilustração do Processo que Ocorre no Terreno

A deteção de zonas com e sem humidade também será muito útil na pré-plantação de uma vinha. O processo de estudar o terreno ao nível da humidade é fundamental para a instalação de infraestruturas de rega e para escolher a orientação da vinha. A Figura 3.2 representa o fluxograma para a análise do stress hídrico na viticultura [16].

3.2. Sensor - Câmara Térmica

O sensor utilizado para captar as imagens térmicas, ou seja, as imagens que apresentam a temperatura da videira/solo fotografado, foi uma câmara térmica, cuja marca e modelo

é *FLIR Vue Pro R* que foi cedida pela empresa *Skyverse*. Na Figura 3.3 pode-se observar o sensor utilizado alocado ao drone.

Na Tabela 3.1 apresenta-se as características do sensor.

TABELA 3.1. Características da câmara térmica

FLIR Vue Pro R - Especificações	
Resolução	640x512
Tamanho	5.7cm x 4.5cm
Peso	113.4g
Intervalo de Temperaturas	-20° C - 50° C
Tamanho Lente	19mm
Exatidão	+/- 5° C
Banda espectral	7.5 - 13.5 μ m

Na Figura 3.4 observa-se uma das muitas fotografias capturadas pelo sensor térmico, onde as zonas com a cor amarelo, laranja e tons de vermelho representam leituras de zonas com uma temperatura mais elevada, e as zonas em tons de azul e azul escuro representam leituras de zonas com uma temperatura mais baixa, o que representa zonas com mais abundância de água.

Existe a possibilidade de alterar a paleta de cores das fotografias, de modo a destacar-se outras zonas da imagem, dependendo do objetivo do trabalho a ser efetuado.

3.3. Drone - *Quadcopter*

O drone utilizado para transportar o sensor que sobrevoou as vinhas foi um drone *Quadcopter* que foi cedido também pela empresa *Skyverse*. Na Figura 3.5, observa-se o drone e o comando que permite o controlo do mesmo via *Wi-Fi* (2,4GHz).

O drone foi construído pela empresa *Skyverse* e projetado principalmente para operar em projetos agrícolas. A Tabela 3.2 apresenta as características principais do aparelho.

TABELA 3.2. Características do drone

Drone Quadcopter - Especificações	
Tamanho	80cm
Peso	+/- 7kg
Bateria	Gensace 16A 6s 22.2V
Autonomia	15min
Controlador de Voo	DJI A3
Transmissão de vídeo	DJI Lightbridge 2
Sistema de propulsão	KDE
Monitor de vídeo e controlo	iPad Air

Este drone e o sensor utilizados permitiram que a recolha de dados, sob forma de imagens, constituísse o conjunto de dados principal, também denominado de *dataset* fosse

Capítulo 3. *Análise de Stress Hídrico*

feita nas melhores condições possíveis. O drone apresentou voos muito estáveis pela sua robustez e estabilidade, o que resultou em fotografias (imagens) com qualidade e adequadas para responder aos objetivos propostos. O sensor térmico - *FLIR Vue Pro R* é um dos melhores sensores que existe atualmente no mercado para ser acoplado a um drone devido às características apresentadas na tabela 3.1 , as imagens que este captou ficaram com imensa qualidade. Estes 2 aparelhos disponibilizados são de tecnologia de ponta.

É de salientar que a parceria que se estabeleceu com a empresa *Skyverse* foi fundamental, para que este projeto pudesse alcançar os seus objetivos.

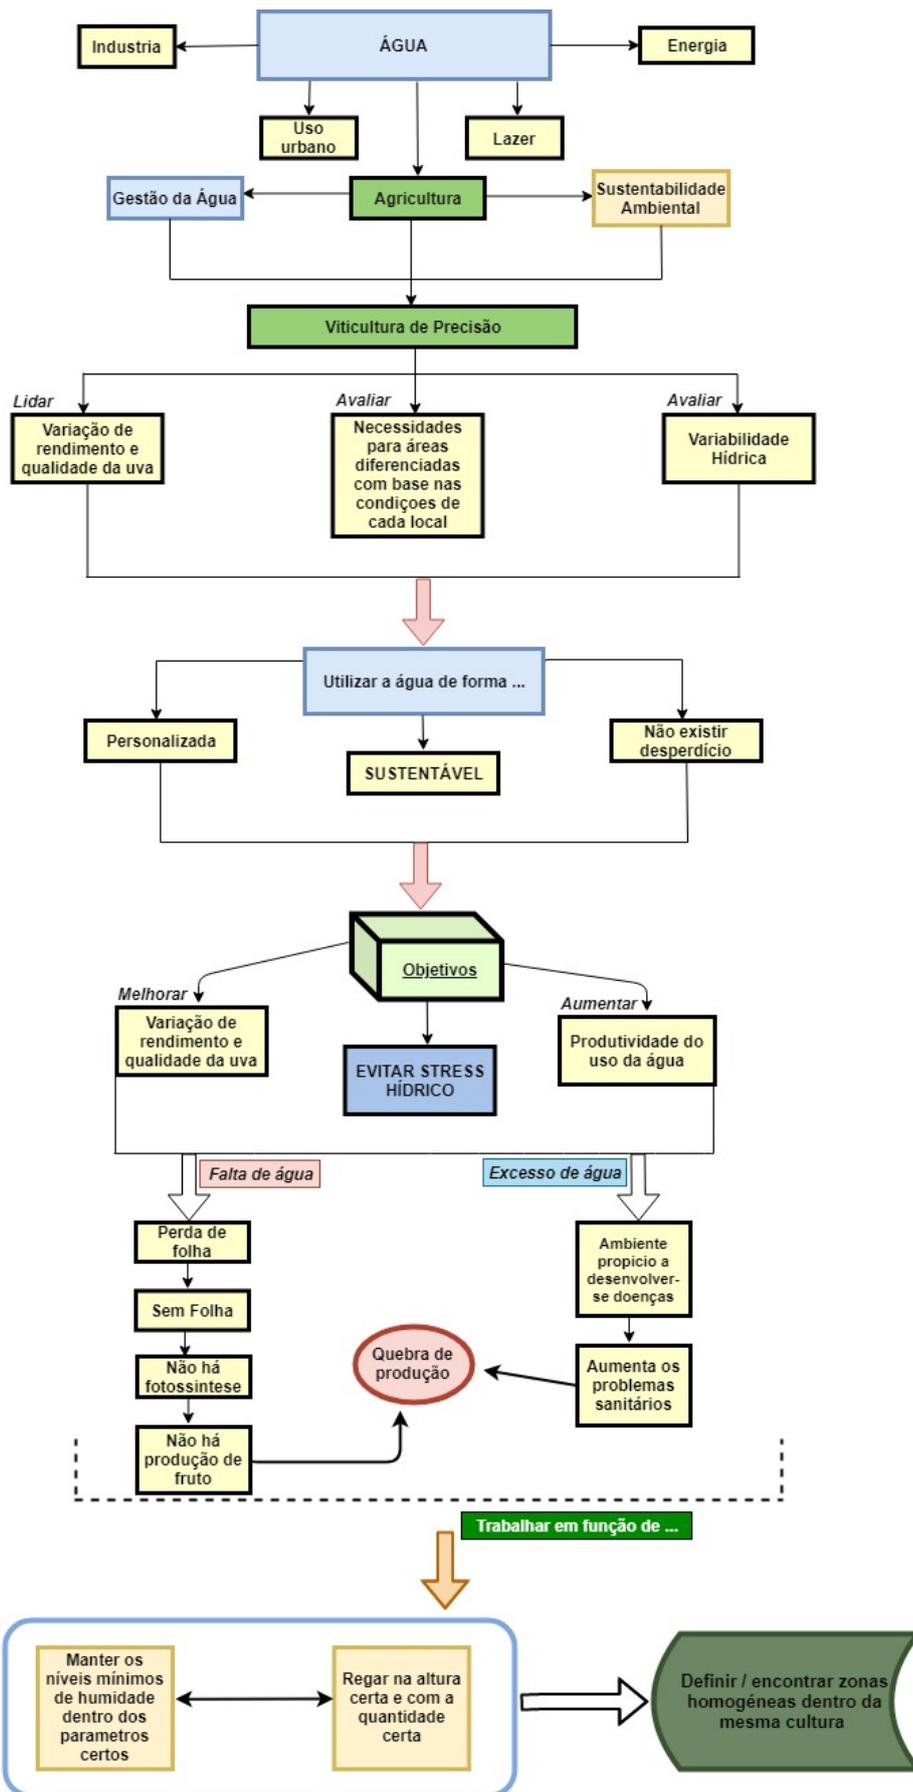


FIGURA 3.2. Importância da Análise ao stress Hídrico na Viticultura



FIGURA 3.3. *Skyverse* - Câmara Térmica - *FLIR Vue Pro R*

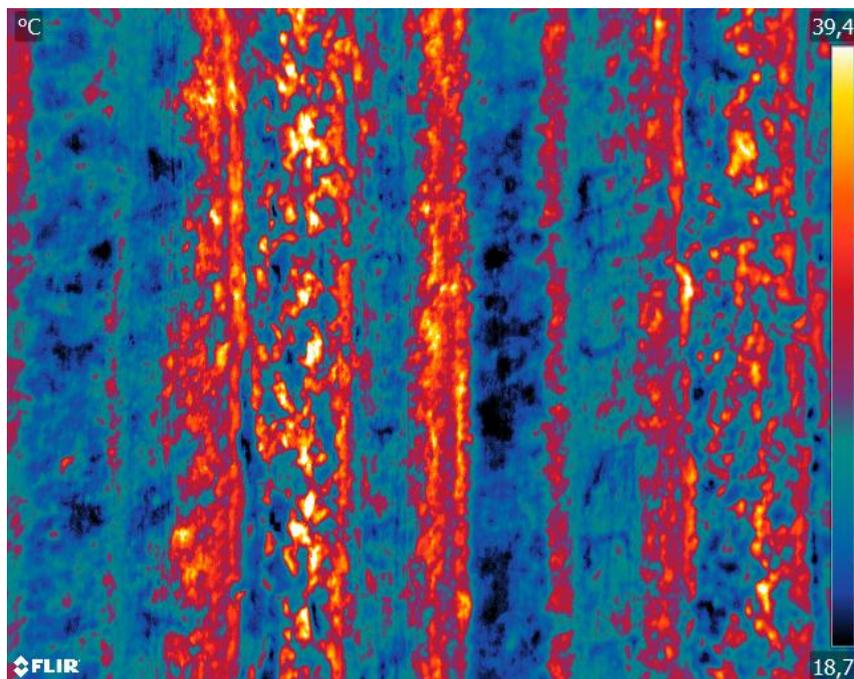


FIGURA 3.4. Fotografia das videiras/solo com as Temperaturas Representadas através de diferentes cores



FIGURA 3.5. *Skyverse - Drone Quadcopter*

Deteção Automática de Humidade Suportada em Redes Neuronais Convolucionias

4.1. Redes Neuronais Convolucionais

As Redes Neuronais Convolucionais (RNC) são uma peça fundamental, a sua implementação permitiu atingir a deteção de zonas com humidade excessiva em imagens térmicas. Tendo em conta o objetivo desta experiência, era de extrema importância que o algoritmo ao efetuar a deteção do pretendido tivesse o menor erro possível. Deste modo, fez-se uma pesquisa e concluiu-se que as RNC seriam as mais indicadas para detetar os "objetos", neste caso as zonas nas imagens que contenham tons de azul escuro, Figura 4.1.

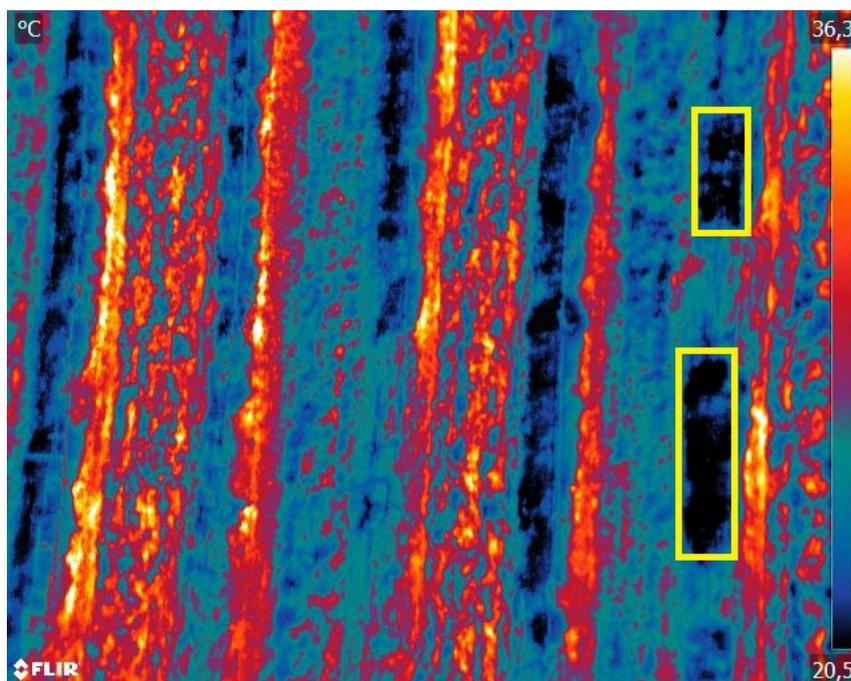


FIGURA 4.1. Zonas selecionadas com os tons de azul escuro

As RNC como o nome indica, durante o processo de deteção do objeto executam uma operação de convolução. Nesta operação é quando ocorre a extração automática de características e padrões que irão ser a base de decisão para o algoritmo. Este tipo de redes tem a capacidade de reconhecer as características de uma imagem (por exemplo:

linhas, curvas, cores, faces, bordas) e de seguida aprende a relacioná-las para identificar estruturas maiores (por exemplo: humanos, animais, objetos, zonas específicas, entre outras) [51].

4.1.1. *Dataset*

Imagens de Treino e Teste

O processo de treino é a base na construção de um algoritmo, consiste na identificação de padrões, formas, cores e regiões semelhantes entre as imagens. É essencial para um ótimo resultado de deteção que o algoritmo tenha um número considerável de imagens para poder ter dados de comparação.

O *dataset* é o conjunto de imagens que se utilizou para treinar o algoritmo. Este banco de dados é composto por imagens para treino e também por imagens idênticas mas estas com a função de testar/avaliar o que o algoritmo consegue detetar.

Este processo de reconhecimento de características efetuado automaticamente pelo algoritmo forma a base para as decisões de análise e deteção do que se pretende.

4.1.2. **Parâmetros de Configuração da RNC**

Relativamente à arquitetura e aos parâmetros iniciais de uma RNC, existem muitas configurações que necessitam de ser escolhidas. Os parâmetros consistem em escolher a função perda, o otimizador mais apropriado, o número mais indicado de épocas de treino, entre outros, de forma a construir um algoritmo eficiente, robusto, e com o funcionamento esperado (classificar e localizar zonas com humidade excessiva). Na vertente de *deep learning*, os parâmetros iniciais são chamados de “Hiperparâmetros”. A escolha destes valores iniciais terão grande impacto nos resultados da rede e na performance geral do modelo [52].

Para avaliar o desempenho do modelo, existem dois tipos de métricas para analisar o desempenho do modelo nos momentos de treino e validação: perda (*loss* ou erro) e exatidão. O valor da perda representa a diferença entre as previsões efetuadas pelo algoritmo e o valor real. Esta diferença é calculada após cada iteração nos processos de treino e validação. O valor de exatidão representa o desempenho do modelo quando executa previsões corretas, tendo em conta o número total de previsões efetuadas. Num cenário ideal, um modelo é considerado adequado quando o erro converge para 0 e a exatidão converge para 1 [52].

4.1.2.1. Função Perda - Loss Function. Durante o processo de treino de uma RNC, a função perda é responsável por ajustar os pesos dos nós da rede, de modo a reduzir o erro entre as previsões efetuadas pelo algoritmo e os valores reais, criando um modelo com uma maior exatidão. A função perda calcula uma penalidade por qualquer desvio entre os valores reais e as previsões de *output* da rede. De uma forma mais objetiva, a função perda quantifica o desempenho da rede.

Existem várias funções perdas, e a sua aplicação depende do tipo de dados que se tiver a analisar. Estes podem ser divididos entre valores discretos (podem assumir apenas valores categóricos, p.ex uma classe - humidade) e contínuos (podem assumir qualquer valor numérico). Perante problemas de regressão, o Erro Médio Quadrático é o mais indicado para o tipo de dados contínuo. Em caso de problemas de classificação, por exemplo, a *Logarithmic Loss* é função mais adequada para dados discretos.

Logarithmic Loss

A *logarithmic loss* é a função perda que é implementada pelo presente algoritmo. Neste caso, e visto que estamos perante uma classificação binária (*BCE - Binary Cross-Entropy*), a *logarithmic loss* aplica um peso aos casos falsos-negativos e aos falsos-positivos. Se este valor for maior que 1, é aumentado a penalidade para os casos falsos-negativos, se o valor for menor que 1, é diminuída a penalidade. Para uma multi-classificação (*CCE - Categorical Cross-Entropy*), esta função aplica pesos a classes ou conjuntos, aumentando ou diminuindo a penalidade relativamente a casos falso-negativos [52].

$$BCE = -\frac{1}{N} \sum_{i=1}^N y_i \cdot \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i)) \quad (4.1)$$

Na equação 4.1 apresenta-se a função BCE em que N é o número de amostras, onde y é a característica (exemplo: 1 para pontos verdes e 0 para pontos vermelhos) e p(y_i) é a probabilidade do ponto i ser verde para todos os N pontos.

Para cada ponto verde (y_i=1), adiciona log(p(y_i)) à perda, ou seja, a probabilidade de ser verde. Ao invés, adiciona log(1 - p(y_i)), isto é a probabilidade do ponto de ser vermelho, para cada ponto vermelho (y_i=0) [53].

4.1.2.2. Exatidão. Nos algoritmos de ML, é possível avaliar a métrica de exatidão durante 2 momentos distintos: durante o processo de treino e durante o processo de teste. No entanto, os seus valores tem significados diferentes:

- Avaliar a exatidão durante o treino de um algoritmo representa a performance do modelo que está na fase de aprendizagem. Um modelo que está a executar

uma boa aprendizagem, certamente irá fazer previsões com melhores resultados sobre os dados que conhece.

- Avaliar a exatidão durante a fase de teste representa o desempenho do modelo quando o mesmo não conhece os dados. Isto permite perceber se o modelo é robusto o suficiente para detetar o pretendido em imagens futuras.

A exatidão no processo de treino é calculada a cada iteração/época concluída e é bastante útil para se perceber se o algoritmo está a atingir um processo de aprendizagem correto. A compreensão desta evolução é crucial, uma vez que pode ajudar no *fine-tuning* dos hiperparâmetros, a melhorar os otimizadores, entre outros aspetos.

4.1.2.3. Otimização. O otimizador atualiza o valor do *learning rate* durante o processo de treino, de modo a atingir valores mínimos possíveis da função perda. Para este caso, o algoritmo implementa o otimizador *RMSPProp*. Metaforicamente representa a velocidade com que um modelo "aprende" de modo a apresentar o menor erro possível [54].

4.1.2.4. Batch Size. O *batch size* é o hiperparâmetro que define o número de amostras a serem analisadas antes de se iniciar a fase de treino, ou seja, antes de se atualizar os parâmetros internos do modelo.

O *Batch Size* a nível operacional funciona por conjunto de amostras, pois divide o *dataset* inicial em pequenos conjuntos - *subsets*. Estas metodologias permitem resolver problemas, tais como o uso excessivo de memória do sistema. Para este caso e visto que se está a processar imagem, a utilização controlada de memória de vídeo é importante para o bom funcionamento do processo de treino/teste.

4.1.2.5. Número de Épocas. O número de épocas é definido pelo número de vezes que o algoritmo irá ser executado na sua fase de treino. Uma época é um conjunto de etapas do processo de treino desde o *input* das imagens, otimização de pesos até ao cálculo das métricas de perda e exatidão. As épocas são compostas por um ou mais *batch*.

4.1.2.6. Learning Rate. *Learning rate* é o hiperparâmetro fundamental na configuração da rede neuronal convolucional. O objetivo deste hiperparâmetro é gerir em que medida se altera o modelo em resposta ao erro avaliado em todos os momentos que os pesos são atualizados. A escolha da *Learning rate* é desafiante, visto que um valor muito pequeno pode resultar num longo processo de treino, apresentando também elevados valores de erro e baixos valores de exatidão (*underfitting*, Figura 4.2), enquanto um valor muito alto

pode resultar numa aprendizagem pouco generalizada e cujo o algoritmo não consegue relacionar os dados (*overfitting*, Figura 4.2) [54] [55].

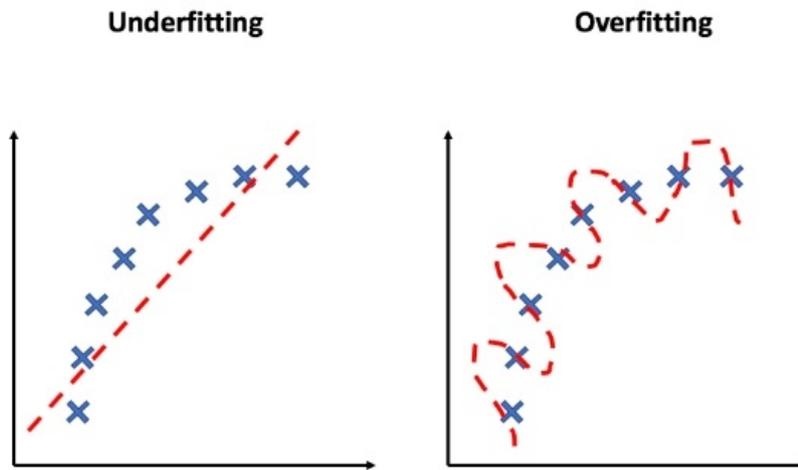


FIGURA 4.2. *Underfitting e Overfitting* [56]

De uma forma mais específica, a *Learning rate* é um hiperparâmetro configurável usado no treino de RNC que possui um pequeno valor positivo, por norma varia entre 0 a 1. A *Learning rate* controla a rapidez com que o modelo se adapta ao problema. Um menor valor de *Learning rate* requer mais épocas de treino, dadas as pequenas alterações feitas nos pesos a cada atualização, um valor maior faz com que haja mudanças mais rápidas e resulta em menos épocas de treino [54].

Um *Learning rate* com um valor elevado pode originar que o modelo convirja muito rapidamente e resulta numa solução com resultados inferiores ao ideal, enquanto um valor muito pequeno pode gerar que o processo fique bloqueado. Neste projeto utilizou-se o valor de *learning rate* - 0,004. Devido à dificuldade em encontrar um valor inicial ideal, este valor foi o que após vários testes, apresentou melhores resultados [54].

4.1.2.7. *Data Augmentation*. O método de *Data Augmentation* é um método fundamental para aumentar a robustez das RNC. O *Data Augmentation* consiste na expansão artificial do conjunto de dados (*dataset*) de treino, gerando novos dados a partir dos dados de treino existentes. Este processo aplica técnicas específicas que criam imagens novas e diferenciadas que aumentam substancialmente o nosso *dataset*, que servirá como *input* no processo de treino da rede. As transformações envolvem uma vasta gama de operações na vertente de manipulação de imagens, tais como compressão, inversões, rotações redimensionamento, alteração de cores, entre outras. O objetivo é aumentar as amostras de

treino com exemplos novos e plausíveis, de modo a que o algoritmo tenha mais dados para aprender a detetar e localizar o pretendido com uma melhor robustez [57] [58].

4.1.2.8. Função de Ativação. As funções de ativação são equações matemáticas que estão agregadas a cada neurónio da rede e estimulam esse neurónio, deve ficar "ativado" ou não, com base no *input* de cada neurónio (se este é pertinente para a previsão do algoritmo). O objetivo da função de ativação é introduzir convergência no *output* de um neurónio, Figura 4.3 [59]. As funções de ativação ajudam a ajustar o *output* de cada neurónio e que pode ter diversas variações.

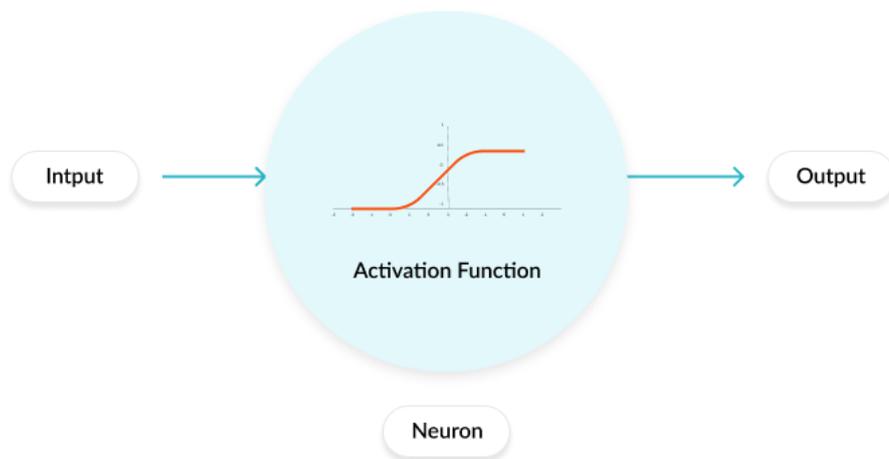


FIGURA 4.3. Função de Ativação [59]

Numa RNC, os *inputs* "alimentam" os neurónios na camada de entrada. A todo e qualquer neurónio na rede é lhe atribuído um peso, multiplicando o *input* pelo peso, obtém-se o *output* do neurónio, que será depois transferido para a próxima camada e assim sucessivamente.

A função de ativação funciona como um "portão" matemático entre o *input* e *output* dos neurónios, fazendo progredir o processo de treino de camada em camada. De uma simples forma, esta função "liga" e/ou "desliga" o *output* do neurónio, conforme a necessidade e importância do neurónio para o que se pretende obter da rede [60].

4.1.3. Tipos de Arquitetura de RNC

A arquitetura da rede ou *base network* é a base do algoritmo, pode-se afirmar ainda que é a ponte generalizada entre o *dataset* e o detetor. Uma *base network* é a especificação inicial do algoritmo, ou seja, o ponto de partida das etapas envolvidas no processo de treino [61].

4.1.3.1. MobileNet. A *MobileNet* é uma *base network* direcionada para ser implementada e executada em dispositivos móveis. Caracteriza-se por ser um modelo de visão computacional compacto, pouco complexo e com baixa latência, o que a torna bastante adequada para execução em dispositivos móveis. A *MobileNet* é utilizada para classificação de imagens, deteção, segmentação ou apenas para extração de características de RNC [62] [63].

Este modelo foi projetado por investigadores da *Google*. Ao nível da exatidão é relativamente menos exata que as outras *base network*, mas assim o tempo de processamento é menor.

Por defeito, a *MobileNet* foi pré-treinada utilizando o *dataset ImageNet*, que utiliza cerca de 1.500.000 de imagens agregadas em 1.000 categorias (exemplos de categorias: objetos, expressões faciais, cores, letras, posições do corpo humano) [64].

Neste projeto utilizou-se a *base network Mobilenet*, pois é bastante leve em termos de processamento e indicada para correr em sistemas com baixo poder computacional, p.ex *Raspberry Pi*. Se no futuro este projeto for para ser utilizado com um drone e efetuar-se a deteção da humidade em *real-time*, a *base network* adequada será a *mobilenet*, pois é possível o drone acoplar uma unidade de processamento, p.ex *Raspberry Pi*.

4.1.3.2. ResNet. A *ResNet* (Rede Residual) é também uma *base network* das RNC. Foi desenvolvida para permitir um número elevado de camadas convolucionais. Fazendo uma comparação com outras arquiteturas de RNC, a *ResNet* consegue adicionar um grande número de camadas convolucionais, o que possibilita a criação de modelos mais complexos, que por sua vez resolve também problemas mais complexos (p.ex classificar muitos objetos numa única imagem).

As camadas que inicialmente não têm um papel ativo na rede, a *ResNet* "ignora" essas camadas. Ao ignorar essas camadas permite comprimir a rede, tornando-a mais pequena (menos complexa), o que por sua vez, faz com que o processo de aprendizagem seja mais rápido [65].

4.1.3.3. Inception. A *Inception* também pertence ao grupo das *base networks*, incorporada nas RNC, de modo a reduzir gastos computacionais. As RNC são bastante complexas, dado que necessitam de ser projetadas de uma forma estruturada e adequada ao objetivo que se pretende atingir. Por fim, os *outputs* resultantes são concatenados e enviados para a próxima camada. Ao estruturar a RNC para executar as suas convoluções na mesma camada, a rede será gradualmente mais ampla e menos profunda. Uma RNC

muito profunda também não é o ideal, pois torna o processo de treino mais complexo e mais exigente a nível computacional [66] [67].

4.1.4. Detetores

O detetor é o responsável por localizar os "objetos" e detetar a classe deste mesmo, coloca as *bounding boxes* na localização em que prevê onde esteja o objeto.

As *bounding boxes* são uma técnica de anotação de imagens. Os detetores colocam-nas sobre as zonas de interesse, de modo a que o algoritmo encontre o que pretende [68].

4.1.4.1. SSD - Single Shot MultiBox Detector. O SSD é um detetor que permite efetuar deteção de objetos em imagens, que utiliza uma abordagem na qual a rede tem a capacidade de detetar todos os objetos de uma imagem de uma só vez (uma só tentativa), daí ter o nome *single-shot*.

O detetor SSD agrupa as *bounding boxes* dos *outputs* em conjuntos de *boxes* em diferentes proporções e escalas por local de características.

Este modelo SSD é relativamente simples, quando comparado com modelos que necessitam de uma rede que gera propostas de regiões, onde esses objetos possam existir na imagem (como é o caso das *RPR - Redes de Propostas de Regiões*). Ao eliminar esta necessidade e aglomerando todo o processo num único "passo", torna o modelo mais simples, tornando também as deteções mais rápidas [69] [70] [71].

Na Figura 4.4 pode observar-se uma RNC, composta pela sua *base network mobilenet* e o seu detetor SSD.

4.1.4.2. Faster R-CNN. Uma abordagem diferente torna o método *Faster R-CNN* mais rápido com a vantagem de ter na sua arquitetura uma RPR. Uma RPR é uma rede convolucional que antecipa limites e pesos/pontuações dos objetos que deteta.

O *Faster R-CNN* é constituído por uma rede de extração de características que por norma é um RNC pré-treinada. De seguida tem 2 sub-redes, em que a primeira rede é uma RPR e a segunda rede é usada para prever a classe a que pertence o objeto detetado [73] [74].

A principal diferença do *Faster R-CNN* para os restantes detetores é a existência de uma RPR e esta encontra-se logo após a última camada convolucional. Na Figura 4.5 está ilustrado o funcionamento do detetor *Faster R-CNN*, nomeadamente na representação das regiões propostas.

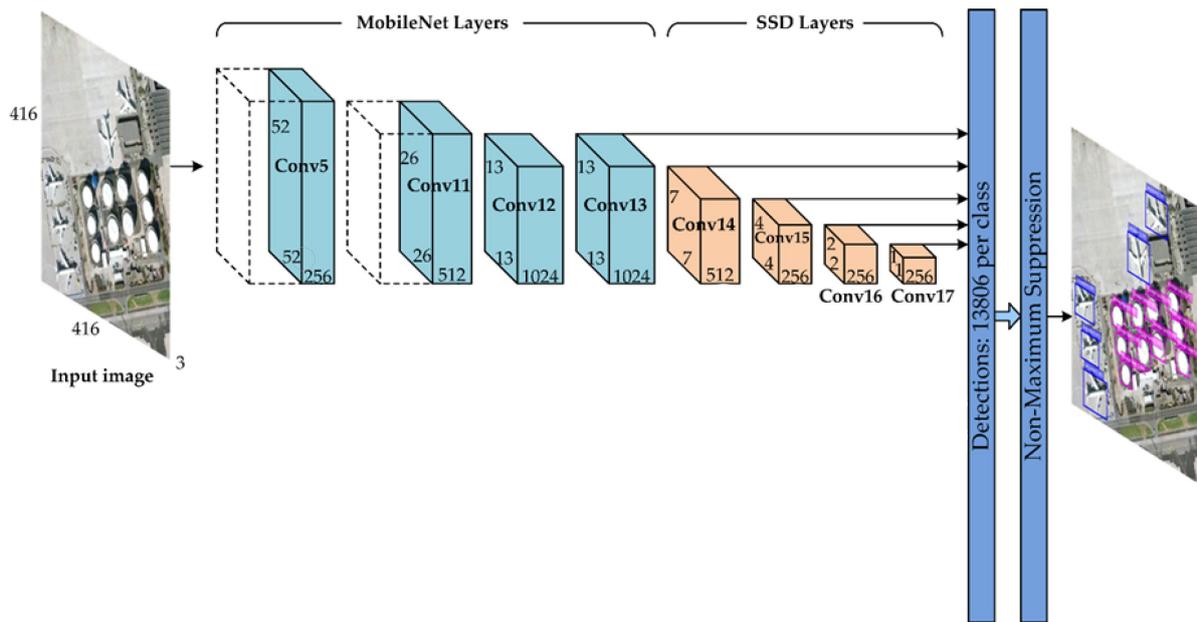


FIGURA 4.4. *Mobilenet e SSD*[72]

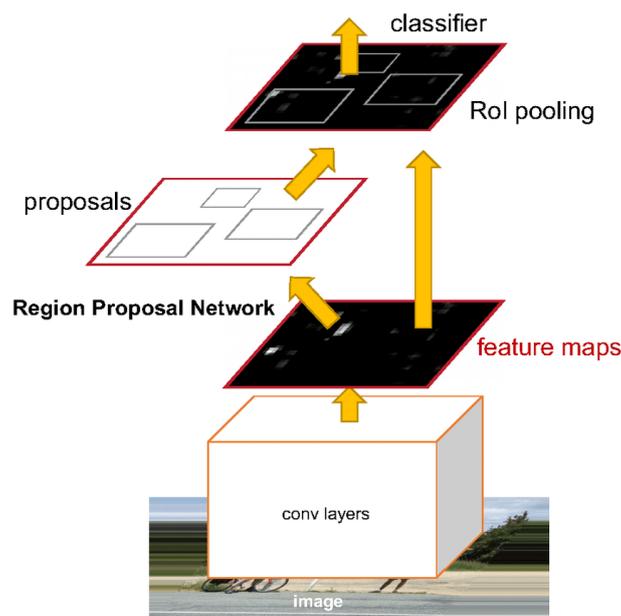


FIGURA 4.5. Detetor *Faster R-CNN* [75]

4.1.4.3. YOLO - You only look once. O YOLO foi elaborado para deteção de objetos em tempo real. Este modelo é extremamente rápido, mas perde um pouco a capacidade de exatidão. O detetor YOLO aplica apenas uma RNC à imagem completa. Esta RNC divide a imagem em regiões, prevê as *bounding boxes* e probabilidades para cada zona e objeto detetado [76] [77] .

O SSD é um detetor algo semelhante ao YOLO, em termos de rapidez o YOLO é mais rápido do que o SSD mas na vertente relacionada com a exatidão o SSD tem um melhor

desempenho. O detetor SSD tem a capacidade de equilibrar a velocidade e a exatidão, enquanto o YOLO é mais rápido mas atinge valores inferiores de exatidão [78]. Pela razão mencionada anteriormente, o detetor SSD foi o utilizado.

CAPÍTULO 5

Testes e Resultados

A realização desta dissertação foi possível devido à parceria que se desenvolveu com a *Startup Skyverse*. Esta *Startup* e os seus colaboradores foram fundamentais na recolha dos dados (imagens térmicas). A empresa, não só disponibilizou o drone e a câmara térmica, assim como os seus colaboradores, que se deslocaram ao local de testes dando o seu contributo, para que a recolha de dados se efetuasse dentro da normalidade e o resultado da captura das imagens fosse concluído com sucesso.

Foi com a colaboração do Eng. Nuno Ramalho que se conseguiu obter o acesso às vinhas, de modo a capturar as imagens térmicas. O Eng. Nuno é consultor na área da Viticultura e responsável por 500 ha de vinha. Tendo permitido que todo o processo de recolha de imagens térmicas fosse realizada corretamente, junto às vinhas designadas, de modo a efetuar-se os testes com o máximo rigor possível, sendo este um fator crucial para a construção de um *dataset* com qualidade. Acresce que também acompanhou na recolha das imagens desde o início ao fim do dia.

5.1. Recolha dos dados

No dia 26 de Março de 2019, pelas 8h00, João Martins (aluno), António Raimundo e Ricardo Silva (colaboradores da *Skyverse*) deslocaram-se de Lisboa a **Ponte de Sor, Portalegre**. A Figura 5.1 representa a zona onde se encontram as vinhas, em que o Eng. Nuno é responsável.

É de realçar que na zona de Ponte de Sor, Alto Alentejo, a vertente da agricultura é um dos setores predominantes da economia local. Em redor de Ponte de Sor existe um elevado número de ha de vinha e muitos vinhos de excelência, o que fez com que fosse o local escolhido para a recolha das imagens. A área da Viticultura está bastante desenvolvida nesta zona e em constante desenvolvimento e projeção. Nos últimos anos tem havido um forte investimento na melhoria das infraestruturas das vinhas/adegas, na forma como analisam as uvas e os terrenos das vinhas, utilizando métodos inovadores de Agricultura de Precisão.

Capítulo 5. Testes e Resultados



FIGURA 5.1. Localização de Lisboa e Ponte de Sor - Distância 140km

Pelas 10h00 chegaram a Ponte de Sor, onde se encontraram com o Eng. Nuno e deslocaram-se às vinhas. Na seguinte Figura 5.2 está representado a vinha A-1 com um total de 2 ha que se fotografou na parte da manhã.



FIGURA 5.2. Vinha A-1

A captura de imagens nesta vinha decorreu dentro da normalidade, obteve-se um resultado bastante positivo. Na parte da manhã ainda se fotografou outra parcela da vinha A-2 com 1 ha, Figura 5.3, onde tudo decorreu como o esperado.



FIGURA 5.3. Vinha A-2

Feito um intervalo para almoçar, retomou-se os trabalhos seguindo-se para a vinha B com cerca de 1.5 ha - Figura 5.4. Nesta vinha, devido às alterações climatéricas que se fizeram sentir, nomeadamente rajadas de vento forte, impossibilitou que a operação decorresse com êxito, é de referir que foram executadas algumas tentativas de voo.

Dia terminado com sucesso com o empenho de todos os intervenientes, obteve-se 280 imagens no total, 250 imagens para treino do algoritmo e 30 imagens para testar o resultado final do algoritmo. A captura das imagens foi realizada com o material referido no capítulo 3. Encontra-se no Anexo A as imagens ilustrativas do registo do dia da recolha de dados.

5.2. Tratamento dos dados

5.2.1. *Input* da Rede

O *input* da RNC é composto por 250 imagens, onde as mesmas foram utilizadas para iniciar o processo de treino da RNC. Para estas imagens de treino (*train dataset*), houve a necessidade de efetuar a classificação manualmente de zonas com humidade excessiva.

Foi necessário fazer uma relação direta com os valores da humidade do solo e a temperatura do mesmo. O Eng. Nuno Ramalho após a realização de alguns testes aos solos das vinhas em questão, concluiu que quando existem leituras de humidade relativa superior a 60%, as leituras de temperatura do solo são sempre inferiores a 20°C. Sendo assim,



FIGURA 5.4. Vinha B

pode-se concluir que qualquer leitura efetuada pela câmara térmica que apresente zonas com temperaturas inferiores a 20°C , as mesmas também apresentam valores de humidade excessivos (superior a 60%).

Esta informação de referência permite realizar a delimitação das *bounding boxes* nas zonas correspondentes a valores de temperatura inferiores a 20°C . A Figura 5.5 demonstra as zonas com humidade excessiva, delimitadas pelas respetivas *bounding boxes*.

As imagens capturadas pela câmara térmica apresentam uma escala de temperatura que permitiu identificar as zonas que apresentavam leituras de temperatura mais baixa. Pode-se afirmar então que essas zonas, são zonas onde o nível de humidade é elevado, quando comparado com as restantes zonas (temperaturas mais elevadas - zonas mais secas).

5.2.2. Configuração da RNC

5.2.2.1. Classificação Manual: LabelImg e FLIR Tools. Antes de iniciar a classificação manual todas as imagens foram lidas pelo programa *Flir Tools* que a própria marca - *Flir* - da câmara térmica disponibiliza. A leitura que o programa executa, consiste na aplicação a cada imagem de um filtro pré-selecionado, neste caso o escolhido

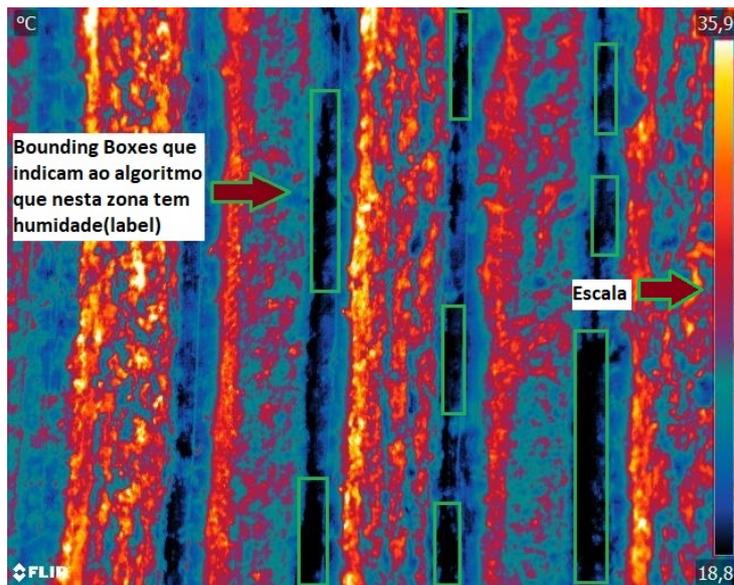


FIGURA 5.5. Imagem classificada com as zonas de humidade excessiva delimitadas por *bounding boxes*

recaiu sobre o filtro "Lava" que destaca fortemente as diferentes zonas de temperatura em conformidade com a sua cor.

Numa segunda fase e última na vertente de classificação manual através do programa *LabelImg* colocou-se as *bounding boxes* nas respetivas zonas de humidade das imagens.

A classificação manual das imagens foi um fator muito importante para o desempenho final do algoritmo. Houve um critério rigoroso ao colocar as *boundings boxes* nas zonas que se considerou humidade, para que quando o algoritmo tivesse na sua fase de treino, conseguisse "aprender" da melhor forma e sem falsas considerações o que são zonas de humidade e o que não são zonas de humidade. Na Figura seguinte, 5.6, segue-se um exemplo do critério que foi posto em prática.

Deste modo a rede recebeu de entrada 250 imagens devidamente classificadas com *bounding boxes* nas zonas que se considerou humidade.

5.2.2.2. Ferramentas: TensorFlow e Keras. A ferramenta *TensorFlow* (TF) é uma biblioteca de software *open-source* focada em fluxo de dados e diferentes tipos de programação para diversos fins. Esta ferramenta foi desenvolvida com foco em *Machine Learning*, *Deep Learning* e em trabalhos de análise estatística, na vertente de RNC, mas é utilizada com sucesso em variadíssimas áreas. O TF foi projetado para facilitar o processo de desenvolvimento e execução de mecanismos de análise para áreas como por exemplo, ciência de dados e estatística. Esta ferramenta é da autoria da empresa *Google* [79] [80].

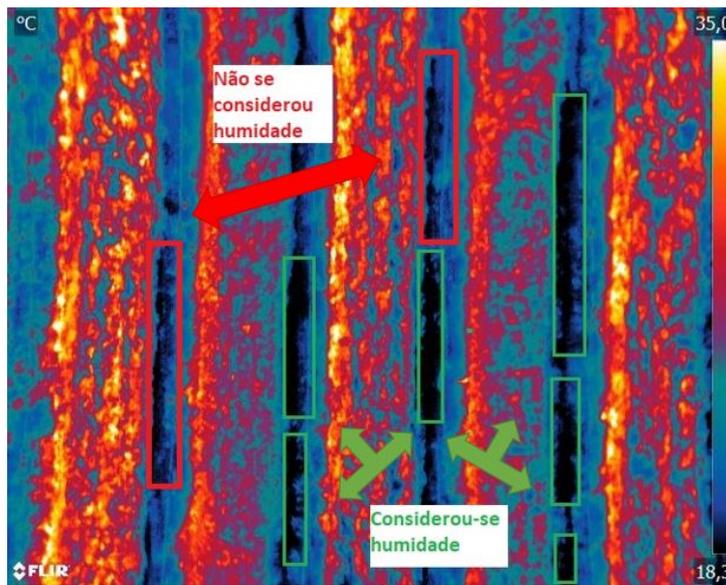


FIGURA 5.6. Imagem ilustrativa do critério para a classificação

O nome *TensorFlow* resulta das matrizes multidimensionais caracterizadas como tensores, que são usadas pelas RNC. O TF classifica as camadas de dados (NÓS da rede).

Na primeira camada, o TF absorve as características básicas do “objeto”. No decorrer da aprendizagem o algoritmo está em constante procura de informações mais peculiares/refinadas sobre o “objeto” [81].

Relativamente ao *Keras* é uma biblioteca de alto nível que fornece uma API que tem a capacidade de ser executada em conjunto com o TF, ou seja, “corre sobre o TF. O *Keras* é usado para criar, implementar e treinar algoritmos. Tem as características de ser uma *framework frontend* em *Python* fácil de utilizar, entender e muito intuitivo, veio ajudar no desenvolvimento de algoritmos [82].

A ferramenta permite configurar os seguintes parâmetros do algoritmo que se pretende implementar: função de ativação, otimizadores, função perda entre outros. Estes parâmetros são todos configurados no código *Python* [83].

A grande vantagem desta ferramenta é que os seus utilizadores conseguem criar um algoritmo relativamente rápido sem terem de configurar os aspetos matemáticos de álgebra tensorial e técnicas numéricas.

O TF e o *Keras*, além de serem 2 *frameworks opensource* e gratuitas, enquadram-se de modo a cumprir os objetivos propostos da dissertação utilizando o algoritmo. Na comunidade de DP são 2 ferramentas muito utilizadas e apresentam sempre *feedback* positivo.

Estas 2 ferramentas foram o core para definir as configurações, treinar a rede e para que no final se conseguisse obter o modelo com resultados positivos. O TF em conjunto com o *Keras* foram os pilares para que se pudesse desenvolver este algoritmo.

5.2.2.3. *Parâmetros: Detetor e Modelo. Parâmetros do Detetor (SSD) - Hiperparâmetros*

- Numero de Épocas - 10.000
- *Batch Size* - 10
- Otimizador - *RMSProp*
- *Learning Rate* - 0.004

Arquitetura da Rede (*Mobilenet*)

- *Input Size* - 250
- Número de *Layers* - 6
- *Dropout* - *False*
- *Batch Normalization* - *True*

Parâmetros do Modelo Final

Na Figura 5.7 está representado o modo como é construído o modelo final. A arquitetura do modelo e a configuração dos hiperparâmetros permitem definir o modelo final que será responsável por classificar e detetar humidade excessiva.

(Model Design + Hyperparameters) → Model Parameters

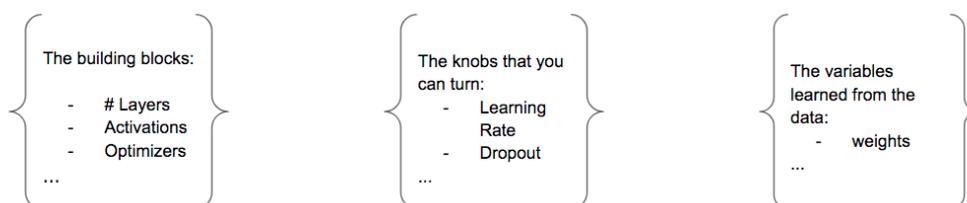


FIGURA 5.7. Construção do Modelo Final

A escolha do detector recaiu sobre o SSD devido a ser um detetor que equilibra a sua velocidade com a sua exatidão bastante bem, a combinação destes 2 fatores permite alcançar ótimos resultados de deteção e localização. Neste caso o objetivo é localizar uma zona de humidade (não é necessário o detetor ter elevada exatidão).

A arquitetura da rede ou *base network* é do tipo *mobilenet*, esta tem uma importante particularidade que é gerar modelos de menores dimensões, leves e rápidos. Os modelos com estas características são recomendados para a deteção e classificação, pois são ideais

para se colocarem em micro chips que são muito utilizados em operações de detecção e localização.

Apesar da *mobilenet* ser uma *base network* menos complexa e robusta, permitiu ao algoritmo obter uma performance satisfatória, o que levou a atingir-se os objetivos propostos.

5.2.3. Treino da RNC

Chegando ao momento de treinar a RNC com as configurações efetuadas, é de salientar que a rede é o core do algoritmo.

Utilizou-se o computador com um CPU Intel i7-6700K e a placa gráfica GeForce GTX 1080Ti, iniciou-se o processo de treino e o mesmo decorreu até se verificar valores de perda/exatidão aceitáveis, este processo teve a duração de 8Horas.

A Figura 5.8 representa a evolução das métricas de perda/exatidão ao longo de todo o processo de treino.

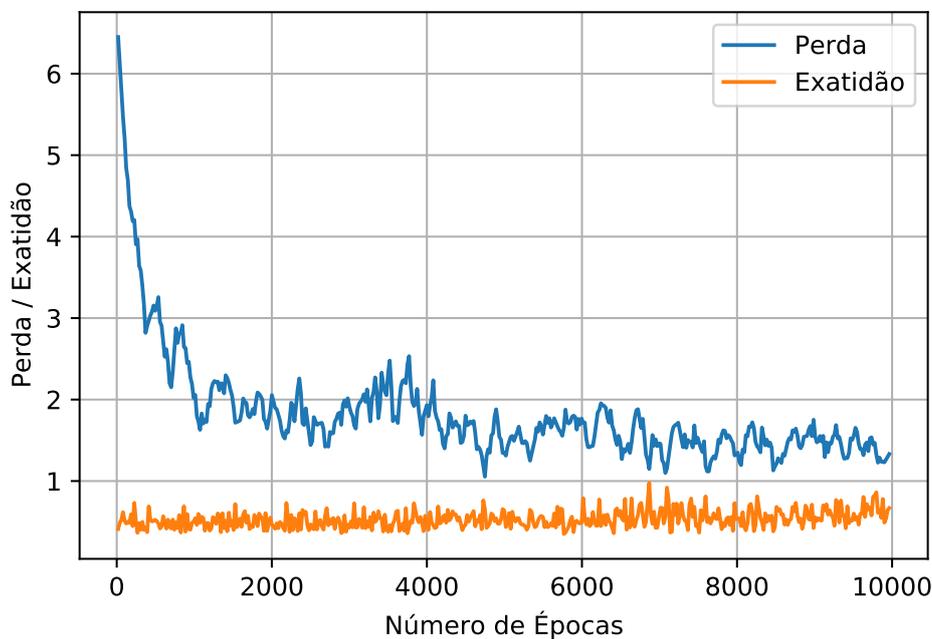


FIGURA 5.8. Gráfico representativo da curva de aprendizagem do algoritmo

Atingiu-se a performance pretendida quando os valores de perda estabilizaram e obteve-se valores de exatidão aceitáveis. Após o treino gerou-se o modelo final, a etapa seguinte é os testes.

5.3. Resultados

5.3.1. Performance Final

Chegado o momento de avaliar a performance do algoritmo, efetuou-se os testes com 30 imagens. Para tal recorreu-se à métrica da exatidão, que consiste na soma das deteções quando existe humidade excessiva e nas não-deteções quando não se está na presença de humidade excessiva, dividindo pelo total de deteções.

A Figura 5.9 apresenta uma matriz de confusão, onde é possível retirar várias métricas de performance, sendo uma delas a exatidão. Cada quadrante representa o número de deteções e não-deteções, tendo em conta o que foi previsto pelo algoritmo e a situação real respetiva.

		Situação real	
		Com humidade	Sem humidade
Previsão	Com humidade	45	8
	Sem humidade	11	41

FIGURA 5.9. Resultados da avaliação à performance final do algoritmo

A lista abaixo representa o significado de cada um dos valores presentes na Figura 5.9, no que diz respeito à sua definição:

- 1º Quadrante (Verdadeiros Positivos - VP) - 45 ocorrências
- 2º Quadrante (Falsos Positivos - FP) - 8 ocorrências
- 3º Quadrante (Falsos Negativos - FN) - 11 ocorrências
- 4º Quadrante (Verdadeiros Negativos - VN) - 41 ocorrências

A exatidão é então calculada através da seguinte equação:

$$Exatidão = \frac{VP + VN}{VP + FP + FN + VN} \cdot 100[\%] \quad (5.1)$$

Aplicando a equação 5.1 e utilizando os resultados presentes na Figura 5.9, pode-se observar que houve 19 (8 + 11) detecções incorretas e 86 (45 + 41) detecções corretas. Fazendo o balanço final, obteve-se 82% de exatidão, apesar de algumas imagens detetarem zonas de humidade um pouco irrelevantes devido à pequena dimensão do local.

A Figura 5.10 apresenta 2 detecções de humidade onde existem realmente humidade excessiva (verdadeiros positivos).

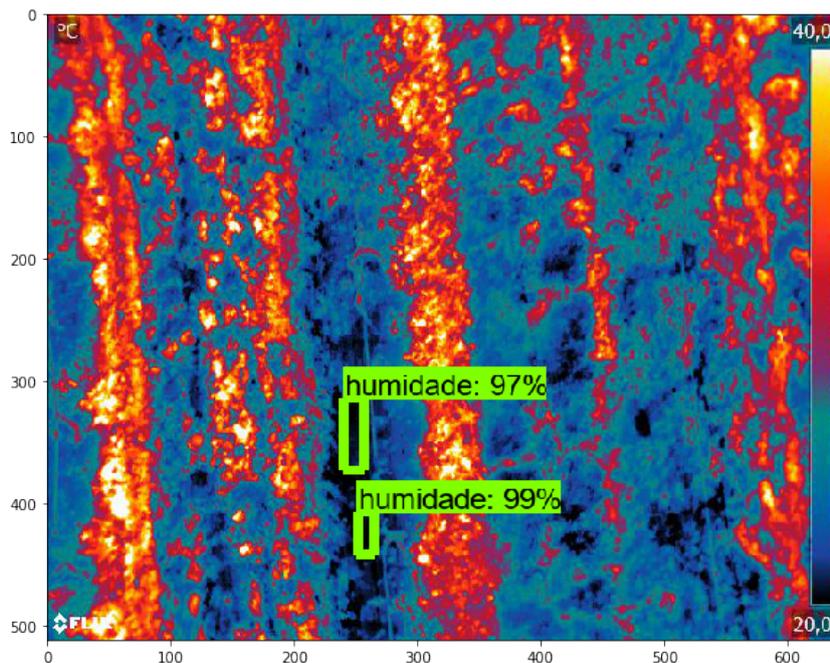


FIGURA 5.10. Detecção e localização efetuada pelo algoritmo numa imagem térmica

Pelo contrário, em 18% das classificações, o algoritmo não teve o desempenho esperado, efetuou detecções erradas e não detetou zonas onde era suposto detetar.

Concluindo, o resultado final do algoritmo é bastante positivo, uma vez que a exatidão obtida (82%) foi suficiente para concluir os objetivos propostos.

Apesar do algoritmo ter atingido um ótimo resultado de deteção das zonas de humidade, haverá sempre aspetos a melhorar. Um aspeto seria configurar/afinar o *Non Maximum Suppression (NMS)*. O *NMS* consiste numa técnica que os algoritmos usam para diminuir a *overclassification*, o algoritmo no processo de deteção cria várias bounding boxes em redor do objeto a detetar, o *NMS* calcula a maior probabilidade de sobreposição das bounding boxes, para um melhor entendimento sobre o *NMS* a Figura 5.11 ilustra de uma forma muito esclarecedora o conceito [84].

Deste modo o algoritmo consegue obter um nível superior de exatidão, visto que o *NMS* diminui a zona possível onde poderá estar o objeto.

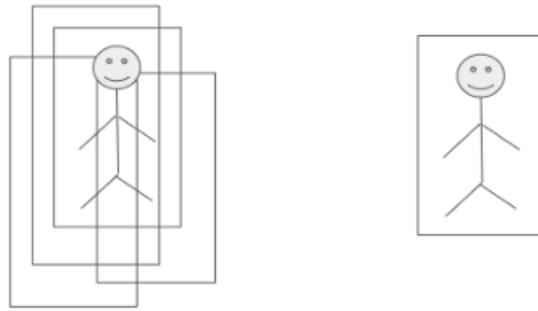


FIGURA 5.11. *Non Maximum Suppression*

5.3.2. Reconstrução 2D do terreno analisado

Obteve-se uma pequena reconstrução 2D, Figura 5.12 de um dos terrenos sobrevoados, inseriu-se manualmente as coordenadas em 15 fotografias. O ideal seria as fotografias no momento que foram fotografadas registarem as coordenadas, ou seja, serem imagens georreferenciadas.

5.4. Poupança de Água

A presente dissertação assenta em 2 pilares, a sustentabilidade ambiental e a inovação. A água é um dos bens mais valiosos que temos na terra, cerca de 60% do nosso corpo é constituído por água e em quase todas as ações do nosso dia-a-dia necessitamos deste bem precioso. A água é um recurso natural, ou seja, é finito e limitado. Cada vez existe mais zonas de risco de seca extrema e escassez de água potável, tendo em conta a situação atual do planeta terra é tempo de estudar e aplicar mecanismos que nos permitam poupar água [85].

Aliar a inovação à sustentabilidade ambiental, na minha opinião é das melhores fusões da atualidade, pois permite-nos utilizar metodologias inovadoras e ao mesmo tempo preservar o meio ambiente.

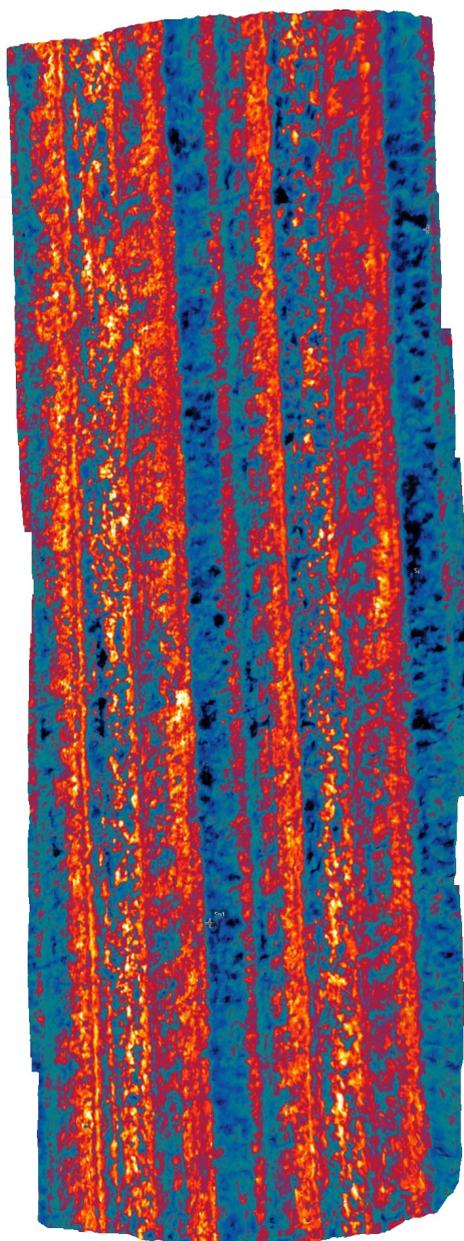


FIGURA 5.12. Reconstrução 2D de uma das áreas fotografadas

CAPÍTULO 6

Conclusão

6.1. Principais Conclusões

A utilização do algoritmo consiste em analisar o terreno, de modo a que o algoritmo detete e localize as zonas de maior humidade, assim estas zonas não necessitam de um tempo de rega igual às zonas com menor humidade. Tendo as zonas localizadas, é possível ir diminuindo o tempo de rega nas zonas de maior humidade, poupando-se assim milhares de litros de água, traduzindo-se no final também em poupança monetária.

Existem alguns fatores que podem dificultar esta diminuição do tempo de rega, por exemplo: a forma como o sistema de rega está construído e colocado na vinha e ainda a diferença da composição do terreno num curto espaço, onde não é possível diferenciar o tempo de rega.

Nas Figuras seguintes 6.1 e 6.2 fez-se um exercício comparativo, de modo a compreender o que se conseguirá poupar ao nível dos litros de água ao utilizar o algoritmo numa vinha.

Dados da Vinha

- Vinha com a dimensão de **50ha**
 - Espaçamento entre linhas = **2,20 metros**
 - Espaçamento entre plantas na linha = **1,10 metros**
 - Gotejadores debitam em média **2,1 litros/hora**
- O tubo de rega gota a gota tem os gotejadores separados por **1m**. Teremos nesta situação **4545 gotejadores por ha**.
- **1ha** de uma vinha com estas características gastará **9,5m³** por hora por **ha**, logo gastará nos **50ha** por hora **475m³**, ou seja, **475 000 litros de água**.

*Valores standard

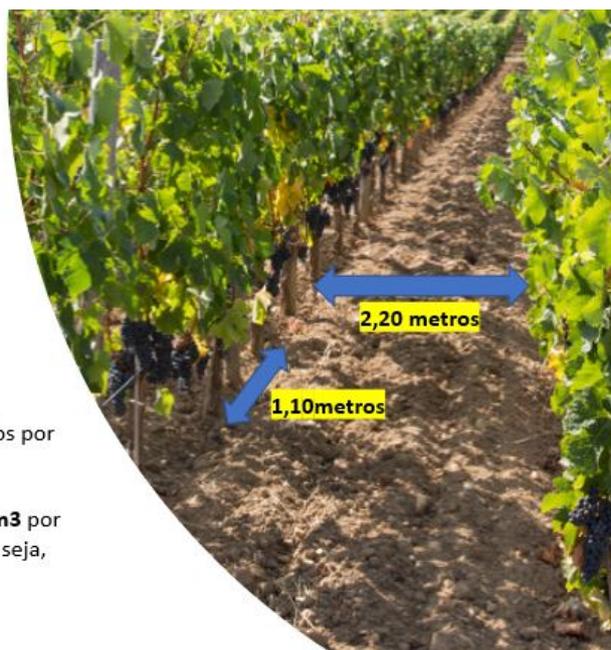


FIGURA 6.1. Dados da Vinha

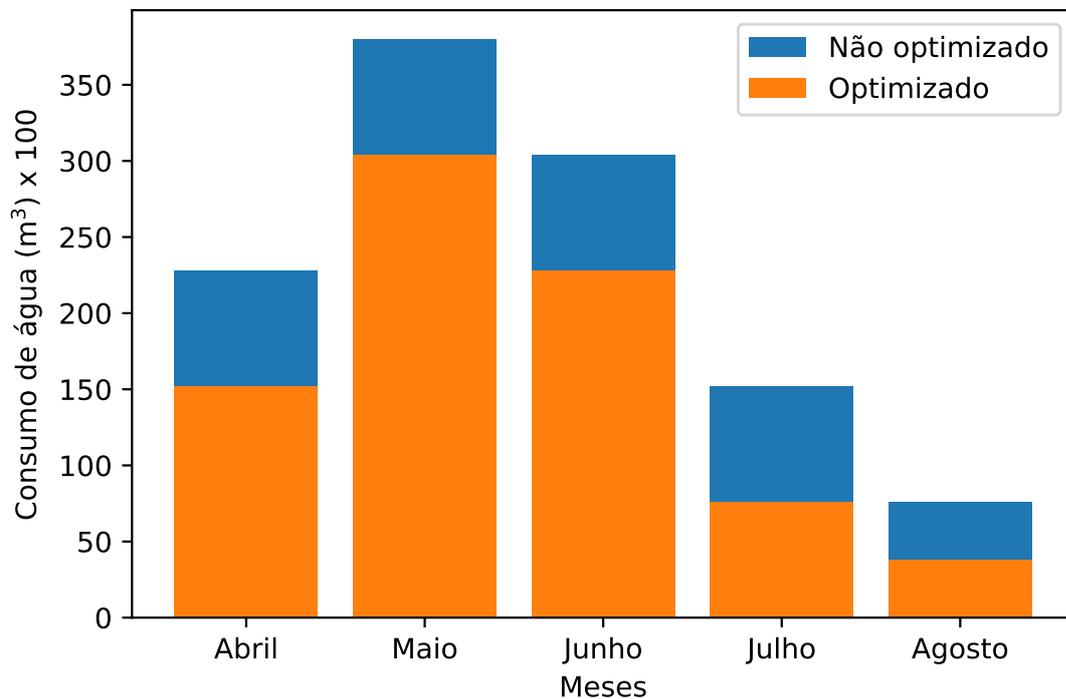


FIGURA 6.2. Litros de água gastos anualmente numa vinha com 50 ha

Na figura 6.1 estão presentes os dados da vinha necessários para os cálculos relativos ao consumo horário de água por hectare (ha). Relativamente à figura 6.2, a mesma apresenta os valores gastos de água **sem** e **com** a utilização do algoritmo na vinha.

Na figura 6.2 verifica-se nas barras laranja os litros de água (**79.800.000 litros**) dispensados na vinha utilizando o algoritmo para otimizar as horas de rega e por consequência a diminuição dos litros de água consumidos. Enquanto que sem a utilização do algoritmo, acresce um gasto elevado de litros de água (**34.200.000 litros**) (barras azuis do gráfico).

A utilização do algoritmo, na medida em que já se localizou as zonas de maior humidade, permite diminuir as horas de rega (diminui-se 1h/diária de rega em cada mês com a utilização do algoritmo) e deste modo poupar **34.200.000 litros** de água anualmente em 50ha.

Traduzindo os números de litros de água que se consegue poupar para valores monetários, obtêm-se um valor médio na ordem dos 5.000 euros anuais, isto apenas nos meses de maior rega (entre Abril e Agosto). Os valores que aqui são apresentados foram facultados pelo Eng. Nuno Ramalho.

Referências

Chegada a fase de conclusão, é notório que se atingiu o objetivo proposto inicialmente. O modelo final tem a capacidade de detetar e localizar zonas de humidade nas imagens térmicas. As configurações escolhidas inicialmente foram assertivas, em 8 horas de processo de treino atingiu-se uma ótima performance, concluiu-se que os resultados foram de encontro com as expectativas.

A escolha recaiu sobre a Viticultura devido a ser uma vertente da agricultura que está em constante crescimento e cada vez mais procurada por investidores. O produto final que pode ser o vinho, é uma área em que os produtores pretendem personalizar e fabricar com os seus ideais de parâmetros, exemplo de parâmetro: litros de água disponibilizada à vinha.

Os aspetos positivos a destacar vão ao encontro do modelo final ter obtido uma deteção e localização do "objeto" pretendido na ordem dos 82% de exatidão.

Nos aspetos menos positivos, quero salientar que seria uma mais valia o *dataset* conter um maior número de imagens, no entanto o algoritmo atingiu resultados muito bons.

6.2. Trabalho Futuro

Uma sugestão de um trabalho de futuro, seria a câmara permitir guardar as coordenadas nas configurações de cada fotografia, ou seja, obter imagens térmicas georreferenciadas. Assim com as coordenadas das imagens permitiria fazer uma construção "quase" real do terreno fotografado, deste modo seria possível fazer uma reconstrução perfeita e identificar com maior exatidão os locais que se encontram com maior humidade.

Outra sugestão seria fazer várias passagens ao mesmo terreno em várias épocas do ano para aumentar significativamente o *dataset* do algoritmo, assim este conseguia analisar com maior critério quais são as zonas que realmente detêm humidade no seu interior.

Também seria interessante utilizar outros algoritmos, uma vez que teriam diferentes configurações em termos de parâmetros, logo o resultado final seria certamente diferente, sendo possível fazer uma comparação entre algoritmos.

Referências

- [1] J. Gago, C. Douthe, R. E. Coopman, P. P. Gallego, M. Ribas-Carbo, J. Flexas, J. Escalona, and H. Medrano, “UAVs challenge to assess water stress for sustainable agriculture,” *Agricultural Water Management*, vol. 153, pp. 9–19, 2015. [Online]. Available: <http://dx.doi.org/10.1016/j.agwat.2015.01.020>
- [2] K.R.Krishna, *Agricultural Drones - A Peaceful Pursuit*, A. A. Press, Ed. CRC Press, 2018.
- [3] N. Ramalho, “Importância do stress hidrico na viticultura,” Ponte de Sor, 2018.
- [4] I. Bennis, H. Fouchal, O. Zytoune, and D. Aboutajdine, “Drip Irrigation System using Wireless Sensor Networks,” *Proceedings of the Federated Conference on Computer Science and Information Systems*, vol. 5, pp. 1297–1302, 2015.
- [5] L.A.Viana, L.Zambolim, T.V.Sousa, and D.C.Tomaz, “POTENCIAL USO DE CÂMERA TER-MAL ACOPLADA A VANT PARA MONITORAMENTO DE CULTURAS,” *Brazilian Journal of Biosystems Engineering v. 12(3): 286-298, 2018*, vol. 12, no. 3, pp. 286–298, 2018.
- [6] M. Kerkech, A. Hafiane, and R. Canals, “Deep leaning approach with colorimetric spaces and vegetation indices for vine diseases detection in UAV images,” *Computers and Electronics in Agriculture*, vol. 155, no. July, pp. 237–243, 2018.
- [7] D. Turner, A. Lucieer, and C. Watson, “Development of an Unmanned Aerial Vehicle (UAV) for hyper resolution vineyard mapping based on visible , multispectral , and thermal imagery,” *Conference: Proceedings of 34th International Symposium on Remote Sensing of Environment*, 2011.
- [8] Emília Freire, “Gestão de precisão,” 2015. [Online]. Available: <https://www.vidarural.pt/insights/gestao-de-precisao/>
- [9] —, “Como ser mais eficiente em agricultura,” 2016. [Online]. Available: <https://www.vidarural.pt/insights/como-ser-mais-eficiente-em-agricultura/>
- [10] J. Valente, D. Sanz, A. Barrientos, J. del Cerro, Á. Ribeiro, and C. Rossi, “An air-ground wireless sensor network for crop monitoring,” *Sensors*, vol. 11, no. 6, pp. 6088–6108, 2011.
- [11] A. Mcbratney, B. WHELAN, T. ANCEV, and J. BOUMA, “Future Directions of Precision Agriculture,” *Precision Agriculture*, 6, no. July 2004, pp. 7–23, 2006.
- [12] T. Agriculture, “What Is Precision Ag?” 2018. [Online]. Available: <https://agriculture.trimble.com/blog/what-is-precision-ag/>
- [13] R. Rodrigues, “O que é vinicultura e viticultura?” 2018. [Online]. Available: <https://www.cpt.com.br/artigos/o-que-e-vinicultura-e-viticultura>
- [14] A. Matese and S. Di Gennaro, “Practical Applications of a Multisensor UAV Platform Based on Multispectral, Thermal and RGB High Resolution Images in Precision Viticulture,” *Agriculture*, vol. 8, no. 7, p. 116, 2018. [Online]. Available: <http://www.mdpi.com/2077-0472/8/7/116>

Referências

- [15] J. Primicerio, A. Matese, S. F. D. Gennaro, L. Albanese, S. Guidoni, and P. Gay, “Development of an integrated , low-cost and open-source system for precision viticulture : from UAV to WSN,” *EFITA-WCCA-CIGR Conference "Sustainable Agriculture through ICT Innovation" Turin, Italy*, no. June 2013, pp. 24–27, 2013.
- [16] A. T. Dos and V. d. C. O. e. d. T. d. R. Alentejo, ““ Benchmarking ” na Rega e Boas Praticas de Gestão da Rega da,” 2009.
- [17] J. Baluja, M. P. Diago, P. Balda, and J. Tardaguila, “Assessment of vineyard water status variability by thermal and multispectral imagery using an unmanned aerial vehicle (UAV),” *Irrigation Science*, no. 6, pp. 511–522, 2012.
- [18] M. Srbinovska, C. Gavrovski, V. Dimcev, and A. Krkoleva, “Environmental parameters monitoring in precision agriculture using wireless sensor networks,” *Journal of Cleaner Production*, 2014. [Online]. Available: <http://dx.doi.org/10.1016/j.jclepro.2014.04.036>
- [19] M. S. Chaudhari, R. Jaiswal, C. Birhade, and V. Bhapkar, “Wireless Sensor Network as a Tool for Supporting Agriculture in the Precision Irrigation System,” *International Journal of Advanced Research in Computer and Communication Engineering*, vol. 4, no. 2, pp. 311–314, 2015.
- [20] H. Al-Saddik, A. Laybros, J. C. Simon, and F. Cointault, “Protocol for the Definition of a Multi-Spectral Sensor for Specific Foliar Disease Detection: Case of “Flavescence Dorée” ,” *Ship Design & Construction, Volume 1*, vol. 1875, pp. 1–31, 2019.
- [21] H. Al-Saddik, J. Simon, O. Brousse, and F. Cointault, “Multispectral band selection for imaging sensor design for vineyard disease detection: case of Flavescence Dorée,” *Advances in Animal Biosciences*, vol. 8, no. 02, pp. 150–155, 2017.
- [22] J. Albetis, S. Duthoit, F. Guttler, A. Jacquin, M. Goulard, H. Poilvé, J. B. Féret, and G. Dedieu, “Detection of Flavescence dorée grapevine disease using Unmanned Aerial Vehicle (UAV) multispectral imagery,” *Remote Sensing*, vol. 9, no. 4, pp. 1–20, 2017.
- [23] F. Vanegas, D. Bratanov, K. Powell, J. Weiss, and F. Gonzalez, “A novel methodology for improving plant pest surveillance in vineyards and crops using UAV-based hyperspectral and spatial data,” *Sensors (Switzerland)*, vol. 18, no. 1, pp. 1–21, 2018.
- [24] F. Vanegas, J. Weiss, and F. Gonzalez, “Multi and Hyperspectral UAV Remote Sensing : Grapevine Phylloxera Detection in Vineyards,” *2018 IEEE Aerospace Conference*, no. October, pp. 1–9, 2018.
- [25] F. Nex and F. Remondino, “UAV for 3D mapping applications : a review,” *Applied Geomatics*, pp. 1–15, 2013.
- [26] S. Siebert and J. Teizer, “Mobile 3D mapping for surveying earthwork projects using an Unmanned Aerial Vehicle (UAV) system,” *Automation in Construction*, vol. 41, pp. 1–14, 2014. [Online]. Available: <http://dx.doi.org/10.1016/j.autcon.2014.01.004>
- [27] I. Prates, “As mil e uma utilidades dos drones,” 2015. [Online]. Available: <https://mundogeo.com/blog/2015/09/10/as-mil-e-uma-utilidades-dos-drones/>
- [28] A. Raimundo, D. Peres, N. Santos, P. Sebastião, and N. Souto, “Autonomous Obstacle Collision Avoidance System for UAVs in Rescue Operations,” Ph.D. dissertation, ISCTE-IUL, 2016.

Referências

- [29] MoviTherm, “Thermal Infrared Imaging explained.” [Online]. Available: <http://movitherm.com/knowledgebase/thermal-infrared-imaging-explained/>
- [30] W. Carvalho, W. Rocha, and G. Galvão, “Visão computacional para detecção de doenças fúngicas na agricultura,” *Unica Cadernos Acadêmicos*, 2018.
- [31] G. CIMOLIN DA SILVA, “DETECÇÃO E CONTAGEM DE PLANTAS UTILIZANDO TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL E MACHINE LEARNING,” Ph.D. dissertation, Universidade Federal de Santa Catarina, 2017.
- [32] J. Brownlee, “A Gentle Introduction to Computer Vision,” 2019. [Online]. Available: <https://machinelearningmastery.com/what-is-computer-vision/>
- [33] E. C. Neto, E. S. Rebouças, J. L. Moraes, S. L. Gomes, and P. P. R. Filho, “Development Control Parking Access Using Techniques Digital Image Processing And Applied Computational Intelligence,” *IEEE Latin America Transactions*, no. February, 2015.
- [34] SAS, “Machine Learning - What it is and why it matters.” [Online]. Available: https://www.sas.com/en_us/insights/analytics/machine-learning.html#machine-learning-users
- [35] Daniel Faggella, “What is Machine Learning?” 2019. [Online]. Available: <https://emerj.com/ai-glossary-terms/what-is-machine-learning/>
- [36] T. M. Mitchell, “The Discipline of Machine Learning,” no. July, 2006.
- [37] J. DeMuro, “What is a neural network?” 2018. [Online]. Available: <https://www.techradar.com/news/what-is-a-neural-network>
- [38] C. Nicholson, “A Beginner’s Guide to Neural Networks and Deep Learning.” [Online]. Available: <https://skymind.ai/wiki/neural-network#define>
- [39] JAMES CHEN, “Neural Network - What is a Neural Network?” 2019. [Online]. Available: <https://www.investopedia.com/terms/n/neuralnetwork.asp>
- [40] MathWorks, “What Is Deep Learning?” [Online]. Available: <https://www.mathworks.com/discovery/deep-learning.html> e Artigo- Neural networks and deep learning.html
- [41] J. Brownlee, “What is Deep Learning?” 2016. [Online]. Available: <https://machinelearningmastery.com/what-is-deep-learning/>
- [42] M. Nielsen, *Neural Networks and Deep Learning*.
- [43] MathWorks, “Convolutional Neural Network.” [Online]. Available: <https://www.mathworks.com/solutions/deep-learning/convolutional-neural-network.html>
- [44] R. Sakurai, “Implementando a estrutura de uma Rede Neural Convolutacional utilizando o MapReduce do Spark,” 2017. [Online]. Available: <http://rafaelsakurai.github.io/cnn-mapreduce/>
- [45] D. BRITZ, “Recurrent Neural Networks Tutorial, Part 1 – Introduction to RNNs,” 2015. [Online]. Available: <http://www.wildml.com/2015/09/recurrent-neural-networks-tutorial-part-1-introduction-to-rnns/>
- [46] Data Science Academy, “Redes Neurais Recorrentes,” in *Deep Learning Book*, ch. 48. [Online]. Available: <http://deeplearningbook.com.br/redes-neurais-recorrentes/>

Referências

- [47] R. L. Rocha, A. C. Q. Siravenha, A. C. S. Gomes, G. L. Serejo, A. F. B. Silva, L. M. Rodrigues, J. Braga, G. Dias, S. R. Carvalho, and C. R. B. de Souza, “Avaliação de técnicas de Deep Learning aplicadas à identificação de peças defeituosas em vagões de trem,” *Workshop of Industry Applications (Wia)*, no. February 2018, 2017.
- [48] S. Hijazi, R. Kumar, C. Rowen, G. IP, and Cadence, “What is a CNO?” *Cadence*, vol. 95, no. 27, p. 15, 2015.
- [49] P. A. Nortes, “Using high resolution UAV thermal imagery to assess the variability in the water status of five fruit tree species within a commercial orchard,” *Precision Agric*, 2013.
- [50] L. G. Santesteban, S. F. D. Gennaro, A. Herrero-langreo, C. Miranda, J. B. Royo, and A. Matese, “High-resolution UAV-based thermal imaging to estimate the instantaneous and seasonal variability of plant water status within a vineyard,” *Agricultural Water Management*, vol. 183, pp. 49–59, 2017. [Online]. Available: <http://dx.doi.org/10.1016/j.agwat.2016.08.026>
- [51] P. V. Arun, I. Herrmann, K. M. Budhiraju, and A. Karnieli, “Pattern Recognition,” in *Pattern Recognition*. Elsevier Ltd, 2018, ch. Convolutio, pp. 431–446. [Online]. Available: <https://doi.org/10.1016/j.patcog.2018.11.033>
- [52] A. Raimundo, P. Sebastião, and R. Laureano, “Improving Vision-based Industrial Maintenance Inspections : Optimization & Performance Analysis of Deep Learning Classification Models,” pp. 1–15, 2020.
- [53] D. Godoy, “Understanding binary cross-entropy / log loss: a visual explanation,” 2018. [Online]. Available: <https://towardsdatascience.com/understanding-binary-cross-entropy-log-loss-a-visual-explanation-a3ac6025181a>
- [54] J. Brownlee, “Understand the Impact of Learning Rate on Neural Network Performance,” 2019. [Online]. Available: <https://machinelearningmastery.com/understand-the-dynamics-of-learning-rate-on-deep-learning-neural-networks/>
- [55] —, “Overfitting and Underfitting With Machine Learning Algorithms,” 2016. [Online]. Available: <https://machinelearningmastery.com/overfitting-and-underfitting-with-machine-learning-algorithms/>
- [56] K. Ramasubramanian and J. Moolayil, *Applied Supervised Learning with R*, 2019.
- [57] C. Lin, M. Guo, C. Li, W. Wu, J. Yan, D. Lin, and W. Ouyang, “Online Hyper-parameter Learning for Auto-Augmentation Strategy,” *Computer Vision and Pattern Recognition*, 2019.
- [58] J. Brownlee, “How to Configure Image Data Augmentation in Keras,” 2019. [Online]. Available: <https://machinelearningmastery.com/how-to-configure-image-data-augmentation-when-training-deep-learning-neural-networks/>
- [59] MissingLink, “7 Types of Neural Network Activation Functions: How to Choose?” 2019. [Online]. Available: <https://missinglink.ai/guides/neural-network-concepts/7-types-neural-network-activation-functions-right/>
- [60] S. Tiwari, “Activation functions in Neural Networks,” 2019. [Online]. Available: <https://www.geeksforgeeks.org/activation-functions-neural-networks/>

Referências

- [61] D. S. Academy, “Data Science Academy. Deep Learning Book,” p. Capítulo10, 2019. [Online]. Available: <http://deeplearningbook.com.br/as-10-principais-arquiteturas-de-redes-neurais/>
- [62] A. G. Howard and M. Zhu, “MobileNets: Open-Source Models for Efficient On-Device Vision,” 2017. [Online]. Available: <https://ai.googleblog.com/2017/06/mobilenets-open-source-models-for.html>
- [63] M. Hollemans, “MobileNet version 2,” 2018. [Online]. Available: <https://machinethink.net/blog/mobilenet-v2/>
- [64] F. Cintra, “O que é MobileNet?” 2019. [Online]. Available: <https://blog.fellyph.com.br/javascript/o-que-e-mobilenet/>
- [65] MissingLink, “Keras ResNet: Building, Training & Scaling Residual Nets on Keras.” [Online]. Available: <https://missinglink.ai/guides/keras/keras-resnet-building-training-scaling-residual-nets-keras/>
- [66] Deep AI, “What is an Inception Module?” 2019. [Online]. Available: <https://deepai.org/machine-learning-glossary-and-terms/inception-module>
- [67] D. Vaishnav, “ML — Inception Network V1,” 2018. [Online]. Available: <https://www.geeksforgeeks.org/ml-inception-network-v1/>
- [68] I. Nomerovska, “Image Processing Techniques: What Are Bounding Boxes?” 2020. [Online]. Available: <https://keymakr.com/blog/what-are-bounding-boxes/>
- [69] J. Hui, “SSD object detection: Single Shot MultiBox Detector for real-time processing,” 2018. [Online]. Available: https://medium.com/@jonathan_hui/ssd-object-detection-single-shot-multibox-detector-for-real-time-processing-9bd8deac0e06
- [70] ArcGIS API, “How single-shot detector (SSD) works?” 2019. [Online]. Available: <https://developers.arcgis.com/python/guide/how-ssd-works/>
- [71] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.-y. Fu, and A. C. Berg, “SSD : Single Shot MultiBox Detector,” *Computer Vision and Pattern Recognition*, pp. 1–15, 2016.
- [72] L. Li, S. Zhang, and J. Wu, “Efficient Object Detection Framework and Hardware Architecture for Remote Sensing Images,” <https://www.mdpi.com/>, pp. 1–29, 2019.
- [73] MathWorks, “Getting Started with R-CNN, Fast R-CNN, and Faster R-CNN,” 2020. [Online]. Available: <https://www.mathworks.com/help/vision/ug/getting-started-with-r-cnn-fast-r-cnn-and-faster-r-cnn.html>
- [74] Alegion, “Faster R-CNN,” 2019. [Online]. Available: <https://www.alegion.com/faster-r-cnn>
- [75] L. Weng, “Object Detection for Dummies Part 3: R-CNN Family,” 2017. [Online]. Available: <https://lilianweng.github.io/lil-log/2017/12/31/object-recognition-for-dummies-part-3.html>
- [76] J. C. Redmon, “YOLO: Real-Time Object Detection,” 2019. [Online]. Available: <https://pjreddie.com/darknet/yolo/>
- [77] J. Świeżewski, “YOLO Algorithm and YOLO Object Detection: An Introduction,” 2020. [Online]. Available: <https://appsilon.com/object-detection-yolo-algorithm/>
- [78] H. Shah, “YOLO Vs. SSD: Choice of a Precise Object Detection Method,” 2018. [Online]. Available: <https://technostacks.com/blog/yolo-vs-ssd/>

Referências

- [79] Deep AI, “What is TensorFlow?” 2018. [Online]. Available: <https://deepai.org/machine-learning-glossary-and-terms/tensorflow>
- [80] M. Rouse, “TensorFlow,” 2018. [Online]. Available: <https://searchdatamanagement.techtarget.com/definition/TensorFlow>
- [81] Techopedia, “TensorFlow,” 2018. [Online]. Available: <https://www.techopedia.com/definition/32862/tensorflow>
- [82] M. Heller, “What is Keras? The deep neural network API explained,” 2019. [Online]. Available: <https://www.infoworld.com/article/3336192/what-is-keras-the-deep-neural-network-api-explained.html>
- [83] R. Chandra, “The What’s What of Keras and TensorFlow,” 2019. [Online]. Available: <https://www.upgrad.com/blog/the-whats-what-of-keras-and-tensorflow/>
- [84] S. Goswami, “Reflections on Non Maximum Suppression (NMS),” 2020. [Online]. Available: <https://medium.com/@whatdhack/reflections-on-non-maximum-suppression-nms-d2fce148ef0a>
- [85] E. PLANETIERS, “Água em Portugal: porquê, quando e como poupar água,” 2019. [Online]. Available: <https://www.simplyflow.pt/agua-em-portugal-porque-quando-e-como-poupar-agua/>

APÊNDICE A

Registo do dia da recolha de dados



FIGURA A.1. Drone em voo



FIGURA A.2. Drone em voo sobre uma das vinhas



FIGURA A.3. Drone em posição de aterragem e descolagem



FIGURA A.4. Drone em posição de aterragem e descolagem sobre um tapete



FIGURA A.5. Paisagem de uma das vinhas fotografadas



FIGURA A.6. Mecanismo de controlo do drone composto por um *tablet* e um comando

APÊNDICE B

Artigo da Dissertação

O artigo da dissertação foi submetido para o Journal Sensors, Special Issue "Sensors and Deep Learning for Digital Image Processing".

Water Stress Analysis System for Vineyard Applications Supported by UAVs

1st João Francisco Martins
ISCTE-IUL
Lisboa, Portugal
jfdal@iscte-iul.pt

2nd Pedro Sebastião
ISCTE-IUL
Lisboa, Portugal
pedro.sebastiao@iscte-iul.pt

3rd António Raimundo
ISCTE-IUL
Lisboa, Portugal
aslro@iscte-iul.pt

Abstract—This article presents a system composed by an UAV with an attached thermal camera, which was used to fly over a vineyard, taking thermal images. These images contains temperature readings of the vineyard on every pixel in order to analyse vineyard's regions which contains lower values of temperature, which represent regions with a high concentration of humidity. The objective of this work is to use a pre-trained machine learning algorithm to detect areas of humidity in thermal images. This System has two principal features: High resolution of thermal camera, as it allows to know exactly the temperature in any place in the vineyard; The use of a machine learning algorithm to automatically classify regions with excess of humidity levels, in which the performance results were satisfactory. This classification is very useful in precision viticulture and agriculture, in order to optimise water resource usage and irrigation plans.

Index Terms—UAV, Thermal Camera, algorithm, detection, water stress, humidity

I. INTRODUCTION

In Portugal, there are 189.000 ha of vineyard and it's the largest European vineyard area. It represents 2.0% of national territory and its contribution is 1282 M€ for business dimension of the country. The wine industry has a huge impact for the economical development of Portugal. Two of the main problems that wine sector have is: The excessive use of hydric resources and the opposite: its absence. These problems contribute for one of the principal adversities that viticulture is facing. The vines damaged by water stress are vulnerable due to decreased speed of germination, fertility, growing of the plant, reduction of photosynthetic activity, dry leaves and increased plant transpiration. [1] [2] [3].

The advance of technology forced human beings to not be stuck in time, where a constant progress in technology evolution is required to implement simpler, better and faster processes. Concerning the viticulture sector, it's very important to make a continuous monitoring and surveillance, in order to find the first symptoms of water stress, so that immediate action can be done as soon as possible to identify dry and/or water abundance zones. This analysis is an essential process in order to maximise productivity and to perform a better management of hydric resources, with a constant focus in environmental sustainability, which will become the biggest control of monetary resources.

Due to those reasons, the use of last-tech and highly sophisticated sensors coupled to Unmanned Aerial Vehicles

(UAVs) is required to get detailed analysis with the constant aim of strengthening the agricultural production. [3].

The main goal of this work is to develop a system supported by an UAV and a specific sensor: a thermal camera, which will be used to perform automated flights over vineyard sites with the purpose of getting the necessary data, so that in a posterior stage, the analysis and processing of the obtained results of camera can be made. The goal of this system consists in evaluating the vines and soil, regarding the following:

- Water stress analysis;
- Dry plants detection;
- Regions with excess or shortage of water;
- Water leaks detection.

In order to achieve these analysis, a machine learning algorithm was implemented and some intermediary steps were performed:

- Sensor configuration leading to algorithms optimisation ;
- Implementation of an optimised computer vision algorithm for image analysis and detection;
- Fine-tuning and precision checks.

Due to the steps mentioned above, it is possible to get an accurate overview of the vineyard humidity levels, detecting regions with high humidity levels. This monitoring can greatly increase vineyards and soil productivity and reduce water resource usage.

II. PRECISION AGRICULTURE

Precision Agriculture (PA) consists in almost perfect execution, at the right time, at the right quantity and on the right region. Nowadays, high-tech methods are expanding to new areas. And when it comes to the agriculture sector, a lot of variables need to be taking into account when performing PA tasks. Variables such as weather conditions, humidity indexes, soil quality and health indexes, vegetative states, crop pests and diseases, and many others. These parameters can be analysed, in order to achieve better productivity, quality and profitability values of the soil and crops. [4] [5].

The fusion between agriculture and technology can solve existing problems in traditional methods. PA allows to manage and analyse in the best way any specific agricultural production: Soil, overall plantation, the plant itself, and the fruit. PA's main goal is to develop support systems to help farmers

make appropriate decisions based on the constant monitoring of fields, which final goal is to optimise the final product. [5] [6].

A. Precision Viticulture

Viticulture is the science that studies the grape cultivation and harvesting. Grapes can also be used for juice and raisins production. By applying technology to the viticulture sector, the concept of Precision Viticulture (PV) is created, which will allow the development of several high-tech and brand new methods, solving existing problems on conventional viticulture methods, maximising productivity, as well as to optimise the agronomic profitability, so that the costs are minimised and environmental sustainability is maintained. [7] [8] [9].

Figure 1 shows the advantages of using PV.



Fig. 1. Advantages of using PV

By using an UAV with an attached thermal camera, vineyards can be visualised from the sky in order to get a general overview of the vineyard. Temperature readings are achieved by using thermal imagery, in which every pixel of the image taken has temperature information. For humidity readings, it is essential to perform manual analysis of a thermal image. Lower temperature values represent regions with high humidity levels. Higher temperature values represent dry regions and humidity absence. Since the main goal is to detect regions with high humidity values, this process is essential in order to serve as an input for the developed algorithm. This process will help managing hydric resources, avoid dry regions, with the main goal of diminishing the negative effects of water stress. Water irrigation of a certain local must be planned according to analysed thermal imagery, attending to the requirements of a specific agricultural culture. This process will help optimising hydric resources, reduce costs and to make a sustainable environmental water irrigation process. [10].

There are several advantages in using UAVs in agricultural and/or industrial sectors:

- Easy and fast to use
- Non-destructive and non-intrusive
- High resolution and high flexibility in image acquisition
- Easy to transport
- An economic solution

The most common solutions to perform PV analysis are: Network of locally installed sensors; Analysis by using specific sensors attached to an UAV. The sensors network needs to be installed manually by a human operator and the number of sensors used will depend on the size of vineyard (more sensors will increase coverage area). This can be expensive

and time consuming. By using UAV technology, and when compared with the sensors network, an UAV is capable of flying through a vineyard, with a great coverage area in short periods of time. There is no need for a human operator and the execution time for this operation is drastically decreased, when compared with the sensors network.

Nowadays, there are many companies in Portugal acting in this area. Using satellite imagery, it is possible to obtain detailed information of cultivated fields allowing farmers to know exactly the vegetation distribution on their plantations. However, and most of the times, the available data online is outdated and the visualised areas might not correspond to reality.

The newly defined concept of “Internet of Things” and their applications are becoming very popular nowadays. There are some projects developed, where PV is applied, that make use of mobile solutions, wireless communications, network of sensors and digital multimedia. Using navigation and positioning systems, such as GPS, a farmer can visualise any kind of data about their crops, almost in a real time from any remote place.

In France [11] [12], an UAV with an attached multispectral camera was used to identify regions with *Flavescence Dorée* disease. A neuronal network was used to automatically classify the disease based on the data gathered by the multispectral camera.

In [9], images of infected vines were taken by using a visual camera. In this method, there was combination between the use of neuronal network with several colour spaces, and vegetation indices to find possible disease symptoms. In [13] and [14], vines were overflown and examined to increase the efficiency of saving against the whole of insects and also to detect *Filoxera* (a very common disease in vineyards). This process was made with the help of multispectral and hyperspectral cameras. In [12], a multispectral camera was used to evaluate the plant condition, where it was also used a thermal camera to verify the temperature of the leave in the plant, as well as a RGB (Red, Green, Blue) high resolution camera to find the breaks in vegetation.

III. METHODOLOGY

A. AI Algorithms

Computer Vision (CV) is an area that focus literally in the *vision* of machines and robots. The main goal is intended to investigate hypotheses and methods, with the aim of collecting relevant information from a given image. This area of science aims to develop computational models identical to the human visual field that allow differentiating, modifying and examining objects that are part of the image. [15] [16].

After data gathering, imagery analysis and interpretation is needed. One of the features of CV is image recognition, which consists of the identification of patterns, objects and colours in order to obtain the desired information. This component meets the goal of this work, which consists in the detection of humidity regions in vineyards. This method the images captured by the specific sensor (RGB and/or thermal), processing them

by using an artificial intelligence algorithm trained to identify regions with excess of humidity.

The term *Machine Learning* (ML) is a branch of Artificial Intelligence algorithms that have the ability to receive data and use statistical analysis to predict an output. [17].

On the other hand, *Deep Learning* is a subfield of ML that correlates algorithms based on the structure and function of the human brain, called Convolutional Neural Networks (CNNs), with greater incidence in the study and analysis of images [18]. These have the ability to produce filters autonomously, being able to identify very detailed patterns that adjust to imperfections and geometric modifications. Recurring Neural Networks (RNNs) are called recurring neural networks because they perform the same task for each element of a sequence, with the output dependent on the calculations previously performed. These have a memory that stores information about what has already been calculated so far. [19].

A CNN was used because they have the capacity to develop an internal representation of a two-dimensional image. This allows the model to learn and identify a position and scale in different structures in the data, which is fundamental when working with images. [20].

Figure 2 shows the internal behaviour of a CNN algorithm:

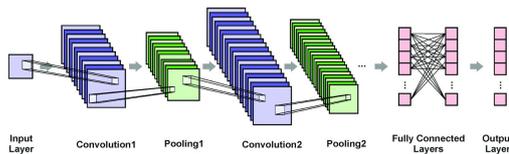


Fig. 2. Operation method of a CNN

The convolutional network typology chosen was the Mobile Single Shot Detection (SSD) due to its ability to achieve a balance between speed and precision in object detection. The SSD significantly outperforms the Faster R-CNN (Region-based Convolutional Neural Networks) in terms of accuracy and is faster in real time than the YOLO (You only look once) alternative. This model is relatively simple and is considered as a useful tool for larger systems that holds an object detection component. [21] [22] [23].

B. System architecture

1) *UAV*: UAVs are a very versatile technology. Nowadays, they are widely used in several areas such as: protection and surveillance of the sea coast, surveillance of forests, coverage of filming events, mapping of land and entertainment, among others. There are software applications developed to communicate with the UAV, with a visual interface where he can visualise the data collected from sensors, maintaining a reliable communication with the UAV. [24].

There are two different models of UAVs, each one with its way of landing and taking off, aerodynamic features and fly modes: The fixed-wing UAV and the multi-rotor UAV. In this project we used the multi-motor UAV instead of the fixed

wing drone. A multi-rotor UAV has no wings and has the ability of hovering in mid-air. The way it behaves is similar to a helicopter, they take off and land vertically. When compared to fixed-wing UAVs, they fly at lower speeds but have greater control of action, which is an excellent feature. Because they have several motors, they consume more power and have less autonomy. The most common UAVs of this type are the tri-copter, quadcopter, hexacopter and octocopter. [25].

This UAV was used due to the need of an accurate analysis of the vineyards. that is intended to carry out humidity detection on vineyard. High flight altitudes will be not necessary, but great control and stability is required.

Figure 3 shows the UAV that was used on this work:



Fig. 3. Quadcopter UAV, the RC controller and the visual interface (tablet).

2) *Sensors*: For the intended purpose of this work, the sensor used was a thermal camera (FLIR Vue Pro). This camera is capable of detecting heat in the Infra Red (IR) spectrum. It can acquire temperature readings in the range of -20°C to 50°C with high precision. It provides high resolution images and is very light-weighted (Weight: 113.4g), which is essential for increased flight times. With these features in mind, it is the most suitable sensor, meeting the requirement for humidity detection.

Figure 4 represents the thermal camera already attached to the UAV.

IV. TESTS AND RESULTS

Regarding the dataset obtained, in partnership with Eng. Nuno Ramalho and Skyverse portuguese company, the test took place in a vineyard near Ponte de Sor, Portalegre, Portugal. The UAV flew over a vineyard with a total area of 2 ha, obtaining thermal images required for this work.

Figure 5, the analysed vineyard A is shown:

A total of 280 images was obtained:

- Images for training – 250;
- Image for test – 30;

With the obtained images, the manual classification of images was made for training trough labelImg software application image. Using labelBoxes, boxes placed in humidity zones, just in the training images. In next stage the tool



Fig. 4. Thermal Camera - FLIR Vue Pro



Fig. 5. Vineyard A

TensorFlow, open source library for numerical computation and machine learning, was used to train the algorithm. A pre-trained algorithm (in order to detect "objects") to identify the zones with humidity, was also used.

A new class named "Humidity" was defined, this class consists on manual classified thermal images. The algorithm used the class to learn, to detect and locate the humidity zones. This class "Humidity" was fundamental to obtain good results, since it's for her that the algorithm is based on to learn to make decisions and to do characterisations. A new dataSet was inserted (250 thermal images) in the algorithm, and there was a training (8hours) to identify zones of humidity inside the thermal images.

Figure 6, the type of photo shows the result of the thermal camera, where the dark blues zones correspond to the humidity zones, and orange/yellow and red zones correspond to the no humidity zones.

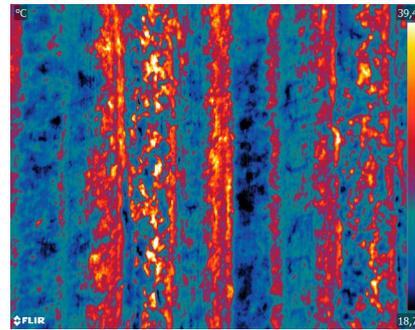


Fig. 6. Thermal Image of a certain sector on the vineyard.

At last, with trained algorithm the tests started in the thermal images with no classification (image of test). In the figure 7, the final result of classification and location of humidity zones got by the algorithm, was observed. In the picture 7, it can also be observed two zones with humidity, while it can also be observed some blues zones, however the algorithm doesn't consider them as relevant humidity zones. It's extremely important too, that the algorithm is able not to detect and analyse a no humidity zone.

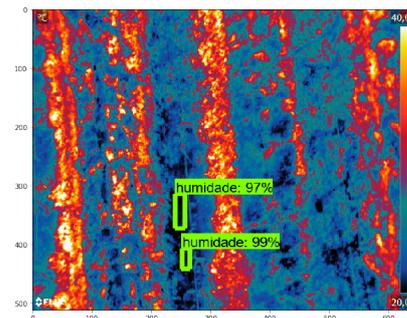


Fig. 7. Detection of the class "Humidity " in the thermal image

V. CONCLUSION

The vineyard visit has proven to be very effective to collect the dataSet (thermal images), due to the fact that these images are the key element for this work.

The results show that thermal images have a huge potential to be increasingly used in precision viticulture. They can be used for soil analysis and precision irrigation management. They also allow to detect anomalies that are essential in the control and management of an agricultural culture.

It's necessary to be aware, concerning the saving and never waste water. This is really important to get this goal in the area of agriculture.

Anexo B. Artigo da Dissertação

The algorithm reached the expected result, being able to detect the target humidity, as shown in figure 7. In the 30 test images, a satisfactory degree was obtained in 90% of the images.

It would be very interesting, if several images could be collected in vineyard during the year, so that the evolution of humidity can be understood, paying attention to the growing period of the plant, helping even more precisely the farmer to his decision making.

ACKNOWLEDGMENT

I would like to thank Prof. Dr. Pedro Sebastião, António Raimundo, Eng. Nuno Ramalho, Rodrigo Sebastião, Mariana Barros, Daniel Fernandes, João Pedro Pavia, António Abreu da Silva, António Monteiro.

REFERENCES

- [1] K.R.Krishna, *Agricultural Drones - A Peaceful Pursuit*, A. A. Press, Ed. CRC Press, 2018.
- [2] S. Almeida, "Stress hídrico - Conceito de stress hídrico," 2017. [Online]. Available: <http://knoow.net/cienterravida/biologia/stress-hidrico/>
- [3] L.A.Viana, L.Zambolim, T.V.Sousa, and D.C.Tomaz, "POTENCIAL USO DE CÂMERA TERMAL ACOPLADA A VANT PARA MONITORAMENTO DE CULTURAS," *Brazilian Journal of Biosystems Engineering v. 12(3)*: 286-298, 2018, vol. 12, no. 3, pp. 286-298, 2018.
- [4] Emília Freire, "Gestão de precisão," 2015. [Online]. Available: <https://www.vidarural.pt/insights/gestao-de-precisao/>
- [5] —, "Como ser mais eficiente em agricultura," 2016. [Online]. Available: <https://www.vidarural.pt/insights/como-ser-mais-eficiente-em-agricultura/>
- [6] A. Mcbratney, B. WHELAN, T. ANCEV, and J. BOUMA, "Future Directions of Precision Agriculture," *Precision Agriculture*, 6, no. July 2004, pp. 7-23, 2006.
- [7] R. Rodrigues, "O que é viticultura e viticultura?" 2018. [Online]. Available: <https://www.cpt.com.br/artigos/o-que-e-viticultura-e-viticultura>
- [8] A. Matese and S. Di Gennaro, "Practical Applications of a Multisensor UAV Platform Based on Multispectral, Thermal and RGB High Resolution Images in Precision Viticulture," *Agriculture*, vol. 8, no. 7, p. 116, 2018. [Online]. Available: <http://www.mdpi.com/2077-0472/8/7/116>
- [9] M. Kerkech, A. Hafiane, and R. Canals, "Deep learning approach with colorimetric spaces and vegetation indices for vine diseases detection in UAV images," *Computers and Electronics in Agriculture*, vol. 155, no. July, pp. 237-243, 2018.
- [10] J. Baluja, M. P. Diago, P. Balda, and J. Tardaguila, "Assessment of vineyard water status variability by thermal and multispectral imagery using an unmanned aerial vehicle (UAV)," *Irrigation Science*, no. 6, pp. 511-522, 2012.
- [11] H. Al-Saddik, J. Simon, O. Brousse, and F. Cointault, "Multispectral band selection for imaging sensor design for vineyard disease detection: case of Flavescence Dorée," *Advances in Animal Biosciences*, vol. 8, no. 02, pp. 150-155, 2017.
- [12] J. Albetis, S. Duthoit, F. Guttler, A. Jacquin, M. Goulard, H. Poilvé, J. B. Féret, and G. Dedieu, "Detection of Flavescence dorée grapevine disease using Unmanned Aerial Vehicle (UAV) multispectral imagery," *Remote Sensing*, vol. 9, no. 4, pp. 1-20, 2017.
- [13] F. Vanegas, D. Bratanov, K. Powell, J. Weiss, and F. Gonzalez, "A novel methodology for improving plant pest surveillance in vineyards and crops using UAV-based hyperspectral and spatial data," *Sensors (Switzerland)*, vol. 18, no. 1, pp. 1-21, 2018.
- [14] F. Vanegas, J. Weiss, and F. Gonzalez, "Multi and Hyperspectral UAV Remote Sensing : Grapevine Phylloxera Detection in Vineyards," *2018 IEEE Aerospace Conference*, no. October, pp. 1-9, 2018.
- [15] W. Carvalho, W. Rocha, and G. Galvão, "Visão computacional para detecção de doenças fúngicas na agricultura," *Unica Cadernos Acadêmicos*, 2018.
- [16] G. CIMOLIN DA SILVA, "DETECÇÃO E CONTAGEM DE PLANTAS UTILIZANDO TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL E MACHINE LEARNING," Ph.D. dissertation, Universidade Federal de Santa Catarina, 2017.
- [17] M. Rouse, "machine learning (ML)," 2018. [Online]. Available: <https://searchenterpriseai.techtarget.com/definition/machine-learning-ML>
- [18] J. Brownlee, "What is Deep Learning?" 2016. [Online]. Available: <https://machinelearningmastery.com/what-is-deep-learning/>
- [19] D. BRITZ, "Recurrent Neural Networks Tutorial, Part 1 - Introduction to RNNs," 2015. [Online]. Available: <http://www.wildml.com/2015/09/recurrent-neural-networks-tutorial-part-1-introduction-to-rnns/>
- [20] J. Brownlee, "When to Use MLP, CNN, and RNN Neural Networks," 2018. [Online]. Available: <https://machinelearningmastery.com/when-to-use-mlp-cnn-and-rnn-neural-networks/>
- [21] H. Shah, "YOLO Vs. SSD: Choice of a Precise Object Detection Method," 2018. [Online]. Available: <https://technostacks.com/blog/yolo-vs-ssd/>
- [22] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.-y. Fu, and A. C. Berg, "SSD : Single Shot MultiBox Detector," *European Conference on Computer Vision*, 2016.
- [23] R. Gandhi, "R-CNN, Fast R-CNN, Faster R-CNN, YOLO - Object Detection Algorithms," 2018. [Online]. Available: <https://towardsdatascience.com/r-cnn-fast-r-cnn-faster-r-cnn-yolo-object-detection-algorithms-36d53571365e>
- [24] I. Prates, "As mil e uma utilidades dos drones," <https://mundogeo.com/>, 2015. [Online]. Available: <https://mundogeo.com/blog/2015/09/10/as-mil-e-uma-utilidades-dos-drones/>
- [25] A. Raimundo, D. Peres, N. Santos, P. Sebastião, and N. Souto, "Autonomous Obstacle Collision Avoidance System for UAVs in Rescue Operations," Ph.D. dissertation, ISCTE-IUL, 2016.