

# Avaliação de sensores aplicada à refletância das folhas para a fertilização sustentável em olival

Dissertação

Curso de Mestrado em Agricultura Sustentável

Maria Catarina Lopes Manuelito

Orientador: Doutor Luís Alcino Pinto Monteiro da Conceição

Coorientador: Doutora Rocío Arias Calderón

Elvas, 2024



Maria Catarina Lopes Manuelito

## Avaliação de sensores aplicada à refletância das folhas para a fertilização sustentável em olival

Dissertação apresentada para obtenção do grau de mestre em AGRICULTURA SUSTENTÁVEL conferido pelo Instituto Politécnico de Portalegre.

Orientador: Professor Doutor Luís Alcino da Conceição

Coorientador: Professora Doutora Rocío Arias Calderón

Arguente principal: Professor Doutor Manuel Joaquim Marques Patanita

Presidente do Júri: Professora Doutora Ana Isabel Rodrigues Cordeiro

Classificação: 18 valores

Escola Superior Agrária de Elvas

2024

# Agradecimentos

Chegada esta etapa do curso não podia deixar de agradecer a todos aqueles que me ajudaram ao longo deste caminho e tornaram tudo isto possível.

Ao professor Luís Alcino, agradeço todo o apoio profissional e académico que me tem dado ao longo deste tempo.

À Rocío e ao José Silvestre por desde o primeiro instante me terem dado todo o apoio e ajuda necessária ao início da minha atividade profissional, por me terem desafiado e mostrado que não devo ter receio em explorar novos caminhos.

À SISCOG que desde o momento que lhes foi proposto este desafio se mostraram bastante interessados e deram um apoio e uma ajuda incondicional.

Aos meus antigos e atuais colegas de trabalho que desde o primeiro momento me receberam de braços abertos, por partilharem comigo a sua sabedoria e por me proporcionarem uma ótima experiência profissional. Ao Doutor António e Doutora Carla por acreditarem no meu trabalho e por me darem a liberdade e autonomia necessária para a execução do mesmo. Aos meus restantes colegas, por alinharem nas minhas ideias e fazerem sempre que é necessário um esforço adicional.

À minha família, em particular aos meus pais, à minha irmã, à minha tia e à minha avó porque é graças a eles que tudo isto tem vindo a ser possível. Por me terem preparado para o futuro, por estarem presentes sempre que necessito e por me darem o apoio e incentivo que muitas vezes preciso. Ao meu colega de curso e namorado, João Ramos, por também estar presente sempre que preciso, por me ouvir e apoiar sempre.

A todos vocês, o meu muito obrigado.

Este trabalho foi desenvolvido no âmbito do projeto AI4RealAg – “Soluções de Inteligência Artificial e *Data Science* para a implementação e democratização da agricultura digital”, código POCI-01-0247-FEDER-069670, financiado pelo Programa Operacional Competitividade e Internacionalização, Programa Operacional Regional de Lisboa.

# Resumo

Com a intensificação das culturas, nomeadamente do olival, surgiram preocupações quanto ao consumo de água e ao impacto ambiental causado pelo uso de produtos fitofarmacêuticos e fertilizantes. Assente nesta preocupação, na União Europeia a estratégia Farm to Fork tem como algumas das principais metas até 2030 reduzir 50% a utilização dos pesticidas químicos e diminuir fatores que causem pelo menos 50% das perdas de nutrientes do solo. Com foco na eficiência de produção e sustentabilidade, esta dissertação tem como objetivo principal, através da deteção proximal, validar medições de refletância das folhas de oliveira (*Olea europaea* L.), obtidas com um sensor multiespectral de baixo-custo e um espectrómetro de alta resolução, para o diagnóstico nutricional em macronutrientes principais do olival. O ensaio decorreu no olival em sebe do Departamento de Olivicultura do INIAV, I.P., em Elvas no ano de 2022. Para esse efeito foi delineado um ensaio com fertilização diferenciada por fertirrega, durante o ciclo vegetativo, em três cultivares de oliveira, ‘Azeiteira’, ‘Arbequina’ e ‘Koroneiki’. O material vegetal foi recolhido na maturação dos frutos, somando um total de 120 amostras e um total de 14 400 folhas, onde posteriormente se procedeu às medições de refletância. Após a recolha de dados com os sensores, as folhas foram submetidas a análises químicas clássicas para quantificação de nutrientes. A correlação entre os dados recolhidos pelos sensores com o teor de macronutrientes principais mostrou ser bastante promissora com o espectrómetro de alta resolução onde se obtiveram os melhores resultados para o Fósforo ( $R^2$ : 0,67 – modelo KNeighborsRegressor) e Potássio ( $R^2$ : 0,60 – modelo SVR).

Palavras-chave: deteção proximal; diagnóstico nutricional; eficiência de produção; *Olea europaea* L..

# Abstract

With the intensification of agriculture, notably olive cultivation, there have arisen concerns regarding water consumption and the environmental impact caused using phytopharmaceutical products and fertilizers. Against this backdrop, one of the European Union's key objectives through its Farm to Fork strategy, aiming for 2030, is to cut the use of chemical pesticides by 50% and to reduce the factors causing at least 50% of soil nutrient loss. Focused on the efficiency and sustainability of production, the principal aim of this dissertation is to validate olive leaf (*Olea europaea* L.) reflectance measures through proximal detection, obtained with a low-cost multispectral sensor and a high-resolution spectrometer, for nutritional assessment and diagnosis in the main macronutrients of the olive grove. The trial was conducted in the hedge olive grove of the INIAV's Department of Olive Culture in Elvas, in the year 2022. For this purpose, a trial with differentiated fertilization by fertigation was designed during the vegetative cycle on three olive tree cultivars, 'Azeiteira', 'Arbequina', and 'Koroneiki'. The plant material was collected when the fruits matured, totaling 120 samples and 14 400 leaves, where reflectance measurements were subsequently taken. Following data collection with the sensors, the leaves underwent classical chemical analyses for nutrient quantification. The correlation between the data collected by the sensors and the content of the main macronutrients proved very promising with the high-resolution spectrometer, where the best results were obtained for Phosphorus ( $R^2$ : 0,67 – KNeighborsRegressor model) and Potassium ( $R^2$ : 0,60 – SVR model). Conversely, the low-cost sensor presented some difficulty in corroborating the results observed in the laboratory analyses, necessitating further tests for its validation.

Key words: efficiency of production; nutritional diagnosis; *Olea europaea* L.; proximal detection.

# Abreviaturas, Siglas e Acrónimos

% – Percentagem

°C – Graus Celsius

€ – Euro

ANOVA – Análise da Variância

BBCH – Biologische Bundesanstalt, Bundessortenamt and CHemical industry

CI – Compasso 3,75m x 1,80m

C2 – Compasso 3,75m x 1,35m

cm – centímetros

CV – Coeficiente de Variação

DP – Desvio Padrão

GNSS – Global Navigation Satellite Systems

GPS – Sistema de Posicionamento Global

ha – hectare

IA – Inteligência Artificial

INIAV – Instituto Nacional de Investigação Agrária e Veterinária

K – Potássio

K<sub>2</sub>O – Óxido de Potássio

kg - quilogramas

l/h – litros/hora

LED – Díodo emissor de luz

m – metro

m/s – metros/segundo

ML - Machine Learning

mm – milímetros

N – Azoto;

N/W – Norte/Oeste

NDVI – Índice de Vegetação por Diferença Normalizada

NIR – Infravermelho Próximo

nm – nanómetros

OLED – Diodo Orgânico Emissor de Luz

OLED – Díodos emissores de luz orgânicos

P – Fósforo

P<sub>2</sub>O<sub>5</sub> – Pentóxido de Fósforo

PCA – Análise de Componentes Principais

PCA – Análise de Componentes Principais

PCB – Placa de circuito impresso

PCB – Placa de Circuito Impresso

pH – Potencial de Hidrogénio

PIB – Produto Interno Bruto

R<sup>2</sup> – Coeficiente de Determinação

RGB – Vermelho, Verde, Azul

SD – Digital Seguro

SISCOG – Software de otimização para empresas de transporte

spec – Espectrómetro FLAME

SVR – Support Vector Regression

T0 – Testemunha

T1 – Fertilização Recomendada

T2 – Fertilização Superior à Recomendada

UAV – Veículo Aéreo Não Tripulado

uhu – Sensor de baixo-custo

USB – Universal Serial Bus

UV – Ultra-Violeta

V1 – Azeiteira

V2 – Arbequina

V3 – Koroneiki

# Índice Geral

Agradecimentos.....	i
Resumo.....	ii
Abstract.....	iii
Abreviaturas, Siglas e Acrónimos.....	iv
Índice Geral.....	vii
Índice de Quadros.....	ix
Índice de Figuras.....	x
1. Introdução e Objetivos.....	1
1.1. Introdução.....	1
1.2. Objetivos.....	2
2. Revisão Bibliográfica.....	3
2.1. Olivicultura, importância da cultura em Portugal.....	3
2.2. Sustentabilidade e Fertilização Racional do Olival.....	4
2.3. Olivicultura de Precisão.....	7
2.4. Detecção Remota.....	8
2.4.1. Imagens Multiespectrais Obtidas Através de UAVs.....	9
2.5. Detecção Remota Próxima.....	11
2.5.1. Outros Dispositivos Sensoriais (Baixo-Custo).....	12
2.5.2. Espectroscopia, Conceito e Aplicação em Nutrição Vegetal.....	13
2.6. Inteligência Artificial e Machine Learning.....	14
3. Material e Métodos.....	16
3.1. Projeto AI4RealAg.....	16
3.2. Local de Realização dos Ensaios.....	16
3.3. Caracterização Edafo-Climática.....	18
3.4. Procedimento experimental.....	22
3.4.1. Ensaio experimental.....	22
3.4.2. Recolha do material vegetal no campo.....	24

3.4.3. Leituras com sensores .....	25
3.4.3.1. Sensor Multiespectral de Baixo-Custo .....	25
3.4.3.2. Espectrômetro 'FLAME' .....	27
3.4.4. Metodologia Utilizada na Recolha de Dados com Sensores.....	28
3.4.5. Preparação das Amostras para Posterior Análise Química.....	29
3.4.6. Métodos Utilizados em Laboratório .....	30
3.4.7. Processamento dos dados .....	30
3.5. Tratamento Estatístico dos Dados.....	31
4. Resultados e Discussão .....	32
4.1. Análise Estatística Descritiva – Resultados das Análises Foliaves .....	32
4.2. Estatística Descritiva – Diagrama de Caixa (Boxplot).....	35
4.3. Análise de Variância (ANOVA) para os macronutrientes principais .....	38
4.3.1. ANOVA para a classe de tratamento .....	38
4.3.2. ANOVA para as classes de tratamento de fertilização, compasso e variedade .....	38
4.4. Tratamento de Dados dos Sensores .....	39
4.4.1. Análise de Componentes Principais (PCA).....	39
4.4.2. Resultados obtidos.....	40
5. Conclusões.....	42
6. Bibliografia .....	43
Anexos.....	50

# Índice de Quadros

Quadro 1: Dados climáticos de Elvas no período de 1971 a 2000, e 2022 .....	18
Quadro 2: Total de N-P-K (kg/ha) aplicado em 2022 .....	22
Quadro 3: Registo excel da informação do sensor de baixo-custo .....	28
Quadro 4: Registo excel da informação do espectrómetro .....	29
Quadro 5: Estatística descritiva e CV dos resultados das análises foliares (teor de nutrientes, expresso em %, na matéria seca) de T0 C1 .....	32
Quadro 6: Estatística descritiva e CV dos resultados das análises foliares (teor de nutrientes, expresso em %, na matéria seca) de T2 C1 .....	33
Quadro 7: Estatística descritiva e CV dos resultados das análises foliares (teor de nutrientes, expresso em %, na matéria seca) de T0 C2 .....	33
Quadro 8: Estatística descritiva e CV dos resultados das análises foliares (teor de nutrientes, expresso em %, na matéria seca) de T1 C2 .....	34
Quadro 9: ANOVA para a classe de tratamento, agrupada por variedade .....	38
Quadro 10: ANOVA para as classes de tratamento de fertilização, compasso e variedade.....	39
Quadro 11: Modelos com melhores resultados do Coeficiente de Determinação ( $R^2$ ) para o espectrómetro.....	40
Quadro 12: Modelos com melhores resultados do Coeficiente de Determinação ( $R^2$ ) para o sensor de baixo-custo.....	41
Quadro 13: Descrição dos modelos .....	41

# Índice de Figuras

Figura 1 – a) e b) Estrutura de custos por hectare de olival das explorações (média 2016 a 2018) .....	5
Figura 2 – Deteção remota .....	8
Figura 3 – Câmara Multiespectral de 5 bandas .....	10
Figura 4 – a) GreenSeeker; b) Espectrorradiómetro ASD FieldSpec® .....	12
Figura 5 – Subdomínios do ML .....	15
Figura 6 – Ortofoto com Drone (modelo Heidi, da Beyond Vision) com câmara Micasense (modelo Rededge) da localização do olival em sebe na Herdade do Reguengo .....	17
Figura 7 – Diagrama ombrotérmico de Gausen para Elvas para o período de 1991-2021 .....	19
Figura 8 – Diagrama ombrotérmico de Gausen para Elvas (segundo dados climáticos do ano agrícola de 2022 da Estação meteorológica da Herdade do Reguengo, INIAV, I.P.) .....	19
Figura 9 – Troço da carta de solos de Portugal nº 37A/414 (Escala 1:25000) com a delimitação da Herdade do Reguengo .....	20
Figura 10 – Distribuição textural do solo na Herdade do Reguengo (olival em sebe: parcela 1 e 2) .....	21
Figura 11 – Sequência das Operações Realizadas na elaboração do Ensaio Experimental do Ensaio Experimental .....	22
Figura 12 – Esquema do Delineamento experimental.....	23
Figura 13 – a) Marcação das árvores; b) Instalação da torneira no tubo de rega.....	24
Figura 14 – Constituição do equipamento multiespectral de baixo custo. ....	26
Figura 15 – Espectrómetro FLAME .....	27
Figura 16 – a) Espectrómetro de Alta Resolução; b) Dispositivo Multiespectral de Baixo-Custo; c) Conjunto de 120 folhas e conjunto de 10 folhas respetivamente .....	29
Figura 17 – a) Solução de água corrente e detergente; b) Solução de água destilada; c) Envelopes com respetivas amostras; d) Estufa Thermo Scientific: Heratherm OMS180 .....	30

Figura 18 – a) Organização dos dados do sensor de baixo-custo; b) Organização dos dados do Espectrómetro FLAME.....	31
Figura 19 – Distribuição das variedades por cada macronutriente principal .....	35
Figura 20 – V1 por tratamento de fertilização.....	36
Figura 21 – V2 por tratamento de fertilização.....	36
Figura 22 – V3 por tratamento de fertilização.....	37
Figura 23 – Distribuição dos macronutrientes principais por variedade .....	37

# I. Introdução e Objetivos

## I.1. Introdução

Na Europa, a área de olival é bastante representativa, ocupando cerca de seis milhões de hectares, sendo os países produtores em que esta cultura tem maior expressão Espanha, Itália, Grécia e Portugal (Pinto *et al.*, 2021). Nos próximos dez anos, Portugal pretende aumentar a produção de azeitona e, conseqüentemente, a produção de azeite, ambicionando assim alcançar a terceira posição do *ranking* de maior produtor de azeite mundial (Nobre, 2021). No Alentejo, nas últimas décadas e, fruto sobretudo da existência do perímetro de rega do Alqueva, tem ocorrido um aumento da área do olival, quer em modo de produção intensivo quer superintensivo, ocupando assim cerca de 61% deste perímetro de rega, equivalente a 68 659 ha (EDIA, 2021).

Ultimamente, o setor agrícola em geral tem vindo a sofrer cada vez mais várias pressões e desafios sociais (aumento da população mundial), ambientais (alterações climáticas) e económicos, como é o caso do aumento do preço dos combustíveis e fertilizantes. Tal obriga à necessidade de produzir mais com menos, incentivando a práticas agrícolas mais sustentáveis e eficientes.

Para que tal seja possível a aposta na “agricultura de precisão” e na “agricultura 4.0” é essencial para que se consiga alcançar tamanho objetivo (Dores, 2021). Importa por isso desenvolver ferramentas que permitam, de uma forma expedita, contribuir para o aumento de eficiência da gestão do olival garantindo a sua maior sustentabilidade.

Considerando a relevância que a utilização da tecnologia pode ter para o aumento da sustentabilidade e eficiência das explorações agrícolas, o estudo “Agricultores e Digitalização” revela que cerca de 82% dos agricultores portugueses acreditam que as tecnologias irão contribuir para o sucesso e sustentabilidade das suas explorações e, cerca de 94% destes mesmos agricultores planeiam investir neste tipo de ferramentas (AGROTEC, 2022). Pela importância desta temática foram criados programas de financiamento à investigação e inovação para a implantação de tecnologias digitais no setor agrícola (European Union, 2023).

## 1.2. Objetivos

São objetivos principais da presente dissertação:

- 1) Utilização de imagens por detecção proximal no espectro do UV a NIR recorrendo a um espectrómetro de elevada resolução (Ocean Insight, Flame-T-XRI) e uso de um sensor de refletância de baixo-custo (18 bandas, das quais 12 são na gama do visível e 6 no NIR) para estimar o teor em macronutrientes principais em folhas de oliveira;
- 2) Comparar a qualidade de informação de dois sensores sendo um deles considerado de baixo custo, com os resultados obtidos por análises clássicas em laboratório.

## 2. Revisão Bibliográfica

### 2.1. Olivicultura, importância da cultura em Portugal

A oliveira (*Olea europaea* L.) é uma cultura que representa bastante importância na bacia do mediterrâneo (Galán *et al.*, 2005, citado por Vivas, 2018). O azeite, como já faz parte da dieta mediterrânea há longas gerações, foi declarado pela UNESCO, em 2010, Patrimônio Cultural Imaterial da Humanidade (Aquino *et al.*, 2022). Esta cultura representa um grande valor económico para diversos países, nomeadamente Espanha, Itália, Grécia e Portugal (FAOSTAT, 2018, citado por Aquino *et al.*, 2022). Em Portugal, no ano de 2021, a área total de olival foi de cerca de 380 412 ha, onde a maioria está concentrada na região do Alentejo (201 474 ha) e destina-se à produção de azeite (INE, 2022).

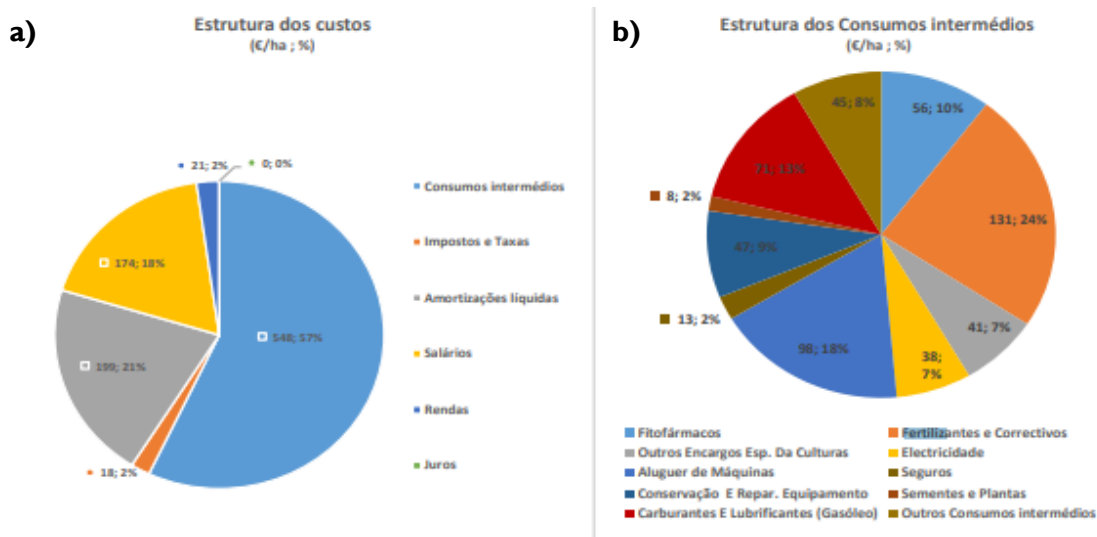
O olival apresenta grande potencial, uma vez que é uma cultura mediterrânica, bem adaptada principalmente à região do Alentejo, com um baixo consumo hídrico e com poucos problemas fitossanitários (EDIA, 2021). O aumento do consumo de azeite levou os produtores a procurarem maneiras de aumentar a produtividade da sua cultura levando à conversão de olivais tradicionais de sequeiro, que representavam uma rentabilidade negativa na maioria dos casos, em olivais em vaso e em sebe (Rufat *et al.*, 2014). A existência dos perímetros de rega permitiu aumentar bastante a produtividade desta cultura e, conseqüentemente, grande parte dos olivais de sequeiro foram reconvertidos para regadio (EDIA, 2021). Com a introdução do regadio nos olivais e com a conversão do seu sistema de condução, em 2016 cerca de 89% dos olivais modernos em copa e em sebe de regadio situavam-se no Alentejo (GPP, 2020). Posto isto, em Portugal a produtividade média passou de 0,5 toneladas de azeitona/hectare para 2 toneladas de azeitona/hectare enquanto na região do Alentejo a média é de aproximadamente 3 toneladas de azeitona/hectare (Louro, 2019).

Em Portugal, nos últimos 3 anos, o setor olivícola representou um grande contributo para o saldo da balança comercial, nomeadamente cerca de 620 milhões de euros em termos de volume de negócio (contribuição para o PIB português), 500 milhões de euros em exportações e, a nível sociais, também detém um grande impacto em termos de empregabilidade, quer a nível nacional quer a nível regional (Louro, 2019).

## 2.2. Sustentabilidade e Fertilização Racional do Olival

Atualmente o setor agrícola tem vindo a sofrer inúmeros desafios. Um dos desafios que tem surgido é a necessidade de produzir mais com menos. Ou seja, com o aumento da população mundial é necessário produzir mais alimentos de uma forma sustentável, mas com menor área de terra arável. Para que o setor consiga corresponder a esse desafio, é necessário intensificar as culturas e/ou adotar ferramentas tecnológicas que permitam que o agricultor pratique uma agricultura mais sustentável (Costa, 2022). Ultimamente tem-se vindo a assistir ao aumento dos preços dos combustíveis e consequentemente dos fertilizantes, o que se tem vindo a tornar insustentável para muitos produtores. Associado a estes fatores está ainda a problemática ambiental. A incorreta utilização dos fertilizantes tem vindo a trazer graves problemas ambientais nomeadamente a poluição dos ecossistemas e, para a sustentabilidade do setor oleícola, surge também a necessidade de fomentar a biodiversidade (Patanita *et al.*, 2021). Com tamanhos desafios, o agricultor tem de tornar a sua atividade mais sustentável e eficiente. Para tal, tem-se vindo a introduzir na atividade agrícola o conceito de “agricultura de precisão” e de “agricultura inteligente”. Neste contexto, torna-se imprescindível a “aposta” na ciência, na inovação e na evolução tecnológica (Patanita *et al.*, 2021).

Atualmente é praticamente impossível conseguir alcançar produções competitivas sem a aplicação de fertilizantes minerais (Głodowska & Wozniak, 2019). No geral a fertilização é essencial para que ocorra um bom desenvolvimento da cultivar, tendo como objetivo principal fornecer à cultura os nutrientes necessários, que porventura não se encontram disponíveis no solo, de maneira a atingir os níveis de produção esperados (Arrobas & Moutinho-Pereira, 2009). Relativamente à estrutura de custos por hectare de olival (Figura 1), os consumos intermédios representam a maioria do total de encargos das explorações (57%) e, dentro dos consumos intermédios, os fertilizantes e corretivos apresentam maior expressividade (GPP, 2020).



**Figura I – a) e b) Estrutura de custos por hectare de olival das explorações (média 2016 a 2018) (GPP, 2020)**

Para que a fertilização seja feita corretamente e de uma forma racional, é necessário ter em consideração as análises de solo, as análises foliares e ainda ter em atenção a recomendação de fertilização para os determinados estados fenológicos da cultura (Jordão & Marcelo, 2015) de maneira a aumentar a produção e consequentemente reduzir a alternância (Arrobas & Moutinho-Pereira, 2009).

Como nem todos os olivais precisam da mesma quantidade de nutrientes há que adotar outra abordagem e começar a fertilizar o olival tendo em consideração a sua heterogeneidade e, se assim se justificar, aplicar fertilizantes à taxa variável (Arrobas & Moutinho-Pereira, 2009; Noguera *et al.*, 2021), para que seja possível obter boas produções respeitando os padrões ambientais e de qualidade (Roma *et al.*, 2023). Diversos fatores, tais como as propriedades do solo, a morfologia da parcela e o microclima, vão diferir consoante o local da parcela e consequentemente ditar a eficácia no consumo dos recursos pela planta (Noguera *et al.*, 2021). As necessidades de fertilização também acabam por diferir consoante o potencial produtivo da cultura (Arrobas & Moutinho-Pereira, 2009). Segundo os mesmos autores, um olival de sequeiro acaba por não ser tão exigente em termos de fertilização como um olival de regadio, assim como um olival jovem também acaba por ter necessidades de fertilização inferiores a um olival adulto em plena produção. Já no que diz respeito às necessidades da planta consoante a fase fenológica, sabemos que até à floração as necessidades em azoto e fósforo são superiores às necessidades de potássio (ADP, 2023).

Segundo o mesmo autor, na altura da floração não deve haver carências de boro, porque este nutriente favorece a polinização e o vingamento da flor. Já após o vingamento do fruto as necessidades de azoto da cultura são superiores às necessidades em fósforo e potássio e de julho a outubro as necessidades em potássio são superiores às necessidades em fósforo e azoto (ADP, 2023).

Hoje em dia aplicar fertilizantes em quantidades excessivas é bastante frequente devido à intensificação da atividade agrícola, o que muitas vezes leva a graves problemas para a saúde humana e para o meio ambiente (Głodowska & Wozniak, 2019). Os mesmos autores ainda referem que quando fertilizamos em excesso, não só estamos a prejudicar a “saúde” do solo, nomeadamente a sua estrutura e a função microbiológica do mesmo, (como podemos consultar num estudo elaborado por Allison & Martiny (2008), onde concluíram que os microorganismos são sensíveis ao azoto, ao fósforo e ao potássio) como também grande parte dos nutrientes que aplicamos não vão ser utilizados pela planta acabando por se perder por percolação, contaminando os lençõs freáticos e eventualmente causando a eutrofização das água (Fernandez-Escobar *et al.*, 2009 ; Savci, 2012 citado por Noguera *et al.*, 2021).

Com a sobrefertilização, não só o produtor está a gastar dinheiro desnecessariamente, como também a qualidade da produção está a ser prejudicada, nomeadamente teremos uma redução de polifenóis e desequilíbrios no crescimento vegetativo em relação à produção (Fernández-Escobar *et al.*, 2008; Zipori *et al.*, 2020 citado por Roma *et al.*, 2023). Já a fertilização insuficiente também gera problemas à cultura, tendo impactos negativos na fotossíntese e na produção da cultura, quer em termos quantitativo como qualitativos (Hank *et al.*, 2019; Lopez-Granados *et al.*, 2004 citado por Noguera *et al.*, 2021).

## 2.3. Olivicultura de Precisão

A adoção de tecnologia na agricultura está em constante evolução e cada vez mais tem vindo a desempenhar um papel importante na agricultura, com o objetivo de aumentar a sustentabilidade do setor, contribuindo para aumentar a eficiência, qualidade e a produtividade das culturas. Posto isto, devemos adaptar-nos e diferenciar-nos, conseguindo processar, interpretar e gerar um grande leque de informação para nos mantermos competitivos (Porter & Heppelmann, 2014 citado por Ciruela-Lorenzo *et al.*, 2020). A agricultura de precisão é uma estratégia de gestão que considera a variabilidade temporal (variação entre colheitas) e espacial (variação entre parcelas) para melhorar a sustentabilidade da produção agrícola (Molin *et al.*, 2021). O conceito de “Agricultura de Precisão” surge da necessidade de não só aumentar a quantidade e qualidade das produções, como também da necessidade de ser cada vez mais sustentável e eficiente nos recursos aplicados de maneira que seja possível melhorar a competitividade do setor, bem como corresponder aos desafios agroalimentares como o aumento da população mundial, alterações climáticas, escassez de água, degradação dos solos (Best *et al.*, 2012). Para que tal seja possível, o recurso às tecnologias sensoriais é imprescindível, surgindo cada vez mais a necessidade de inovar e melhorar as técnicas e instrumentos já existentes (Best *et al.*, 2014).

No que diz respeito à olivicultura de precisão pretendem-se desenvolver sistemas de monitorização e avaliação da cultura recorrendo entre outras técnicas, a técnicas de deteção remota, como por exemplo a termografia no infravermelho distante, que está associada a coeficientes de stress hídrico (Paço *et al.*, 2011); controlo de pragas (Mamdouh *et al.*, 2022); técnicas para estimar o rendimento e medição digital do crescimento dos frutos por visão artificial (Aquino *et al.*, 2020); NDVI para avaliação do estado de vigor vegetativo da cultura (Atik & Akdemir, 2022). Estas podem ser completadas por técnicas para avaliação económica da relação custo/benefício no uso de fatores de produção, estudo das características físicas, químicas e biológicas do solo, determinação do rendimento através do uso de monitores de rendimento nas máquinas de colheita, avaliação do teor em gordura ou do tamanho do fruto (Best *et al.*, 2012). Segundo os mesmos autores, todas as técnicas baseiam-se na análise espacial e temporal de maneira a identificar problemas na cultura para posteriormente corrigir e assim ser possível melhorar a produção, quer quantitativamente quer qualitativamente.

## 2.4. Deteção Remota

Através da deteção remota (Figura 2), é-nos possível obter informações sobre a nossa cultura através de técnicas não destrutivas (Shiratsichi *et al.*, 2014) e não invasivas, com recurso a instrumentos de baixa altitude (nomeadamente drones) e de elevada altitude (satélites), sem estarem em contacto direto com o solo ou a cultura (EOS, 2020). As imagens obtidas através deste método utilizam a interação entre a radiação eletromagnética e a superfície das plantas nos espectros do UV, do visível, do infravermelho e térmico, fornecendo-nos informação quantitativa da luz refletida pela superfície (Best *et al.*, 2012). Graças à compreensão das respostas espectrais das folhas individuais e posteriormente da copa é possível aplicar a deteção remota às culturas (Best *et al.*, 2012). Os mesmos autores também referem que a deteção remota nos fornece imensa informação relevante que tem vindo a ser estudada e compreendida ao longo dos anos, tal como a resposta das folhas a diferentes fatores como a variedade, a forma da copa, a idade da folha, o estado hídrico da cultura e o seu estado nutricional.




Figura 2 - Deteção remota (Clara, 2021)


Ultimamente, tem-se vindo a utilizar vários tipos de sensores em agricultura para mapear a variabilidade espacial e temporal de diversos parâmetros de maneira a auxiliar o agricultor na tomada de decisão (Anastasiou *et al.*, 2023). De acordo com os mesmos autores, os sensores que se têm vindo a utilizar (sozinhos ou combinados) para estimar fatores como o vigor da cultura, stress hídrico, questões relacionadas com pragas e doenças, assim como condições do solo de uma maneira não destrutiva são sensores RGB, multiespectral, hiperespectral, camaras térmicas, deteção de luz e alcance (LiDAR), entre outras.

A utilização de drones apresenta a vantagem de uma avaliação da cultura mais próxima do solo, com maior resolução espacial conseguindo assim identificar questões mais específicas da cultura, nomeadamente a sua condição hídrica, vigor, estado nutritivo e ainda é possível fazer previsões de produção (EOS, 2020). Além disso, permitem obter imagens que não estejam tão sujeitas às condições meteorológicas adversas, que afetam imagens adquiridas a maiores altitudes, podendo ser obtidas quando se entendem necessárias, não dependem da passagem temporal de um satélite (Conceição & Rodrigues, 2020). Na utilização de drones, o grande problema que surge é o consumo de tempo e a baixa eficiência operacional para a monitorização de grandes áreas (Fu, *et al.*, 2020). Já as imagens de satélite, como por exemplo o Sentinel-2, apresentam a vantagem de cobrir uma área superior num menor tempo, de forma automática na sua revisita temporal ao alvo georreferenciado (EOS, 2020; Fu *et al.*, 2020).

#### 2.4.1. Imagens Multiespectrais Obtidas Através de UAVs

As imagens multiespectrais atualmente têm sido utilizadas para estudar os parâmetros quantitativos e qualitativos dos índices de vegetação da cultura (Erena *et al.*, 2012). Segundo os mesmos autores, estes índices conseguem-se através da combinação matemática de diferentes comprimentos de onda. Ainda de referir que a avaliação multiespectral resulta de um sensor que mede a radiação refletida em várias bandas, nomeadamente o infravermelho próximo (842 nm), o Red Edge (717 nm) e o vermelho (R) (668 nm), verde (G) (560 nm), azul (B) (475 nm) (Figura 3), tornando possível captar a radiação que é absorvida e refletida pela planta, dando-nos assim inúmeras informações sobre o estado da nossa cultura em tempo real (TerraSIG, 2022).

No caso de um indicador de NDVI que combina as bandas do infravermelho próximo e do vermelho sabemos que uma planta saudável vai absorver bem a luz vermelha e refletir com intensidade a infravermelha (One Soil, 2023). No caso de a planta estar doente, em stress-hídrico ou afetada por pragas acontece em regra o inverso (EOS, 2023). Estas imagens podem ser obtidas tanto através do satélite Sentinel-2 como também podem ser obtidas através da utilização de um veículo aéreo não tripulado (UAV) (Noguera *et al.*, 2021) embora existam diferenças entre as capturas. Sabemos que se encontra disponível bastante informação e imagens gratuitas de satélite, mas, como estas imagens têm uma baixa resolução, para a elaboração de trabalhos e estudos que requerem mais detalhe recorre-se ao UAV que capta imagens de alta resolução. Giovos *et al.* (2021) também referem que as imagens recolhidas através de um UAV, ao ter um pixel de menor tamanho (centímetros) conseqüentemente irá fornecer uma imagem com maior resolução espacial, embora se saiba que tem um custo acrescido.



**Figura 3 – Câmara Multiespectral de 5 bandas (Interreg, 2023)**

Relativamente à utilização de imagens multiespectrais para avaliação do estado nutricional do olival, Noguera *et al.* (2021) desenvolveram um método (por meios de análise e modelagem de imagens multiespectrais) para determinação do teor de Azoto (N), Fósforo (P) e Potássio (K), onde utilizaram como variáveis de entrada os dados espectrais e como referência os resultados das análises químicas, obtendo pela abordagem de Redes Neurais Artificiais (RNA) resultados como N ( $R^2 = 0,63$ ), P ( $R^2 = 0,89$ ), K ( $R^2 = 0,93$ ).

Já no que diz respeito à utilização de imagens hiperespectrais para avaliação do estado nutricional do olival, Gómez-Casero *et al.* (2007) avaliaram um método para monitorizar a deficiência em N e P em olival com imagens hiperespectrais baseado no índice NDVI que permitiu diferenciar oliveiras com deficiência nutricionais e oliveiras em boas condições nutricionais.


## 2.5. Deteção Remota Próxima

Tal como o nome indica, na deteção remota próxima, utilizam-se sensores de proximidade que nos ajudam a determinar várias características do solo e das plantas. Este tipo de sensores pode ser acoplado ao trator, a uma moto-quatro e podem até mesmo ser transportados à mão pelo operador (Santos, s.d.) e normalmente são utilizados para a prática de rega de precisão, para a previsão de pragas e doenças e até mesmo previsão de colheita (Interreg, 2023).

Uma gama muito ampla de sensores, quer sejam eles dispositivos portáteis ou dispositivos aéreos, está a ser utilizada para a monitorização espectral em escala das culturas (Fu, *et al.*, 2020). Dispositivos portáteis como o GreenSeeker (Figura 4 a)), que tem duas bandas fixas, nomeadamente na luz vermelha e no infravermelho próximo, apesar das suas limitações nos comprimentos de onda, já estão a ser utilizados, por exemplo, para cálculo do Índice de Vegetação de Diferença Normalizada (NDVI) e aplicado em diversas culturas, nomeadamente no arroz e milho para monitorização do crescimento (Zhang *et al.*, 2019; Zhang *et al.*, 2014 citado por Fu *et al.*, 2020).

Com a evolução da tecnologia hoje em dia já se utilizam sensores hiperespectrais para a deteção remota próxima assim como imagens multiespectrais de maneira a obtermos informação mais detalhada da nossa cultura e gerarmos índices de vegetação (Gil-Perez *et al.*, 2010 citado por Giovos *et al.*, 2021).

Segundo os mesmos autores, na viticultura atualmente já se opta por utilizar índices de vegetação hiperespectrais em detecção de proximidade por espectrorradiômetros, em vez de se utilizar apenas a detecção remota. Como exemplo de um espectrorradiômetro portátil, existe no mercado o equipamento Espectrorradiômetro ASD FieldSpec® (Figura 4 b)) é uma ferramenta de campo que se baseia em medições de refletância e as suas principais aplicações são relacionadas com a fisiologia da planta, espectroscopia de campo, análises de biomassa, entre outras aplicações (Malvern Panalytical, 2023).



**Figura 4 – a) GreenSeeker (Trimble Agriculture, 2023); b) Espectrorradiômetro ASD FieldSpec® (Malvern Panalytical, 2023)**

### 2.5.1. Outros Dispositivos Sensoriais (Baixo-Custo)

Quando nos referimos a sensores de baixo-custo referimo-nos a sensores cujo preço é muito inferior ao de produtos comerciais convencionais. Este tipo de abordagem tecnológica desempenha um papel crucial no avanço da agricultura de precisão sendo necessário ter em consideração algumas oportunidades e desafios associados à sua utilização (Furtak *et al.*, 2019). Como oportunidades, ao ter um preço mais baixo, torna a sua aquisição e posterior utilização mais acessível a uma gama mais ampla de agricultores, incluindo os pequenos produtores e aqueles em países em desenvolvimento. Essa democratização da tecnologia pode ajudar a reduzir a divisão digital na agricultura. A recolha de dados pode assim ser feita de forma mais efetiva também pela escalabilidade permitida, pois através de um preço mais baixo consegue-se uma área de cobertura de informação mais ampla.

À semelhança de sensores convencionais em regra mantém-se os pressupostos na sua utilização, nomeadamente a monitorização podendo contribuir para o desenvolvimento de modelos preditivos para ajuda à tomada de decisão, e envio de informação remotamente através de aplicativos para smartphones ou interfaces web, o que permite respostas oportunas a condições em mudança reduzindo a necessidade de inspeções físicas. Contudo a sua utilização oferece também desafios tais como a privacidade e segurança dos dados, a calibração dos sensores e precisão da informação obtida, e a maior ou menor facilidade de integração de dados.

Como exemplos, Rosa & Dall’Agnol (2021) desenvolveram um protótipo de um sistema de baixo custo para monitorizar variáveis relacionadas com a rega tais como a humidade relativa do ar, a temperatura e humidade do solo com um custo total muito inferior aos comercializados convencionalmente para as funções pretendidas. Já Magalhães (2016), desenvolveu um protótipo de um dendrómetro de baixo custo (65€) que foi aplicado numa oliveira adulta com o intuito de otimizar a água da rega, assim como desenvolver um sistema autónomo para recolha e armazenamento de dados, cujo processo de fabrico local permitiu criar um instrumento de valor consideravelmente inferior a dispositivos comerciais.

### 2.5.2. Espectroscopia, Conceito e Aplicação em Nutrição Vegetal

A espectroscopia assenta no estudo da interação entre a radiação eletromagnética e a matéria (Tatum, 2019). Atualmente, a espectroscopia é utilizada para diversas finalidades e existem no mercado uma gama bastante variada de espectrómetros. Oliveira (2023), combinou a espectrometria Raman e espectrometria de absorção atômica e molecular para determinação de N, P e K em fertilizantes, onde alcançaram resultados positivos para a determinação de N e P através da espectroscopia Raman e, através da espectrometria de absorção atômica, foi possível determinar o teor de N em 215 nm, P em 248 nm e K em 345 nm. A validação destes métodos fez-se em comparação com métodos oficiais, nomeadamente para determinação de N foi aplicado o Método Kjeldahl, para determinação de P a espectrofotometria de UV-Vis, e para K a espectrometria de emissão atômica em chama (Oliveira, 2023).


Outro exemplo de espectrômetro existente no mercado é o FLAMENIR, que abrange um comprimento de onda compreendido entre os 950-1650 nm utilizado principalmente para medições de humidade, qualidade de grãos e rações, medições de gordura e óleos, entre outras (Ocean Optics, 2016).

## 2.6. Inteligência Artificial e *Machine Learning*

A Agricultura Inteligente ou Agricultura 4.0 tem vindo a ser impulsionada pelo desenvolvimento de tecnologias de automação e Inteligência Artificial (IA) (Borba *et al.*, 2022). A vantagem da sua utilização prende-se com a otimização dos dados e agilidade na informação processada. A IA é um campo científico amplo que visa replicar a inteligência humana em sistemas de computação, enquanto o *Machine Learning* (ML) é uma técnica dentro da IA que se concentra na capacidade de aprender com dados. O ML é uma das abordagens mais proeminentes e bem-sucedidas na IA atualmente, permitindo que sistemas realizem tarefas complexas e tomem decisões com base em dados contribuindo de igual forma a outras tecnologias, também para a sustentabilidade dos processos de produção. A IA é constituída por vários outros campos, mais concretamente sete campos onde se inclui a ML, a Visão Computacional, a Robótica, o Processamento de Linguagem Natural, o Planeamento, Programação e Otimização, os Sistemas Especialistas e, por último, a Fala (Cortés *et al.*, 2000; Kumar & Bhramaramba, 2017 citado por Borba *et al.*, 2022).

Como referido, o termo ML assenta na capacidade que os computadores têm de aprender com uma base de dados (Queiroz *et al.*, 2022). Na Figura 5 estão representados subdomínios do ML. Os algoritmos de ML requerem grandes conjuntos de dados para aprender padrões, relacionamentos e tendências (Bishop, 2006). Esses dados podem incluir texto, imagens, valores numéricos ou qualquer outra forma de informação relevante para o problema em questão. Outro requisito é o treino. Nesta fase um modelo de aprendizagem de máquina é exposto a um conjunto de dados rotulado, o que significa que os dados de entrada são emparelhados com a saída ou destino correto. O modelo aprende com esse conjunto de dados ajustando os seus parâmetros internos para fazer previsões precisas. Através de engenharia de recursos torna-se possível seleccionar, transformar e codificar recursos relevantes para melhorar o desempenho do modelo (Bishop, 2006).

Os processos de aprendizagem podem ser supervisionados e não supervisionados consoante haja rotulagem dos dados para encontrar padrões. Criam-se então algoritmos que incluem modelos de regressão linear, árvores de decisão, máquinas de vetores de suporte e redes neurais. O modelo deve então ser avaliado e se validado, deve ser utilizado na predição de dados novos em situações reais (Bishop, 2006). À semelhança de outros setores de atividade, ML é aplicada com o objetivo de apoio à tomada de decisão (Queiroz *et al.*, 2022). Em ML, segundo os mesmos autores, os dados utilizados podem ser categóricos e numéricos (binários, inteiros, reais) originários de vários tipos de sensores e os algoritmos podem ser divididos em algoritmos de classificação e algoritmos de regressão. Das técnicas para aprendizagem supervisionada, ao algoritmo aplicado (Redes Neurais Artificiais, Regressão Linear, K-Nearest Neighbors, Support Vector Machine, entre outros), para cada amostra de entrada apresenta-se também o resultado que é esperado na saída (Queiroz *et al.*, 2022).



**Figura 5 – Subdomínios do ML (Jagadale *et al.*, 2021)**

# 3. Material e Métodos

## 3.1. Projeto AI4RealAg

O presente trabalho desenvolveu-se no âmbito do projeto AI4RealAg – “Soluções de Inteligência Artificial e *Data Science* para a implementação e democratização da agricultura digital”, na qual foram apresentados os trabalhos presentes no Anexo I. É um projeto liderado pela empresa SISCOG – Sistemas Cognitivos, S.A. e tem como parceiros o INIAV – Instituto Nacional de Investigação Agrária e Veterinária, I.P. e a BEYOND VISION – Sistemas Móveis Autónomos de Realidade Aumentada, Lda.

O projeto AI4RealAg pretende otimizar a fertilização racional das culturas procurando a máxima eficiência no uso dos nutrientes, contribuindo quer para a qualidade e segurança dos alimentos, quer para a redução das perdas por lixiviação e/ou volatilização. A solução assenta num sistema inteligente de extração de conhecimento, baseado em Inteligência Artificial e *Data Science*. Usa ML para extrair dos dados, obtidos por sensoriamento remoto combinado, conhecimento útil para decidir melhor, aumentando a produção e protegendo o ambiente (INIAV, I.P., 2023; SISCOG, 2023).

## 3.2. Local de Realização dos Ensaios

O ensaio experimental foi implementado na Herdade do Reguengo, no INIAV I.P. – Polo Elvas (38°54'27.6"N 7°08'41.5"W). Este ensaio decorreu no olival em sebe (Figura 6), que abrange uma área de cerca de 2,77 ha. O olival em sebe apresenta dois compassos de plantação diferentes, 3,75m x 1,80m (C1) (plantado no ano de 2004, tendo sido feita uma extensão das variedades ‘Azeiteira’ e ‘Arbequina’ no ano de 2014) e 3,75m x 1,35m (C2) (plantado no ano de 2004), com orientação Noroeste – Sudeste, e é constituído por 9 variedades (repetidas em ambos os compassos de plantação).

Para a realização deste estudo foram consideradas três variedades, mais precisamente uma variedade portuguesa ‘Azeiteira’ (V1), uma variedade espanhola ‘Arbequina’ (V2) e uma variedade grega ‘Koroneiki’ (V3). A razão pela qual se optou pela V1 foi pelo facto de ser uma variedade do país com grande interesse agronómico que convém valorizar e perceber qual o seu comportamento em sebe. No que diz respeito à V2 e V3, por serem

variedades que atualmente estão instaladas no olival em sebe e representam grande expressão e interesse em Portugal.

O olival é regado através de rega localizada, gota-a-gota, com um débito nominal de 2,2 l/h e espaçamento entre gotejadores de 1 metro, sendo praticada rega reduzida (1000 m<sup>3</sup> de água por ha e ano) e fertilização por fertirrega. Neste ensaio, em julho de 2022, foram implementados três tratamentos de fertilização diferenciada em cada compasso, nomeadamente a Testemunha (T0) e uma Fertilização Superior à Recomendada (T2) no C1, e a Testemunha (T0) e o Recomendado (T1) no C2. Cada tratamento é constituído por 10 blocos.



**Figura 6 – Ortofoto com Drone (modelo Heidi, da Beyond Vision) com câmara Micasense (modelo Rededge) da localização do olival em sebe na Herdade do Reguengo**

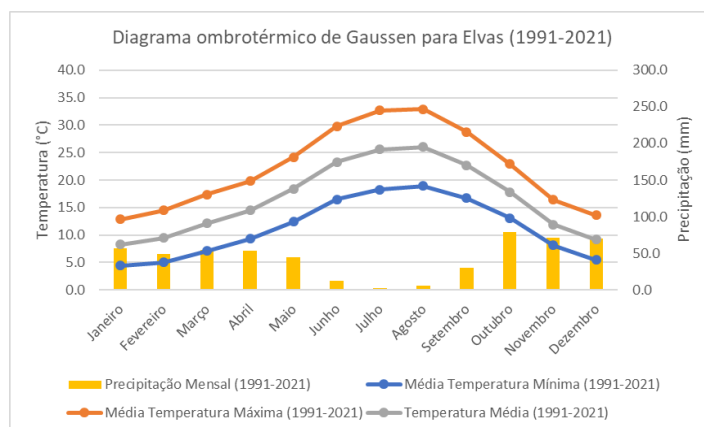
### 3.3. Caracterização Edafo-Climática

A Herdade do Reguengo está inserida numa região de clima Mediterrânico, onde os verões se caracterizam por serem quentes e secos e os invernos frios com base na classificação de Koppen-Geijer, caracterizando-se por um clima do tipo “Csa” (IPMA, 2023). De acordo com IPMA (2023), no período de 1971 a 2000, a precipitação em Elvas (local onde se encontra o ensaio) caracteriza-se por ser superior a 500 mm, humidade relativa média de 70% e temperatura média amena (Quadro I).


**Quadro I: Dados climáticos de Elvas no período de 1971 a 2000 (Adaptado de IPMA, 2022), e 2022 (Estação Meteorológica da Herdade do Reguengo, INIAV, I.P.)**

	Elvas 1971 a 2000	Elvas 2022
Temperatura média (°C)	16,3	18,3
Temperatura máxima média (°C)	22,7	26,6
Temperatura mínima média (°C)	10,0	10,0
Precipitação média (mm)	535,4	599,4

Na Figura 7 está representado o diagrama ombrotérmico de Gausson para a região de Elvas para o período compreendido entre 1991 e 2021 e na Figura 8 o diagrama ombrotérmico de Gausson para a mesma região para o ano de 2022. Comparando ambas as Figuras constatamos que as temperaturas médias de 2022 foram ligeiramente superiores às temperaturas médias normais. Já em relação à precipitação, na sua totalidade, no ano de 2022 esta foi de aproximadamente 599 mm, um pouco acima da média embora com pouca relevância. Ainda sobre a precipitação, a questão que realça é que o mês de janeiro, fevereiro e maio teve uma precipitação inferior à precipitação média para o ano de 1991-2021 e dezembro foi o mês em que ocorreu uma maior precipitação. Em suma, com a comparação dos diagramas ombrotérmicos constatamos que cada vez há uma maior heterogeneidade na distribuição da precipitação e que há um aumento da temperatura média anual.



**Figura 7 - Diagrama ombrotérmico de Gausson para Elvas para o período de 1991-2021 (adaptado de ClimateData (2022))**




**Figura 8 - Diagrama ombrotérmico de Gausson para Elvas (segundo dados climáticos do ano agrícola de 2022 da Estação meteorológica da Herdade do Reguengo, INIAV, I.P.)**

Já em relação aos solos e segundo a Carta de Solos nº 37A/414 (Figura 9), a génese dos solos da Herdade do Reguengo caracteriza-se por ter solos “Vc\*”, “Pc\*”, “Aac + Ac”. Os solos “Vc\*” pertencem à família dos Solos Calcários Vermelhos, caracterizando-se por serem “Solos Calcários Vermelhos de calcários associados a dioritos ou gabros ou rochas cristalófilas básicas”. Já os solos “Pc\*” pertencem à família dos Solos Calcários Pardos, mais concretamente são “Solos Calcários Pardos de calcários não compactos associados a dioritos ou gabros ou rochas cristalófilas básicas” (DGADR, 2023).

Segundo Cardoso (1965), os solos Vc\* no horizonte Ap (25 a 50 cm), apresentam uma cor pardo-avermelhada ou vermelho, uma textura franco-argilosa ou argilo calcária, uma estrutura granulosa média moderada, agrupada por ventura em anisoforme, firme, e um pH de 7,5 a 8,5, estando assim associados a Barros. Já os solos Pc\*, segundo o mesmo autor, também estão quase sempre associados a Barros. O horizonte Ap (25 a 40 cm) normalmente apresenta uma textura franco-argilosa a argilosa calcária, estrutura granulosa média moderada, por vezes agrupada em anisoforme, firme, com um pH de 7,5 a 8,5 e uma cor pardo, pardo-pálido, pardo-amarelado ou pardo-acinzentado (Cardoso, 1965). Quanto à capacidade de uso dos solos “Vc\*” e “Pc\*”, estes solos encaixam-se na classe tipo “D”, o que indica que são solos com bastantes limitações e com um elevado a muito elevado risco de erosão. Já a sua subclasse “e” diz-nos que este tipo de solos apresentam erosão e escorrimento superficial (DGADR, 2023).

Quanto ao tipo de solo onde está implementado o olival em sebe, caracterizam-se por solos “Aac”, que são solos “Solos Incipientes - Aluviosolos Modernos, Calcários, (Para-Solos Calcários), de textura pesada” e os solos “Ac”, que se caracterizam como “Solos Incipientes - Aluviosolos Modernos, Calcários, (Para-Solos Calcários), de textura mediana”. Os solos “Aac” e “Ac” “idem, com carbonatos” são solos incipientes, onde o processo de formação do solo ainda não atuou tempo suficiente para provocar diferenciações no mesmo, embora em alguns casos já exista alguma acumulação de matéria orgânica à superfície, não muita devido à elevada taxa de mineralização uma vez que há um bom arejamento da camada superior (Cardoso, 1965).



**Figura 9 – Troço da carta de solos de Portugal n° 37A/414 (Escala 1:25000) com a delimitação da Herdade do Reguengo**

De maneira a obtermos uma informação atual do estado do solo da parcela onde estava instalado o ensaio, foi realizado (pela empresa aquagri) o levantamento da condutividade elétrica aparente do solo com recurso ao sistema de monitorização Topsoil Mapper da Geoprpospectors, ligado a um veículo com tração, com o objetivo de recolher informação sobre a variabilidade espacial da condutividade elétrica aparente da área em estudo. Como a bibliografia indica, o conceito de condutividade elétrica aparente do solo define-se como a capacidade que determinado volume de solo tem para facultar a passagem de corrente elétrica (Rabello *et al.*, 2014).

Relativamente aos valores da condutividade elétrica aparente do solo, sabemos que valores de condutividade elétrica aparente mais altos correspondem a solos mais pesados, de granulometria mais fina e com maior teor de argila. Já valores de condutividade elétrica aparente mais baixos, correspondem a solos de granulometria mais grosseira e com teor de areias mais elevado. Posto isto, tendo em conta os valores de condutividade elétrica aparente do solo e a humidade relativa do solo, na Figura 10 encontra-se representado a textura do solo da parcela em estudo.




**Figura 10 – Distribuição textural do solo na Herdade do Reguengo (olival em sebe: parcela I e 2)**

## 3.4. Procedimento experimental

### 3.4.1. Ensaio experimental

A Figura 11 mostra a sequência de operações realizadas na elaboração do ensaio experimental.



**Figura 11- Sequência das Operações Realizadas na elaboração do Ensaio Experimental**

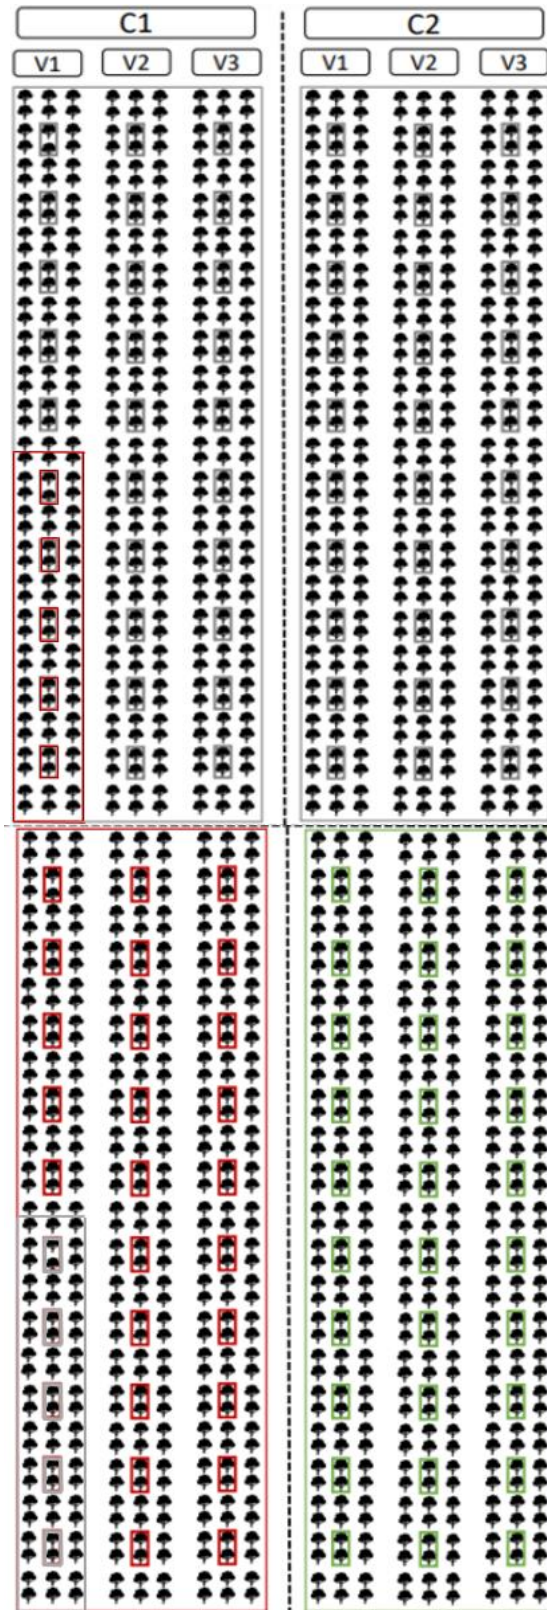
Para realização deste ensaio de fertilização foram formados três tratamentos de fertilização diferenciada estabelecidos em dois compassos. No C2 – T1 de acordo com Veloso *et al.* (2022), o intuito era aplicar cerca de 80-100 kg de N por ha (insuficiente), 30-40 kg de P<sub>2</sub>O<sub>5</sub> por ha (suficiente) e 60-90 kg de K<sub>2</sub>O por ha (suficiente) (produção esperada de 6-8 toneladas/ha), enquanto que no C1 (T2) o objetivo era aplicar uma fertilização superior à aplicada no T1. Para esse efeito, recorreu-se aos adubos com formulação 8-2-8 (julho 2022) e 12-2-8 (agosto 2022), aplicando-se um total de N-P-K (kg/ha) em 2022 referido no Quadro 2.

**Quadro 2: Total de N-P-K (kg/ha) aplicado em 2022**

		2022: Total de N-P-K (kg/ha) aplicado		
		N	P	K
C1	(T0)	0	0	0
	(T2)	47	9	37
C2	(T0)	0	0	0
	(T1)	37	7	27

Para a execução do ensaio (Figura 12) foi necessário fazer um levantamento das árvores da parcela em ambos os compassos e nas três variedades em estudo. Posteriormente esses dados foram registados recorrendo ao software Excel e foi elaborado o ensaio experimental onde foram gerados 10 blocos por cada tratamento, compasso e variedade, sendo cada bloco constituído por 2 árvores. Cada variedade é representada por 3 linhas e em cada linha foram instalados 2 tratamentos. De referir que não foram incluídas as linhas de bordadura, apenas a linha do centro foi tida em consideração. Como complemento, recorrendo ao dispositivo GNSS da marca Spectra Geospatial, e

software MobileMapper60\_2, foram geradas as coordenadas dos tratamentos e respectivos blocos de amostragem.



Legenda:

- C1 – Compasso 3.75m x 1.80m; V1 – Azeitona; T0 (Testemunha);  
 C2 – Compasso 3.75m x 1.35m; V2 – Arbequina; T1 (Recomendado);  
 V3 – Koroneiki; T2 (Fertilização Superior à Recomendada).

**Figura 12 – Esquema do Delineamento experimental**

Na parcela procedeu-se à marcação das árvores com tinta *spray* (Figura 13 a)) de cor vermelho para o tratamento T2, branco para o T0 e verde para o T1. De seguida, de maneira a diferenciar os tratamentos, procedeu-se à instalação de torneiras nos tubos da rega nos locais de início do tratamento diferenciado (Figura 13 b)), com o objetivo de criar secções no circuito da fertirrega para que não se fertilizasse as árvores T0 e para que quando fosse necessário regar essas mesmas árvores bastasse abrir as respetivas torneiras.



**Figura 13 - a) Marcação das árvores; b) Instalação da torneira no tubo de rega**

#### 3.4.2. Recolha do material vegetal no campo

Foram recolhidas folhas do terço médio do crescimento do ano de acordo com a metodologia proposta por Veloso *et al.* (2022), quando as oliveiras se encontravam no estado principal 8, tendo como referência a escala BBCH adaptada por Sanz-Cortés *et al.* (2002) (Anexo II), mais concretamente num período compreendido de 11/10/2022 a 19/10/2022, que indica que estávamos no estado de maturação dos frutos. O facto de se proceder à recolha do material vegetal nesta fase fenológica justifica-se pela necessidade de recolha de informação nos projetos a decorrer em paralelo no mesmo ensaio. A recolha realizou-se nos 10 blocos em cada tratamento, sendo cada bloco constituído por 2 oliveiras, o que perfaz 20 oliveiras por tratamento. De acordo com a recomendação do laboratório em cada bloco foi efetuada a recolha de 120 folhas, mais concretamente 30 folhas em cada lateral da sebe, perfazendo 60 folhas por oliveira.

As folhas recolhidas eram colocadas num saco devidamente identificado com a variedade, o tratamento, o compasso e o bloco. De seguida, o material vegetal era levado para o laboratório e, de maneira a evitar grandes alterações no material vegetal recolhido, sempre que possível, as leituras com os sensores eram feitas logo após a sua

recolha. No caso de ocorrer algum contratempo e não ser possível fazer as leituras com os sensores no mesmo dia da recolha do material vegetal, este era armazenado a uma temperatura de cerca de 2°C de forma a evitar a sua degradação.

### 3.4.3. Leituras com sensores

Para avaliação de refletância das folhas recorreu-se a dois tipos de sensores, nomeadamente um sensor considerado de baixo-custo (AMS S7265x 18-channel multi-spectral sensor) desenvolvido pela Universidade de Huelva e um sensor de espectrometria de alta resolução da marca Ocean Insight (FLAME-T-XRI).

#### 3.4.3.1. Sensor Multiespectral de Baixo-Custo


Relativamente ao sensor utilizado no âmbito desta dissertação, o custo total deste protótipo não excede os 200€ (Aquino *et al.*, 2022). Para que tal fosse possível e de maneira a reduzir os custos de produção, o exterior deste equipamento foi feito com recurso a uma impressora 3D. Já o interior do equipamento (Figura 14) é constituído por uma placa de desenvolvimento AS7265x (AMS AG, Premstätten, Austria), composta por três chips, cada chip possui seis filtros óticos independentes e a resposta espectral é definida numa faixa de 410 nm a 940 nm, onde resulta um único sensor de baixo-custo que abrange 18 bandas das quais 12 são na gama do visível e 6 no NIR (Noguera *et al.*, 2022; Aquino *et al.*, 2022). Ainda sobre as componentes elétricas do hardware, também foi selecionada uma placa pequena, mais concretamente a ‘Arduino MKRZero Board (Arduino LLC, Monza, Italy)’, onde se pode inserir um cartão SD, com um custo baixo e com um baixo consumo energético, e que irá servir para comunicar com a placa de desenvolvimento AS7265x, o ecrã ‘OLED’ e a ‘LED PCB’ de maneira a obtermos os dados (Noguera *et al.*, 2022).

Noguera *et al.*, (2022), referem que de maneira a gerar uma conexão confiável entre todas as componentes do sistema, foi criada uma placa de interligação com o intuito de servir como núcleo do sistema, ou seja, adapta a voltagem da bateria, regula a intensidade dos LEDs e interliga as diferentes componentes do sensor com os conectores para os diferentes subsistemas. Como este é um dispositivo de refletância, para que tal ocorra é necessário existir uma fonte de luz. Neste caso os autores utilizaram uma matriz constituída por três emissores LED de banda larga IR ‘OSLON P1616 SFH 437 OSRAM, Germany’, desenvolvida especificamente para aplicações de espectroscopia, que fornece

uma ampla emissão no Visível – Infravermelho próximo com menos energia e dissipação de calor e que apenas são ‘alimentados’ com a fonte de energia quando se faz uma leitura.

Já no estudo anteriormente elaborado por Aquino *et al.* (2022), foi utilizada uma fonte de luz calibrada, mais precisamente uma lâmpada halógena dicróica de 35 Watt que, segundo Noguera *et al.*, (2022), necessita de maior quantidade de energia. O Printed Circuit Board permite não só instalar as três ‘LEDs’ dentro do equipamento, assim como também atua como dissipador de calor reduzindo possíveis danos causados devido à acumulação do mesmo (Noguera *et al.*, 2022). Como referem os mesmos autores, este equipamento também possui uma tela ‘OLED’ que permite ao utilizador verificar os dados, nome do arquivo, o número de leituras realizadas e os parâmetros de configuração, sendo mais prático e excluindo a necessidade de ter outro dispositivo para esse efeito (como por exemplo, o computador).

Este dispositivo é alimentado por uma bateria (com limite até 35 Volts) por meio de um conector cilíndrico. A bateria encontra-se no exterior do equipamento e conecta-se à placa controladora do dispositivo e, como este dispositivo tem baixo consumo de energia, permite ao operador um longo tempo de utilização (Noguera *et al.*, 2022).



**Figura 14 – Constituição do equipamento multiespectral de baixo custo (Noguera *et al.*, 2022)**

### 3.4.3.2. Espectrómetro 'FLAME'

De acordo com Ocean Optics (2015), o espectrómetro utilizado no âmbito desta dissertação pode ser aplicado em diversas áreas, nomeadamente na monitorização ambiental (qualidade do ar e água, deteção remota), tecnologias de energia (análise de biocombustíveis, análise de óleo e petróleo), entre outras. No que diz respeito à sua aplicação na área das 'Farm to Table Technologies', um dos exemplos onde este equipamento é utilizado é em medições e monitorização agrícola, bem como no controle da qualidade de alimentos e bebidas e segurança alimentar (Ocean Optics, 2015). Este equipamento pode ser utilizado tanto em laboratório (deteção proximal) como no campo (deteção remota) e, com a sua utilização, adquirimos inúmeros dados no qual podemos destacar dados com base na refletância (Ocean Optics, 2015). O espectrómetro FLAME-T-XRI (Figura 15), é um equipamento de alta resolução com um preço de aquisição muito superior (cerca de 8000€), que fornece dados no espaço de pouco tempo e garante não só um bom desempenho como também dados viáveis, mesmo com oscilação das condições ambientais, e cobre vários comprimentos de onda, mais concretamente de 200-1025nm (Ocean Optics, 2015).



**Figura 15 – Espectrómetro FLAME (Morris, 2021)**

### 3.4.4. Metodologia Utilizada na Recolha de Dados com Sensores

Para tal, tivemos em consideração a seguinte metodologia:

- Dispositivo Multiespectral de Baixo-Custo (Figura 16 b)): Num conjunto de 120 folhas devidamente agrupadas (Figura 16 c)) foram realizadas 10 leituras em cada conjunto de folhas de cada bloco. Antes de se proceder às leituras, o sensor era calibrado no ‘Painel de Refletância Calibrado’ da MicaSense (número de série: RP03), onde se realizavam 2 disparos no painel em questão. Voltava a calibrar-se o sensor ao fim de 42 leituras (4 blocos). De referir ainda que, no conjunto de 120 folhas, as 10 leituras eram feitas em locais diferentes do conjunto. À medida que se realizavam as medições, era feito um registo recorrendo ao software Excel (formato .xlsx) onde estava descrito o dia da leitura, a amostra a que correspondia, o bloco, a identificação do documento onde foram armazenados os dados do sensor (criada pelo sensor em formato ‘.csv’ e armazenada no cartão SD) e o número da leitura (Quadro 3);

**Quadro 3 - Registo excel da informação do sensor de baixo-custo**


DOY	Amostra	Bloco	Documento	Disparo
11/10/2022	V1-T0-C1	B11	data017.csv	3-12

- Espectrómetro de Alta Resolução (Figura 16 a)): Para a recolha dos espectros através deste sensor, foram selecionadas 10 folhas ao acaso do grupo de 120 folhas/bloco (Figura 16 c)) e procedia-se à leitura numa folha individual. Foram realizadas 3 leituras por folha, mais concretamente uma leitura perto do pecíolo da folha, outra no centro e, por fim, outra no ápice da folha, de maneira a garantir uma boa representatividade das folhas. Para o funcionamento deste equipamento era necessário proceder à instalação do software OceanART, possuir uma fonte de luz (AvaLight-Hal), a fibra (QR 400–7–SR–BX), o *specular reflectance standard* (WS-1) para se proceder à calibração do espectrómetro quando iniciado, o suporte da sonda de reflexão (RPH-1) e um cabo USB (CBL-MICROTOA-USB) para ligar o equipamento ao computador, onde posteriormente eram registados os dados. Os ficheiros gerados pelo sensor estavam em formato ‘.tsv’. Indo ao encontro do registo feito para o sensor de baixo-custo, no espectrómetro também se procedia ao registo em Excel (formato .xlsx) onde estava descrito o dia em que foram feitas as leituras com o sensor, a amostra a que correspondia, o bloco e a identificação com o nome do ficheiro criado (Quadro 4).

**Quadro 4 - Registo excel da informação do espectrómetro**

DOY	Amostra	Bloco	Documento
11/10/2022	V1-T0-C1	B11	V1-T0-C1 B11

Para proceder às leituras com ambos os sensores, era sempre verificado se a área onde o sensor iria fazer a leitura estava coberta com o material vegetal.



**Figura 16- a) Espectrómetro de Alta Resolução; b) Dispositivo Multiespectral de Baixo-Custo; c) Conjunto de 120 folhas e conjunto de 10 folhas respetivamente**

### 3.4.5. Preparação das Amostras para Posterior Análise Química

No laboratório, terminadas as leituras com os respetivos sensores, no mesmo dia, procedia-se à preparação do material vegetal para posterior análise química. Para esse efeito era aplicada a metodologia descrita por Silva *et al.* (1999); Carmo *et al.* (2000); Faquin (2002); Silva (2009) citado por Galeriani *et al.* (2020), de maneira a evitar que as amostras de material vegetal fossem contaminadas com pó e/ou resíduos de pulverização. O procedimento de lavagem das folhas consistiu em colocar o material vegetal numa solução de água corrente juntamente com o detergente (TFD 4 – Franklab) não iónico, sem fosfatos (Figura 17 a)) e, posteriormente, numa solução de água destilada (Figura 17 b)).

Após este procedimento o material vegetal foi envolvido com um papel, com o objetivo de retirar a humidade em excesso e, de seguida, as amostras foram colocadas em envelopes devidamente identificados (Figura 17 c)) e levadas para a estufa (Thermo Scientific (Heratherm OMS180)) (Figura 17 d)) a uma temperatura de 65 °C onde permaneciam durante 24 horas. Posteriormente as amostras foram colocadas em caixas e enviadas para o Laboratório Alto Guadalquivir S.L., Labiser, localizado em Córdoba, Espanha, onde foram efetuadas as análises químicas (N, P, K).



**Figura 17 - a) Solução de água corrente e detergente; b) Solução de água destilada; c) Envelopes com respectivas amostras; d) Estufa Thermo Scientific: Heratherm OMSI 80**

### 3.4.6. Métodos Utilizados em Laboratório

Os parâmetros avaliados e metodologia utilizada foram as seguintes:

- **Macronutrientes:**
  - Azoto (N) (%) – utilização do método Kjeldahl;
  - Fósforo (P); Potássio (K) (%) – utilização do método ICP-OES;

### 3.4.7. Processamento dos dados

Nesta etapa analisamos os dados recolhidos com os sensores de maneira a verificar a informação recolhida e, se necessário, corrigir, proceder à normalização dos dados (no caso do sensor de baixo-custo), tratamento e organização dos dados.

Para utilizar a informação do sensor de baixo-custo é necessário proceder à normalização das medições, utilizando como referência a assinatura espectral da superfície de refletância conhecida (53%). Para obter o valor correto de refletância da amostra devemos dividir o valor de refletância medido para uma determinada banda da amostra pelo valor de refletância captado na superfície de refletância conhecida e dividir por 0,53 (Noguera *et al.*, 2023). Neste caso, para disponibilizar a informação aos modelos, dividiu-se apenas o valor da observação pela média das observações de referência para as 18 bandas.

A formatação e organização dos dados consistiu na conversão da informação para o formato adequado e compatível com a biblioteca de programação que se optou (neste caso optou-se pelo formato '.csv'), para que posteriormente possamos passar a informação aos algoritmos. A informação foi organizada no software Excel, onde cada coluna incluía determinada informação. No caso do sensor de baixo-custo estava

representado o código da amostra, resultados das análises foliares, explicação do código da amostra (variedade, tratamento, compasso e bloco), 18 bandas normalizadas, data da recolha das amostras, nome da pasta que continha os dados e nome do ficheiro (Figura 18 a)), somando um total de 1200 linhas de dados. Já no espectrómetro FLAME a informação que cada coluna continha era o código da amostra, resultados das análises foliares, explicação do código da amostra (variedade, tratamento, compasso e bloco), 3648 bandas, local onde foram realizadas as leituras com o espectrómetro (perto do pecíolo, centro e ápice), data da recolha das amostras, nome da pasta que continha os dados e nome do ficheiro, somando um total de 3600 linhas de dados (Figura 18 b)).

a)

id	N	P	K	variedade	tratament	compasso	block_nur	#N	uhu_raw_A	uhu_raw_B	uhu_raw_C	date	folder_na	file_name	
V1-D-C1-B11	1.95	0.2	1.01	1	Azeiteira	1	dobro	1	largo	11	3	781.3	6184.8	6406.4	11/10/2022_2022_10_DATA0201

nº=1199

b)

id	N	P	K	variedade	tratament	compasso	block_nur	192.73	192.99	1039.21	1039.41	1039.62	1039.82	leaf_locat	leaf_locat	date	folder_na	file_name	
V1-D-C1-B11	1.95	0.2	1.01	1	Azeiteira	1	dobro	1	largo	11	112.6761	112.6761	90.9465	87.29508	82.86853	83.49835	0	perto do p	11/10/2022_2022_10_V1-D-C1-B11

nº=3599

**Figura 18 – a) Organização dos dados do sensor de baixo-custo; b) Organização dos dados do Espectrómetro FLAME**

### 3.5. Tratamento Estatístico dos Dados

Os dados foram inicialmente sujeitos a uma análise estatística descritiva e determinação do Coeficiente de Variação (CV), análise realizada no software Excel. Em seguida foi realizada uma análise de variância (ANOVA) por classe de tratamento e por tratamento de fertilização, compasso e variedade com base nos resultados das análises químicas para os macronutrientes principais (recorrendo à linguagem de programação Python (3.12) e à biblioteca SciPy) e a Análise de Componentes Principais (PCA), recorrendo à linguagem de programação Python (3.12) e à biblioteca Scikit-Learn.

## 4. Resultados e Discussão

### 4.1. Análise Estatística Descritiva – Resultados das Análises Foliares

Tendo em conta os resultados das análises foliares em laboratório (Anexo III e IV), nos Quadros infra expostos está representada a estatística descritiva realizada para os macronutrientes principais para cada variedade, tratamento e compasso, tendo em consideração os 10 blocos que constituía cada tratamento.

A análise destes dados indica que em T0 (Quadro 5), ou seja, onde não foi aplicada fertirrega, a V2 apresentou uma média de N e P superior às restantes variedades. Já quanto à média em K, a V3 foi a que apresentou um valor superior. No que diz respeito ao DP, que é uma medida de dispersão que nos indica o quanto os valores estão espalhados em torno da média, em N a V3 tem um valor ligeiramente superior às restantes variedades para o mesmo nutriente, indicado assim uma maior dispersão dos dados em relação à média. Relativamente ao P, a V3 é aquela que apresenta um DP menor, sendo assim a variedade que apresenta menor dispersão dos dados, mas é aquela que apresenta um valor de DP superior para o K, indicando o inverso. Quanto ao CV, razão entre o desvio padrão e a média, a V3 relativamente ao N é a que apresenta maior percentagem (14,77%) indicando alguma dispersão (não excessiva) e V2 é a que representa um valor de CV inferior (9,12%) indicando uma menor dispersão dos dados. Ainda no que diz respeito ao CV, em P a VI é a que apresenta um valor superior e a V3 em K.

**Quadro 5- Estatística descritiva e CV dos resultados das análises foliares (%) de T0 C1**

	V1 - T0 - C1			V2 - T0 - C1			V3 - T0 - C1		
	N (%)	P (%)	K (%)	N (%)	P (%)	K (%)	N (%)	P (%)	K (%)
<b>Máximo</b>	1.78	0.34	0.97	1.95	0.37	1.21	1.71	0.18	1.48
<b>Mínimo</b>	1.22	0.21	0.79	1.46	0.25	0.96	1.12	0.13	1.02
<b>Média</b>	1.48	0.27	0.87	1.57	0.32	1.04	1.38	0.17	1.25
<b>DP</b>	0.19	0.05	0.06	0.14	0.04	0.07	0.20	0.02	0.16
<b>CV (%)</b>	12.53	17.20	6.78	9.12	11.00	6.78	14.77	11.16	12.58

**Legenda:** V1: Azeiteira; V2: Arbequina; V3: Koroneiki; T0: Testemunha; C1: Compasso 3,75 x 1,80 m

No Quadro 6 é possível observar para o T2 (fertilização superior à recomendada) que a V2 continua a ser a variedade que apresenta uma média de N e P superior às restantes variedades e a V3 aquela onde a média de K é superior. No que diz respeito aos valores de DP, a VI relativamente ao N e P é aquela que apresenta um valor superior indicando maior dispersão em relação à média e, quanto ao K a que apresenta menor dispersão. Quanto ao CV, no que diz respeito ao N e P a VI é a variedade que indica maior dispersão dos dados e em K a que apresenta uma menor percentagem, logo menor dispersão. Comparando o Quadro 5 com o Quadro 6 vimos que a quantidade de N e K, no geral, é superior em T2 do que em T0, provavelmente devido à fertilização praticada. Já no que diz respeito ao P, obtivemos valores superiores em T0 do que em T2, que poderá ter haver com a formulação do adubo aplicado ter pouca quantidade de P.

**Quadro 6 - Estatística descritiva e CV dos resultados das análises foliares (%) de T2 C1**

	V1 - T2 - C1			V2 - T2 - C1			V3 - T2 - C1		
	N (%)	P (%)	K (%)	N (%)	P (%)	K (%)	N (%)	P (%)	K (%)
<b>Máximo</b>	1.95	0.29	1.01	2.11	0.32	1.35	1.58	0.18	1.46
<b>Mínimo</b>	1.29	0.18	0.81	1.71	0.24	1.01	1.19	0.12	1.15
<b>Média</b>	1.65	0.23	0.89	1.87	0.29	1.15	1.34	0.15	1.28
<b>DP</b>	0.21	0.04	0.06	0.14	0.02	0.11	0.10	0.02	0.09
<b>CV (%)</b>	12.65	14.97	6.20	7.33	7.47	9.67	7.75	12.66	7.21

**Legenda:** V1: Azeiteira; V2: Arbequina; V3: Koroneiki; T2: Fertilização Superior à Recomendada; C1: Compasso 3,75x 1,80 m

O Quadro 7 indica-nos que para o T0 (sem fertilização) a VI é aquela que apresenta uma média ligeiramente inferior relativamente ao N. Quanto aos valores de P e K, a V2 é a que apresenta uma média superior. Relativamente ao DP, onde existe maior dispersão dos valores em torno da média é no N em VI e V2. Já no que diz respeito ao CV, a maior percentagem está em VI para N e P e em V3 para K, indicando maior dispersão, mas no seu conjunto mantém-se a uniformidade das amostras observadas.

**Quadro 7 - Estatística descritiva e CV dos resultados das análises foliares (%) de T0 C2**

	V1 - T0 - C2			V2 - T0 - C2			V3 - T0 - C2		
	N (%)	P (%)	K (%)	N (%)	P (%)	K (%)	N (%)	P (%)	K (%)
<b>Máximo</b>	1.60	0.32	1.11	1.67	0.43	1.46	1.44	0.24	1.41
<b>Mínimo</b>	1.22	0.21	0.94	1.26	0.32	1.27	1.32	0.18	1.20
<b>Média</b>	1.36	0.24	1.03	1.39	0.36	1.35	1.39	0.21	1.29
<b>DP</b>	0.12	0.03	0.06	0.12	0.03	0.08	0.03	0.02	0.08
<b>CV (%)</b>	8.60	12.73	5.46	8.53	8.32	5.64	2.23	7.45	6.01

**Legenda:** V1: Azeiteira; V2: Arbequina; V3: Koroneiki; T0: Testemunha; C2: Compasso 3,75 x 1,35 m

Por último, no Quadro 8 está representado a estatística descritiva para o T1 (fertilização recomendada). Das três variedades concluímos que a V2 é aquela que tem uma menor quantidade de N mas uma maior quantidade de P e K. No que diz respeito ao DP, existe maior dispersão dos valores em torno da média na V2 em N e P. Já quanto ao K a maior distribuição é em V1. Quanto ao CV encontra-se uma maior dispersão em N e P na V2 e em K na V1. Comparando o Quadro 7 com o Quadro 8 vimos que a quantidade de P e K é superior em T0 do que em T1, que poderá ser justificado pelo tipo de solo ser mais argiloso em T0 do que em T1 (Franco/Franco-Arenoso).


**Quadro 8 - Estatística descritiva e CV dos resultados das análises foliares (%) de T1 C2**

	V1 - T1 - C2			V2 - T1 - C2			V3 - T1 - C2		
	N (%)	P (%)	K (%)	N (%)	P (%)	K (%)	N (%)	P (%)	K (%)
<b>Máximo</b>	1.64	0.25	1.36	1.67	0.41	1.40	1.77	0.24	1.40
<b>Mínimo</b>	1.25	0.15	0.83	1.22	0.21	1.16	1.32	0.16	1.06
<b>Média</b>	1.41	0.20	1.00	1.36	0.32	1.27	1.44	0.20	1.26
<b>DP</b>	0.13	0.03	0.18	0.14	0.05	0.07	0.13	0.02	0.12
<b>CV (%)</b>	9.44	16.13	17.50	10.54	16.39	5.84	9.00	10.61	9.79

Legenda: V1: Azeiteira; V2: Arbequina; V3: Koroneiki; T1: Fertilização Recomendada; C2: Compasso 3,75 x 1,35 m

Considerando a média por tratamento e variedade dos resultados das análises foliares e os valores de referência para o estado fenológico ‘endurecimento do caroço’ de acordo com Veloso *et al.* (2022), os Quadros 5, 6, 7 e 8 indicam que tendo em conta um limite de N entre 1,50 % e 2,00 %, no geral a quantidade de N nos tratamentos foi inferior à quantidade de N recomendada com exceção da V1 e V2 em T2, e da V2 em T0 C1. Relativamente ao P (limite 0,10 % a 0,30%), no geral os resultados permaneceram dentro do limite recomendado, com exceção da V2 em T0 C1 e T1 (0,32 %) e em T0 C2 (0,36%), onde foram superiores ao limite. Quanto ao K (ideal 0,80 % a 1,20%) os resultados também foram superiores ao limite recomendado na V3 em T2 (1,28%) e em T0 C1 (1,25%), em T1 na V2 (1,27%) e na V3 (1,26%), e em T0 C2 na V2 (1,35%) e na V3 (1,29%).

A Figura 19 (software Plotly.js (v2.16.1)) mostra a distribuição das variedades por cada macronutriente principal, onde cada ponto corresponde ao resultado obtido de uma amostra de laboratório. A V2 apresentou valores de N e P superiores à V1 e V3. Já a V3 apresentou valores de K superiores à V2 e à V1. Observou-se que a combinação de P e K foi onde mais se diferenciaram as variedades.




**Figura 19 - Distribuição das variedades por cada macronutriente principal**

#### 4.2. Estatística Descritiva – Diagrama de Caixa (Boxplot)


Para resumir e visualizar a distribuição dos dados, através do software Excel foram criados diagramas de caixa de maneira a representar graficamente a variação dos dados, sendo posteriormente mais fácil identificar padrões, tendências e valores anómalos no conjunto de dados. Para a criação destes diagramas foram tidos em consideração os valores dos resultados das análises químicas foliares para os macronutrientes principais e para as diferentes variedades, tratamentos e compassos.

No que diz respeito à V1 (Figura 20), no geral existe uma maior dispersão nos dados para o N. Há exceção do K em T1 (que também tem maior dispersão dos dados), tanto para o P como para o K no geral dos tratamentos temos menor dispersão e maior simetria nos dados. Em T0 C2 para o P está representado um *outlier*, ou seja, um ponto fora do limite inferior e superior que nos indica que temos um valor atípico comparativamente com os restantes dados. Tendo uma representação gráfica do que foi referido anteriormente (subcapítulo 4.1.), no que diz respeito aos valores médios observou-se valores médios de P mais altos em T0 C1 do que em T2. Em T0 C2, os valores médios de P e K também foram mais elevados do que em T1.




**Figura 20 - VI por tratamento de fertilização**

Os resultados das análises químicas mostraram que para a V2 (Figura 21) a dispersão que observamos no N era inferior à VI. O T2 e o T1 foram os tratamentos que mostraram maior dispersão e menor simetria nos dados. Relativamente ao K verificou-se uma maior dispersão em T2. Outro ponto a referir é que, para a variedade em questão houve mais *outlier* no N para ambos os T0, para o K em T0 C1 e para o P no geral dos tratamentos.



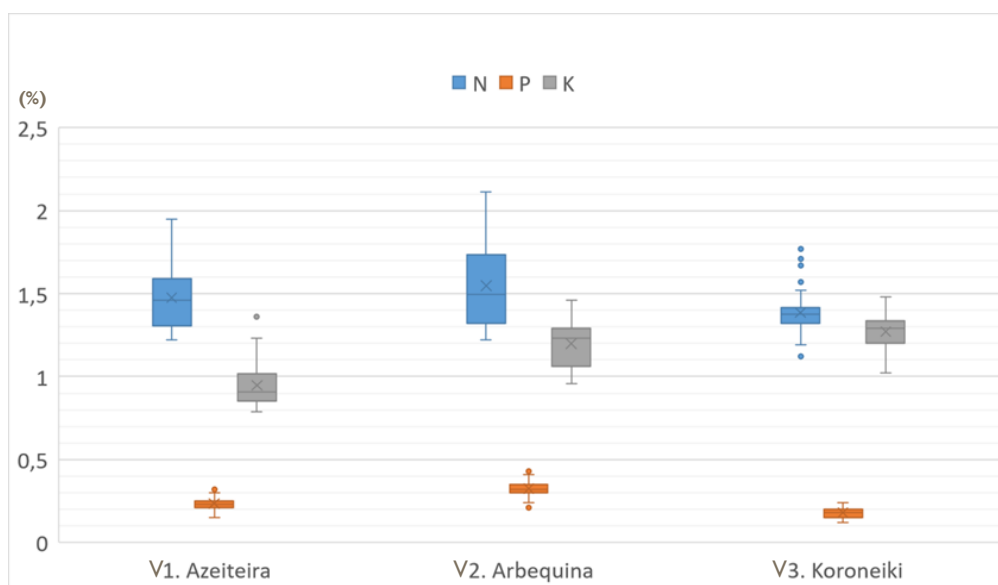
**Figura 21 - V2 por tratamento de fertilização**

Para a V3 (Figura 22), o primeiro aspeto a salientar é que em T0 C1, para o N, foi onde se verificou uma maior dispersão dos dados. Verificaram-se *outliers* em T2 e T0 C2 para o N e em T1 para o N e P.



**Figura 22 - V3 por tratamento de fertilização**

Relativamente à Figura 23 verificou-se que a V2 apresentou um valor médio de N e P superior às restantes variedades, embora com uma maior dispersão dos dados. Já a V3 foi a que apresentou um valor médio de K superior, mas foi também a que apresentou mais *outliers* no N respetivamente.



**Figura 23- Distribuição dos macronutrientes principais por variedade**

### 4.3. Análise de Variância (ANOVA) para os macronutrientes principais

Nos Quadros 9 e 10 estão representados os resultados da determinação do one-way ANOVA onde, em ambos os casos, dada uma categoria (ou classe) (variável independente), é verificado se existe diferenças na quantidade do N, P e K (variáveis dependentes). Assume-se que há diferenças entre as categorias (ou classes) quando o p-value é inferior a 0,05.

#### 4.3.1. ANOVA para a classe de tratamento

O Quadro 9 contém os resultados da ANOVA apenas para a classe de tratamento, agrupado por variedade. No que diz respeito à análise realizada para o N, na V1 e V2 existem diferenças estatísticas significativas ( $p < 0,05$ ) entre tratamentos. Quanto ao P, há diferenças estatísticas significativas entre tratamentos nas três variedades. Por último, no que diz respeito ao K observamos que não há diferenças entre as variedades e tratamentos ( $p > 0,05$ ). Em suma, destes resultados desprende-se que a fertilização não afeta significativamente o N na V3 e o K não apresenta diferenças qualquer que seja a variedade.

**Quadro 9: ANOVA para a classe de tratamento, agrupada por variedade**

Variedade	N		P		K	
	F statistic	p-value	F statistic	p-value	F statistic	p-value
Azeiteira (V1)	12.20	0.00	6.39	0.00	1.70	0.19
Arbequina (V2)	35.19	0.00	6.95	0.00	2.31	0.11
Koroneiki (V3)	1.40	0.25	11.32	0.00	0.67	0.52

#### 4.3.2. ANOVA para as classes de tratamento de fertilização, compasso e variedade

No Quadro 10 estão apresentados os resultados da ANOVA para as classes de tratamento de fertilização, compasso e variedade. Relativamente ao N e P, vimos que há diferenças estatísticas significativas ( $p < 0,05$ ) entre tratamentos, variedades e compassos. Para o K não existem diferenças para o tratamento, no entanto há diferenças estatísticas significativas para a variedade e o compasso. Em resumo, para estes resultados o p-value só é superior a 0,05 para o K no tratamento de fertilização, indicando assim que para este macronutriente principal as diferenças não são atribuíveis aos diferentes tratamentos de fertilização podendo ser mais dependente das características das variedades, por exemplo.

Os resultados do compasso acabam por ser menos interessantes devido ao enviesamento pelos tratamentos (T2 só está presente no C1 e T1 só no C2).

**Quadro 10: ANOVA para as classes de tratamento de fertilização, compasso e variedade**

	N		P		K	
	F statistic	p-value	F statistic	p-value	F statistic	p-value
Tratamento	15.95	0.00	4.74	0.01	1.54	0.22
Variedade	13.61	0.00	128.33	0.00	88.01	0.00
Compasso	30.82	0.00	9.30	0.00	16.19	0.00

#### 4.4. Tratamento de Dados dos Sensores

Para trabalhar os dados e posteriormente se obterem os resultados recorreu-se à linguagem de programação Python (3.12). Ao termos dados de referência optou-se pela aprendizagem supervisionada e, como a referência são valores contínuos, optou-se pela regressão. Com recurso à biblioteca Scikit-Learn, foram selecionados cerca de 43 modelos de regressão disponíveis para a aprendizagem automática. Posteriormente, na fase que visa treinar os modelos, disponibilizaram-se 70% dos dados recolhidos aos modelos. De seguida foi feita uma avaliação dos modelos anteriormente treinados com os restantes 30% dos dados recolhidos, que ainda não tinham sido disponibilizados aos modelos, onde se calcularam métricas, como foi o caso do coeficiente de determinação ( $R^2$ ), e se interpretaram os resultados.

##### 4.4.1. Análise de Componentes Principais (PCA)

Procedeu-se à PCA, com o principal objetivo de reduzir a dimensionalidade dos dados mantendo a maior expressividade dos mesmos. Posto isto, inicialmente foi necessário atribuir o mesmo peso às refletâncias recorrendo ao Z-score para atingir esse objetivo. Posteriormente foram calculadas todas as componentes PCA para os dados em questão. Como as primeiras colunas passam a ter a maior parte da informação, depois dessa transformação foram selecionadas quantas colunas queríamos passar ao modelo com a garantia de que estávamos a passar primeiro as colunas mais importantes. Optou-se por fazer comparações selecionando vários critérios de escolha de componentes principais (baixo, médio e alto), nomeadamente 4, 10 e 20 componentes principais para o espectrómetro e para o sensor de baixo-custo, ao ter comprimentos de onda mais reduzidos, decidiu-se passar ao modelo a informação sem aplicação do PCA, com a

aplicação de PCA onde foram disponibilizadas ao modelo 4 componentes principais e a PCA onde todas as componentes foram utilizadas.

#### 4.4.2. Resultados obtidos

Com o principal objetivo de encontrar uma relação entre os dados recolhidos com os sensores e o teor de macronutrientes principais presentes no material vegetal (analisado em laboratório), obtiveram-se os seguintes resultados ( $R^2$ ) para o espectrómetro FLAME (Quadro 11) e para o sensor de baixo-custo (Quadro 12). Cada linha corresponde a um modelo de regressão diferente e nas colunas estão representadas diferentes parametrizações de pré-processamento, onde os números (4, 10 e 20) indicam a quantidade de componentes principais que foram tidas em consideração e, para o Quadro 12 (sensor de baixo-custo), 'None' indica que não foi aplicado PCA e 'All' indica que o PCA foi aplicado e todos os componentes foram utilizados. Para a elaboração destes Quadros apenas foram tidos em consideração os três melhores modelos para cada macronutriente principal.

No que diz respeito ao espectrómetro de alta resolução (Quadro 11), obtivemos os melhores resultados em 20 componentes principais, destacando-se os resultados para o P e K, e no sensor de baixo-custo (Quadro 12), de uma forma geral, nos dados onde todas as componentes principais foram tidas em consideração. Quanto ao N, numa primeira fase os resultados não são muito promissores. No que diz respeito ao P e K os resultados foram mais promissores e houve uma maior variedade de modelos diferentes a alcançar bons resultados.

**Quadro 11: Modelos com melhores resultados do Coeficiente de Determinação ( $R^2$ ) para o espectrómetro**

		Espectrómetro FLAME ( $R^2$ )					
Modelo \ Componentes PCA		4	Modelo \ Componentes PCA	10	Modelo \ Componentes PCA	20	
Azoto	GradientBoostingRegressor	0.17	ExtraTreesRegressor	0.19	ExtraTreesRegressor	0.27	
	MLPRegressor	0.16	GradientBoostingRegressor	0.17	GradientBoostingRegressor	0.26	
	ExtraTreesRegressor	0.15	RandomForestRegressor	0.15	RandomForestRegressor	0.26	
Fósforo	RadiusNeighborsRegressor	0.51	ExtraTreesRegressor	0.61	KNeighborsRegressor	0.67	
	ExtraTreesRegressor	0.49	KNeighborsRegressor	0.59	GradientBoostingRegressor	0.64	
	GradientBoostingRegressor	0.48	RandomForestRegressor	0.58	ExtraTreesRegressor	0.64	
Potássio	AdaBoostRegressor	0.52	ExtraTreesRegressor	0.56	SVR	0.60	
	RandomForestRegressor	0.51	RandomForestRegressor	0.56	ExtraTreesRegressor	0.58	
	ExtraTreesRegressor	0.51	GradientBoostingRegressor	0.55	GradientBoostingRegressor	0.57	

**Quadro 12: Modelos com melhores resultados do Coeficiente de Determinação (R<sup>2</sup>) para o sensor de baixo-custo**

Sensor de Baixo-Custo (R <sup>2</sup> )						
	Modelo \ Componentes PCA	None	Modelo \ Componentes PCA	4	Modelo \ Componentes PCA	All
Azoto	ExtraTreesRegressor	0.29	ExtraTreesRegressor	0.11	ExtraTreesRegressor	0.34
	RandomForestRegressor	0.29	ARDRegression	0.11	RandomForestRegressor	0.30
	GradientBoostingRegressor	0.28	BayesianRidge	0.10	BaggingRegressor	0.27
Fósforo	NuSVR	0.34	ExtraTreesRegressor	0.09	ExtraTreesRegressor	0.39
	ExtraTreesRegressor	0.30	KNeighborsRegressor	0.07	HistGradientBoostingRegressor	0.36
	HistGradientBoostingRegressor	0.26	RandomForestRegressor	0.06	RandomForestRegressor	0.36
Potássio	ExtraTreesRegressor	0.24	ExtraTreesRegressor	0.21	SVR	0.44
	NuSVR	0.24	GradientBoostingRegressor	0.19	NuSVR	0.42
	SVR	0.24	RandomForestRegressor	0.19	KNeighborsRegressor	0.38

No Quadro 13 estão descritos 4 dos modelos utilizados com bom desempenho.

**Quadro 13: Descrição dos modelos**

Tipo de Aprendizagem	Tipo de Modelo	Algoritmo	Descrição
Supervisionada	Regressão	GradientBoostingRegressor	- Corrige os erros dos modelos anteriores melhorando a precisão das previsões (scikit learn, 2023).
		Support Vector Regression (SVR)	- O objetivo é encontrar uma função que reduza a diferença entre as previsões e os valores reais (Beltrami <i>et al.</i> , 2010).
		KNeighborsRegressor	- Regressão baseada em k-neighbors mais próximos, ou seja, o “alvo” é previsto pela interpolação local dos alvos associados aos neighbors mais próximos no conjunto de dados de treino (scikit learn, 2023).
		ExtraTreesRegressor	- Ajusta árvores de decisão aleatórias em várias sub-amostras do conjunto de dados e usa a média para melhorar a precisão e controlar o <i>overfitting</i> (scikit learn, 2023).

## 5. Conclusões

No que diz respeito aos resultados das análises foliares, a V2 apresentou valores de N e P superiores às restantes variedades e, no que diz respeito ao K, a V3 apresentou valores superiores, resultados que a verificarem-se em novos ensaios podem validar a importância da fertilização diferenciada por variedade.

No que respeita à avaliação das duas técnicas sensoriais para estimar o estado nutritivo da cultura, embora seja um trabalho preliminar, concluímos que numa primeira abordagem os resultados com o espectrómetro FLAME foram bastante promissores. No que diz respeito ao sensor de baixo-custo é necessário tentar outra abordagem, como por exemplo tentar fazer uma calibração mais minuciosa de acordo com os valores do espectrómetro, mais concretamente perceber como as medições do sensor de baixo-custo variam com as refletância, provenientes do espectrómetro, e possivelmente tentar ajustar as medições do sensor de baixo-custo com as do espectrómetro.

Relativamente aos modelos que obtiveram um maior valor de coeficiente de determinação ( $R^2 > 0,50$ ) a estimar os macronutrientes principais, destaca-se o KNeighborsRegressor, GradientBoostingRegressor, ExtraTreesRegressor e SVR, no espectrómetro utilizando as 20 componentes principais. Concluiu-se também que os resultados foram mais promissores na estimativa do P e K do que no N (indo ao encontro do que ocorreu no estudo realizado por Noguera *et al.* (2021) onde avaliaram o estado nutricional das oliveiras por meio de análise e modelagem de imagens multiespectrais recolhidas com UAV), que pode estar relacionado com o facto de os modelos de regressão conseguirem obter uma melhor relação entre os valores das bandas (dados de entrada) e os nutrientes P e K do que para o N.

## 6. Bibliografia

- ADP. (2023). *Olival*. ADP Fertilizantes. Consultado a 17 de março de 2023. Disponível em <https://www.adp-fertilizantes.pt/pt/agricultura/servi%C3%A7o-ao-agricultor/culturas/lista-de-culturas/olival>
- AGROTEC. (2022). *Agricultores portugueses consideram digital essencial para a produtividade e sustentabilidade*. AGROTEC: Revista técnico-científica agrícola. Consultado a 16 de dezembro de 2022. Disponível em <http://www.agrotec.pt/noticias/agricultores-portugueses-consideram-digital-essencial-para-a-produtividade-e-sustentabilidade/>
- Anastasiou, E., Balafoutis, A., & Fountas, S. (2023). *Trends in Remote Sensing Technologies in Olive Cultivation*. ScienceDirect. Consultado a 17 de março de 2023. Disponível em <https://www.sciencedirect.com/science/article/pii/S2772375522000685>
- Aquino, A., Noguera, M., Millan, B., Mejías, A., Ponce, J., & Andújar, J. (2022). *A Preliminary Evaluation of a Low-Cost Multispectral Sensor for Non-Destructive Evaluation of Olive Fruits' Fat Content*. Repositorio Universidad da Coruña. Consultado a 20 de janeiro de 2023. Disponível em [https://ruc.udc.es/dspace/bitstream/handle/2183/31461/2022\\_Aquino\\_Arturo\\_A\\_preliminary\\_evaluation\\_of\\_a\\_low-cost\\_multispectral\\_sensor.pdf?sequence=3&isAllowed=y](https://ruc.udc.es/dspace/bitstream/handle/2183/31461/2022_Aquino_Arturo_A_preliminary_evaluation_of_a_low-cost_multispectral_sensor.pdf?sequence=3&isAllowed=y)
- Aquino, A., Ponce, J., & Andújar, J. (2020). *Identificação de oliveiras, em olivais intensivos, através da sua estrutura morfológica através de redes neurais convolucionais*. ELSEVIER. Consultado a 16 de dezembro de 2022. Disponível em <https://www.sciencedirect.com/science/article/abs/pii/S0168169919323683> .
- Arrobas, M., & Moutinho-Pereira, J. (2009). *Manual de Safra e Contra Safra do Olival - Fertilização do Olival*. Biblioteca Digital IPB. Consultado a 17 de dezembro de 2022. Disponível em <https://bibliotecadigital.ipb.pt/bitstream/10198/7378/3/1%20manual%20safra%202009.pdf>
- Atik, M., & Akdemir, B. (2022). *Spatial Variability of NDVI and SPAD for Variable- and Fixed-Rate Fertilization in Olive Orchards*. SpringerLink. Consultado a 7 de abril de 2023. Disponível em <https://link.springer.com/article/10.1007/s10341-022-00748-w>
- Beltrami, M., Loch, G., & Silva, A. (2010). *COMPARAÇÃO DAS TÉCNICAS DE SUPPORT VECTOR REGRESSION*. XLII SBPO. Consultado a 17 de março de 2023. Disponível em <http://din.uem.br/sbpo/sbpo2010/pdf/72230.pdf>
- Best, S., León, L., Méndez, A., Flores, F., & Aguilera, H. (2014). *Adopción Y Desarrollo de Tecnología en Agricultura de Precisión*. gisandbeers. Consultado a 7 de abril de 2023. Disponível em <http://www.gisandbeers.com/RRSS/Publicaciones/Tecnologia-Agricultura-Precision.pdf>
- Best, S., León, L., Quintana, R., Flores, F., Aguilera, H., Concha, V., & Thomas, P. (2012). *Olivicultura de precisión: nuevas tecnologías aplicables a olivicultura*. Digital Library INIA. Consultado a 17 de dezembro de 2022. Disponível em <https://biblioteca.inia.cl/handle/20.500.14001/7579?&locale-attribute=en>

- Bishop, C. (2006). *Pattern Recognition and Machine Learning*. Institute For Systems and Robotics. Consultado a 16 de dezembro de 2022. Disponível em <http://users.isr.ist.utl.pt/~wurmd/Livros/school/Bishop%20-%20Pattern%20Recognition%20And%20Machine%20Learning%20-%20Springer%20%202006.pdf>
- Borba, M., Ramos, J., Ramborger, B., Marques, E., & Machado, J. (2022). *Gestão no meio agrícola com o apoio da Inteligência Artificial: uma análise da digitalização da agricultura*. ReasearchGate. Consultado a 20 de janeiro de 2023. Disponível em [https://www.researchgate.net/publication/362487580\\_Gestao\\_no\\_meio\\_agricola\\_com\\_o\\_apoio\\_da\\_Inteligencia\\_Artificial\\_uma\\_analise\\_da\\_digitalizacao\\_da\\_agricultura](https://www.researchgate.net/publication/362487580_Gestao_no_meio_agricola_com_o_apoio_da_Inteligencia_Artificial_uma_analise_da_digitalizacao_da_agricultura)
- Cardoso, J. (1965). *Os solos de Portugal - Sua classificação, caracterização e génese (I - A Sul do Rio Tejo)* [The soils of Portugal - Their classification, characterization and genesis (I - South of the Tejo River)]. Secretaria De Estado Da Agricultura, Direção-Geral Dos Serviços Agrícolas. Disponível em <https://www.dgadr.gov.pt/mediateca?task=download.send&id=401&catid=48&m=0>
- Ciruela-Lorenzo, A., Obra, A., Padilla-Meléndez, A., & Plaza-Angulo, J. (2020). *Digitalization of agri-cooperatives in the smart agriculture context. proposal of a digital diagnosis tool*. MDPI. Consultado a 17 de dezembro de 2022. Disponível em <https://www.mdpi.com/2071-1050/12/4/1325>
- Clara, A. (2021). *'AgroRadar': uma solução de baixo custo de agricultura de precisão*. AgriTerra. Consultado a 17 de dezembro de 2022. Disponível em <https://www.agriterra.pt/Artigos/372112-Projeto-%27AgroRadar%27-uma-solucao-de-baixo-custo-de-agricultura-de-precisao.html>
- ClimateData. (2022). *Clima Elvas (Portugal)*. ClimateData. Consultado a 20 de janeiro de 2023. Disponível em <https://pt.climate-data.org/europa/portugal/elvas/elvas-7061/#temperature-graph>
- Conceição, L., & Rodrigues, F. M. (2020). *Monitorização de olivais através do uso de técnicas de deteção remota*. Agronegocios. Consultado a 18 de dezembro de 2022. Disponível em <http://www.agronegocios.eu/noticias/monitorizacao-de-olivais-atraves-do-uso-de-tecnicas-de-detecao-remota/>
- Costa, M. (2022). *A agricultura como promotora da sustentabilidade do planeta*. Agroportal. Consultado a 8 de abril de 2023. Disponível em <https://www.agroportal.pt/a-agricultura-como-promotora-da-sustentabilidade-do-planeta/>
- DGADR. (2023). *Nota Explicativa da Carta dos Solos de Portugal e da Carta de Capacidade de Uso do Solo*. Direção-Geral de Agricultura e Desenvolvimento Rural. Consultado a 10 de agosto de 2023. Disponível em <https://www.dgadr.gov.pt/nota-explicativa>
- Dores, R. (2021). *A revolução digital na agricultura à boleia de drones e satélites*. Diário de Notícias. Consultado a 10 de agosto de 2023. Disponível em <https://www.dn.pt/sociedade/a-revolucao-digital-na-agricultura-a-boleia-de-drones-e-satelites-l3343860.html>
- EDIA. (2021). *Relatório da Campanha de Rega | 2020*. EDIA - Empresa de Desenvolvimento e Infra-estruturas do Alqueva, S.A.. Consultado a 20 de janeiro de 2023. Disponível em

[https://www.edia.pt/wp-content/uploads/2021/02/RELATORIOCAMPANHA2020\\_PERIMETROSALQUEVA.pdf](https://www.edia.pt/wp-content/uploads/2021/02/RELATORIOCAMPANHA2020_PERIMETROSALQUEVA.pdf)

- EOS. (2020). *Drones na Agricultura: Futura Aplicação Massiva*. Earth Observing System. Consultado a 20 de janeiro de 2023. Disponível em <https://eos.com/pt/blog/drones-na-agricultura/>
- EOS. (2023). *NDVI*. Earth Observing System. Consultado a 20 de janeiro de 2023. Disponível em <https://eos.com/pt/make-an-analysis/ndvi/> .
- Erena, M., López-Francos, A., Montesinos, S., & Berthoumieu, J. P. (2012). *The use of multispectral and thermal images as a tool for irrigation scheduling in vineyards*. CIHEAM. Consultado a 20 de janeiro de 2023. Disponível em <https://om.ciheam.org/om/pdf/b67/00006603.pdf> .
- European Union. (2023). *Digitalização do setor agrícola europeu: Atividades no Horizonte 2020*. Comissão Europeia. Consultado a 11 de agosto de 2023. Disponível em <https://digital-strategy.ec.europa.eu/pt/policies/digitalisation-agriculture-horizon-2020>
- Fu, Z., Jiang, J., Gao, Y., Krienke, B., Wang, M., Zhong, K., Qiang, C., Tian, Y., Zhu, Y., Cao, W., Liu, & X.-J. (2020). *Wheat Growth Monitoring and Yield Estimation based on Multi-Rotor Unmanned Aerial Vehicle*. ResearchGate. Consultado a 11 de agosto de 2023. Disponível em [https://www.researchgate.net/publication/339071901\\_Wheat\\_Growth\\_Monitoring\\_and\\_Yield\\_Estimation\\_based\\_on\\_Multi-Rotor\\_Unmanned\\_Aerial\\_Vehicle](https://www.researchgate.net/publication/339071901_Wheat_Growth_Monitoring_and_Yield_Estimation_based_on_Multi-Rotor_Unmanned_Aerial_Vehicle)
- Furtak, J., Zielinski, Z., & Chudzikiewicz, J. (2019). *A Framework for Constructing a Secure Domain of Sensor Nodes*. MDPI. Consultado a 11 de agosto de 2023. Disponível em <https://www.mdpi.com/1424-8220/19/12/2797>
- Galeriani, T., Cosmo, B., & Beneton, A. (2020). *Preparo de amostras de tecido vegetal*. FCAV / Unesp. Consultado a 12 de agosto de 2023. Disponível em <https://www.fcav.unesp.br/Home/ensino/departamentos/cienciasdaproducaoagricola/lab-oratoriodematologia-labmato/revistaagronomiabrasileira/rab202013.pdf>
- Giovas, R., Tassopoulos, D., Kalivas, D., Lougkos, N., & Priovolou, A. (2021). *Remote Sensing Vegetation Indices in Viticulture: A Critical Review*. MDPI. Consultado a 12 de agosto de 2023. Disponível em <https://www.mdpi.com/2077-0472/11/5/457>
- Głodowska, M., & Wozniak, M. (2019). *Changes in Soil Microbial Activity and Community Composition as a Result of Selected Agricultural Practices*. Scientific Research. Consultado a 20 de dezembro de 2022. Disponível em <https://www.scirp.org/journal/paperinformation.aspx?paperid=91171>
- Gómez-Casero, M., López-Granados, F., Penã-Barragán, J., Jurado-Expósito, M., García-Torres, L., & Fernández-Escobar, R. (2007). *Assessing Nitrogen and Potassium Deficiencies in Olive Orchards through Discriminant Analysis of Hyperspectral Data*. ResearchGate. Consultado a 10 de abril de 2023. Disponível em [https://www.researchgate.net/publication/237048488\\_Assessing\\_Nitrogen\\_and\\_Potassium\\_Deficiencies\\_in\\_Olive\\_Orchards\\_through\\_Discriminant\\_Analysis\\_of\\_Hyperspectral\\_Data](https://www.researchgate.net/publication/237048488_Assessing_Nitrogen_and_Potassium_Deficiencies_in_Olive_Orchards_through_Discriminant_Analysis_of_Hyperspectral_Data)
- GPP. (2020). *Análise Setorial Azeite*. GPP. Consultado a 12 de agosto de 2023. Disponível em [https://www.gpp.pt/images/PEPAC/Anexo\\_NDICE\\_ANLISE\\_SETORIAL\\_\\_\\_AZEITE.pdf](https://www.gpp.pt/images/PEPAC/Anexo_NDICE_ANLISE_SETORIAL___AZEITE.pdf)

- INE. (2022). *Superfície das principais culturas agrícolas (ha) por Localização geográfica (Região agrícola) e Espécie; Anual*. Instituto Nacional de Estatística. Consultado a 12 de agosto de 2023. Disponível em [https://www.ine.pt/xportal/xmain?xpid=INE&xpgid=ine\\_indicadores&indOcorrCod=000019&xlang=pt&contexto=bd&selTab=tab2](https://www.ine.pt/xportal/xmain?xpid=INE&xpgid=ine_indicadores&indOcorrCod=000019&xlang=pt&contexto=bd&selTab=tab2)
- INIAV, I.P. (2023). *AI4RealAg - Soluções de Inteligência Artificial e Data Science para a implementação e democratização da agricultura digital*. Instituto Nacional de Investigação Agrária e Veterinária, I.P. Consultado a 4 de janeiro de 2023. Disponível em <https://www.inia.pt/projetos/al4realag>
- Interreg. (2023). *Agricultura de Precisão*. Interreg. Consultado a 13 de agosto de 2023. Disponível em <https://learningdata.hubiberiaagrotech.eu/sensores-distantes/>
- IPMA. (2023). *Normais Climatológicas*. IPMA. Consultado a 13 de agosto de 2023. Disponível em <https://www.ipma.pt/pt/oclima/normais.clima/>
- Jagdale, M., Shrivastava, P., Paradkar, V., Bijarniya, H., & Murthy, G. (2021). *Farm Mechanization to Improve Energy Efficiency and Drudgery Reduction*. ResearchGate. Consultado a 13 de agosto de 2023. Disponível em [https://www.researchgate.net/publication/354160728\\_Farm\\_Mechanization\\_to\\_Improve\\_Energy\\_Efficiency\\_and\\_Drudgery\\_Reduction](https://www.researchgate.net/publication/354160728_Farm_Mechanization_to_Improve_Energy_Efficiency_and_Drudgery_Reduction)
- Jordão, P., & Marcelo, M. E. (2015). *A fertilização do olival em produção*. Vida Rural. Consultado a 4 de janeiro de 2023. Disponível em <https://www.vidarural.pt/sem-categoria/a-fertilizacao-do-olival-em-producao/>
- Louro, M. (2019). *Portugal a liderar a olivicultura moderna internacional*. Parlamento. Consultado a 4 de janeiro de 2023. Disponível em <https://app.parlamento.pt/webutils/docs/doc.pdf?path=6148523063446f764c324679626d56304c334e706447567a4c31684a566b786c5a793944543030764e304e425453394562324e31625756756447397a51574e3061585a705a47466b5a554e7662576c7a633246764c3259314f574d784d6d59354c574e6c4f>
- Magalhães, L. (2016). *Dendrómetro de baixo custo para a agricultura de precisão*. [Dissertação de mestrado, Universidade de Trás-os-Montes e Alto Douro]. Repositório: UTAD. Disponível em <https://repositorio.utad.pt/handle/10348/5848>
- Malvern Panalytical. (2023). *Espectrorradiômetro ASD FieldSpec® 4 Standard-Res*. Malvern Panalytical. Consultado a 4 de janeiro de 2023. Disponível em <https://www.malvernpanalytical.com/br/products/product-range/asd-range/fieldspec-range/fieldspec-4-standard-res-spectroradiometer>
- Mamdouh, N., Wael, M., & Khattab, A. (2022). *Chapter 14 - Artificial intelligence-based detection and counting of olive fruit flies: A comprehensive survey*. ScienceDirect. Consultado a 13 de agosto de 2023. Disponível em <https://www.sciencedirect.com/science/article/abs/pii/B9780323852142000124>
- Molin, J., Ferraz, M., Inamasu, R., & Braga, R. (2021). *Precision Ag Definition*. International Society of Precision Agriculture. Consultado a 13 de agosto de 2023. Disponível em <https://www.ispag.org/about/definition>

- Morris, R. (2021). *Flame Series General Purpose Spectrometers*. Ocean Insight. Consultado a 4 de janeiro de 2023. Disponível em <https://www.oceaninsight.com/blog/flame-series-general-purpose-spectrometers/>
- Nobre, M. (2021). *Tudo é Economia: O Olival em Portugal - RTP*. AGROPORTAL. Consultado a 4 de janeiro de 2023. Disponível em <https://www.agroportal.pt/tudo-e-economia-o-olival-em-portugal/>
- Nogueira, M., Aquino, A., Ponce, J., Cordeiro, A., Silvestre, J., Calderón, R. A., Marcelo, M., Jordão, P., & Andújar, J. (2021). Nutritional status assessment of olive crops by means of the analysis and modelling of multispectral images taken with UAVs. ScienceDirect. Consultado a 4 de janeiro de 2023. Disponível em <https://www.sciencedirect.com/science/article/abs/pii/S1537511021002191>
- Nogueira, M., Millán, B., & Andújar, J. (2022). *New, Low-Cost, Hand-Held Multispectral Device for In-Field Fruit-Ripening Assessment*. MDPI. Consultado a 4 de janeiro de 2023. Disponível em <https://www.mdpi.com/2077-0472/13/1/4>
- Ocean Optics. (2015). *Flame Miniature Spectrometer: User Manual*. OceanInsight. Consultado a 4 de janeiro de 2023. Disponível em <https://www.oceaninsight.com/globalassets/catalog-blocks-and-images/manuals--instruction-ocean-optics/spectrometer/flameio.pdf>
- Ocean Optics. (2016). *Flame-NIR Miniature Spectrometer - User Manual*. OceanInsight. Consultado a 4 de janeiro de 2023. Disponível em <https://www.oceaninsight.com/globalassets/catalog-blocks-and-images/manuals--instruction-ocean-optics/spectrometer/flamenir.pdf>
- Oliveira, E. (2023). *Análise de fertilizantes NPK por espectroscopia Raman e espectrometria de absorção atômica e molecular*. [Pós-Graduação, Universidade Estadual Paulista]. Repositório Institucional UNESP. Disponível em <https://repositorio.unesp.br/handle/11449/243222>
- One Soil. (2023). *O que é o índice NDVI e como ele facilita a vida do agricultor*. One Soil/Blog. Consultado a 4 de janeiro de 2023. Disponível em <https://blog.onesoil.ai/pt/what-is-ndvi>
- Paço, T., Santos, F., & Siqueira, J. (2011). *Modelação das necessidades hídricas de olivais regados utilizando variáveis e parâmetros biofísicos e deteção remota*. Repositório Universidade de Évora. Consultado a 10 de abril de 2023. Disponível em [https://dspace.uevora.pt/rdpc/bitstream/10174/6522/1/Paco\\_et%20al\\_ISA100\\_2011\\_o\\_live\\_final\\_LS.pdf](https://dspace.uevora.pt/rdpc/bitstream/10174/6522/1/Paco_et%20al_ISA100_2011_o_live_final_LS.pdf)
- Patanita, M., Tomaz, A., & Patanita, M. (2021). *OLIVICULTURA – O DESAFIO DA SUSTENTABILIDADE*. Repositório IPBeja. Consultado a 4 de janeiro de 2023. Disponível em [https://repositorio.ipbeja.pt/bitstream/20.500.12207/5594/3/Olivicultura\\_Desafio%20da%20sustentabilidade\\_2021\\_PDFa.pdf](https://repositorio.ipbeja.pt/bitstream/20.500.12207/5594/3/Olivicultura_Desafio%20da%20sustentabilidade_2021_PDFa.pdf)
- Pinto, L., Cabral, R., & Gonçalves, J. (2021). *Olival Tradicional: situação e perspectivas*. InforCNA. Consultado a 4 de janeiro de 2023. Disponível em [https://www.inforcna.pt/Media/Files/20211230\\_20211230ArtigoaecnicoVt107.pdf](https://www.inforcna.pt/Media/Files/20211230_20211230ArtigoaecnicoVt107.pdf)

- Queiroz, D., Valente, D., Pinto, F., & Borém, A. (2022). *Agricultura Digital* (2ª ed.) [Digital Agriculture]. Oficina de Textos. Disponível em [https://books.google.pt/books?hl=pt-PT&lr=&id=9ehvEAAAQBAJ&oi=fnd&pg=PT4&dq=machine+learning+na+agricultura&ots=syKsgHHi3A&sig=VydUKY8qfSmHD2R-UvH3LYOvOUc&redir\\_esc=y#v=onepage&q=machine%20learning%20na%20agricultura&f=false](https://books.google.pt/books?hl=pt-PT&lr=&id=9ehvEAAAQBAJ&oi=fnd&pg=PT4&dq=machine+learning+na+agricultura&ots=syKsgHHi3A&sig=VydUKY8qfSmHD2R-UvH3LYOvOUc&redir_esc=y#v=onepage&q=machine%20learning%20na%20agricultura&f=false)
- Rabello, L., Bernard, A., & Inamasu, R. (2014). *Condutividade elétrica aparente do solo*. Portal Embrapa. Consultado a 12 de agosto de 2023. Disponível em <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1003692/1/BERNARDI48.pdf>
- Roma, E., Laudicina, V., Vallone, M., & Catania, P. (2023). *Application of Precision Agriculture for the Sustainable Management of Fertilization in Olive Groves*. MDPI. Consultado a 10 de abril de 2023. Disponível em <https://www.mdpi.com/2073-4395/13/2/324>
- Rosa, M., & Dall'Agnol, G. (2021). *Sensor sem fio agrícola de baixo custo para aplicações em estufas e hortas residenciais*. DSPACE. Consultado a 10 de abril de 2023. Disponível em <https://acervodigital.ufpr.br/bitstream/handle/1884/76931/R%20-%20E%20-%20MATHEUS%20KUNHAVALIK%20DA%20ROSA.pdf?sequence=1&isAllowed=y>
- Rufat, J., Villar, J., Pascual, M., Falguera, V., & Arbonés, A. (2014). *Productive and vegetative response to different irrigation and fertilization strategies of an Arbequina olive orchard grown under super-intensive conditions*. ScienceDirect. Consultado a 10 de abril de 2023. Disponível em <https://www.sciencedirect.com/science/article/abs/pii/S0378377414001644>
- Santos, F. (s.d.). *Sensores remotos por RADAR, Sensores Remotos por LiDAR, Sensores de Proximidade*. UTAD. Consultado a 4 de janeiro de 2023. Disponível em [https://fsantos.utad.pt/pub-fas/Apt\\_pdf/APE/04AP\\_Sensores06.pdf](https://fsantos.utad.pt/pub-fas/Apt_pdf/APE/04AP_Sensores06.pdf)
- Sanz-Cortés, F., Martínez-Calvo, J., Badenes, M. L., Bleiholder, H., Hack, H., Llacer, G., & Meier, U. (2002). *Phenologic growth stages of olive trees*. ResearchGate. Consultado a 20 de dezembro de 2022. Disponível em [https://www.researchgate.net/publication/229728173\\_Phenological\\_growth\\_stages\\_of\\_olives\\_trees\\_Olea\\_Europaea](https://www.researchgate.net/publication/229728173_Phenological_growth_stages_of_olives_trees_Olea_Europaea)
- Scikit learn. (2023). *scikit-learn: Machine Learning in Python*. scikit learn. Consultado a 12 de agosto de 2023. Disponível em <https://scikit-learn.org/stable/index.html>
- Shiratsichi, L., Brandão, Z., Vicente, L., Victoria, D., Ducati, J., Oliveira, R., & Vilela, M. (2014). *Agricultura de Precisão: Resultados de um Novo Olhar*. Embrapa. Consultado a 10 de abril de 2023. Disponível em <https://www.alice.cnptia.embrapa.br/bitstream/doc/1003275/1/2014cpamtlucianoshiratsushisensoriamentoremotoconceitosbasicosaplicacoesagriculturaprecisao.pdf>
- SISCOG. (2023). *AI4RealAg*. SISCOG. Consultado a 4 de janeiro de 2023. Disponível em <https://www.siscog.pt/pt/lp/agricultura-inteligente/>
- Tatum, J. (2019). *A Very Brief History of Spectroscopy*. LibreTexts Physics. Consultado a 10 de abril de 2023. Disponível em [https://phys.libretexts.org/Bookshelves/Astronomy\\_\\_Cosmology/Stellar\\_Atmospheres\\_\(Tatum\)/07%3A\\_Atomic\\_Spectroscopy/7.02%3A\\_A\\_Very\\_Brief\\_History\\_of\\_Spectroscopy](https://phys.libretexts.org/Bookshelves/Astronomy__Cosmology/Stellar_Atmospheres_(Tatum)/07%3A_Atomic_Spectroscopy/7.02%3A_A_Very_Brief_History_of_Spectroscopy)

- TerraSIG. (2022). *Multispectral (R, G, RE, NIR)*. Terra Drone. Consultado a 20 de dezembro de 2022. Disponível em <https://www.terradrone.pt/en/multispectral-r-g-re-nir/>
- Trimble Agriculture. (2023). *GreenSeeker handheld crop sensor*. Trimble Agriculture. Consultado a 12 de agosto de 2023. Disponível em <https://agriculture.trimble.com/en/products/hardware/flow-application-control/greenseeker-handheld-crop-sensor>
- Veloso, A., Sempiterno, C., Calouro, F., Rebelo, F., Pedra, F., Castro, I., Gonçalves, M., Marcelo, M., Pereira, P., Fareleira, P., Jordão, P., Mano, R., Fernandes, R. (2022). *Manual de fertilização das culturas*. INIAV. Consultado a 12 de agosto de 2023. Disponível em [https://www.inia.pt/images/publicacoes/livros-manuais/Manual\\_Fertilizacao\\_das\\_culturas.pdf](https://www.inia.pt/images/publicacoes/livros-manuais/Manual_Fertilizacao_das_culturas.pdf)
- Vivas, P. (2018). *Comportamento fenológico e produtivo de cinco variedades de oliveira portuguesas na região de Elvas*. [Dissertação de mestrado, Escola Superior Agrária de Elvas]. Repositório Comum. Disponível em [https://comum.rcaap.pt/bitstream/10400.26/25713/1/PauloVivas\\_%20Tese%20de%20Mestrado\\_%20Vers%c3%a3o%20Final\\_Revista\\_Fechada.pdf](https://comum.rcaap.pt/bitstream/10400.26/25713/1/PauloVivas_%20Tese%20de%20Mestrado_%20Vers%c3%a3o%20Final_Revista_Fechada.pdf)

# Anexos

## Anexo I – Trabalhos Publicados em Congressos

No âmbito do projeto AI4RealAg e do trabalho desenvolvido nesta dissertação foram apresentados os seguintes trabalhos:

- Análise de Refletância em Folhas de Oliveira – Apresentação oral – Dia da Olivicultura (INIAV-Elvas) – 11 de outubro de 2023;
- Utilização de Sensores de Refletância para Avaliação de Incidência de *Fusicladium oleagineum* – Poster – 12º Encontro Nacional de Proteção Integrada (ESAE) – 30 e 31 de outubro de 2023;
- Tecnologias sensoriais para avaliação de refletância das folhas e coberto vegetal no apoio à decisão à fertilização em olival – Poster – 6º Simpósio "Produção e Transformação de Alimentos em Ambiente Sustentável" (ESAE) – 25 de maio de 2023;
- Validação de um Fluorómetro Portátil e Deteção Remota na Gestão de um Olival em Sebe – Poster – CNESA (ESAS) – 3 e 4 de novembro de 2022.

## Anexo II – Estados fenológicos segundo a escala BBCH

### Phenological stages of the olive tree (BBCH scale) Sanz-Cortés et al. 2002

#### Principal growth stage 0: Bud development

- 00 Foliar buds at the apex of shoots grown the previous crop-year are completely closed, sharp-pointed, stemless and ochre-coloured (Fig. 2a).
- 01 Foliar buds start to swell and open, showing the new foliar primordia.
- 03 Foliar buds lengthen and separate from the base.
- 07 External small leaves open, not completely separated, remaining joined at apices (Fig. 2a).
- 09 External small leaves opening further with their tips inter-crossing (Fig. 2a).

#### Principal growth stage 1: Leaf development

- 11 First leaves completely separated. Greenish-grey colour (Fig. 2a)
- 15 The leaves are longer without reaching their final length. First leaves turn greenish on the upperside.
- 19 Leaves achieve the typical cultivar length and shape.

#### Principal growth stage 3: Shoot development

- 31 Shoots reach 10% of final length.
- 33 Shoots reach 30% of final length (Fig. 2a).
- 37 Shoots reach 70% of final length.

#### Principal growth stage 5: Inflorescence emergence

- 50 Inflorescence buds in leaf axils are completely closed. They are sharp-pointed, stemless and ochre-coloured.

- 51 Inflorescence buds start to swell.
- 53 Inflorescence buds open. Flower cluster development starts (Fig 2b).
- 54 Flower cluster growing.
- 55 Flower cluster totally expanded. Floral buds start to open (Fig 2b).
- 57 Corolla green-coloured, longer than calyx (Fig 2b).
- 59 Corolla changes colour from green to white.

#### Principal growth stage 6: Flowering

- 60 First flowers open (Fig 2b).
- 61 Beginning of flowering: 10% of flowers open.
- 65 Full flowering: at least 50% of flowers open (Fig 2b).
- 67 First petals falling.
- 68 Majority of petals fallen or faded (Fig 2b).
- 69 End of flowering, fruit set, non-fertilised ovaries fallen.

#### Principal growth stage 7: Fruit development

- 71 Fruit about 10% of final size (Fig 2c).
- 75 Fruit about 50% of final size. Stone becomes lignified (shows cutting resistance).
- 79 Fruit about 90% of final size. Fruit suitable for picking green (Fig 2c).

#### Principal growth stage 8: Maturity of fruit

- 80 Fruit a deep green colour becoming light green or yellowish.
- 81 Beginning of fruit colouring (Fig 2c).
- 85 Increasing specific fruit colouring.
- 89 Harvest maturity: fruits achieve the typical cultivar colour, remain turgid and are suitable for oil extraction (Fig. 2c).

#### Principal growth stage 9: Senescence

- 92 Overripe: fruits lose turgidity and start to fall (Fig 2c).




Fig. 2a. Some bud, leaf and shoot development stages according to the BBCH scale.




Fig. 2b. Some inflorescence emergence and flowering stages according to the BBCH scale.




Fig. 2c. Some fruit development, maturity and senescence stages according to the BCH scale.

Anexo III - Resultados das análises químicas de CI - T2 e T0 das três variedades em estudo

Amostra	N	P	K
VI-T2-CI-B11	1.95	0.20	1.01
VI-T2-CI-B12	1.78	0.20	0.90
VI-T2-CI-B13	1.81	0.24	0.90
VI-T2-CI-B14	1.54	0.18	0.87
VI-T2-CI-B15	1.88	0.24	0.94
VI-T2-CI-B16	1.68	0.22	0.88
VI-T2-CI-B17	1.29	0.28	0.85
VI-T2-CI-B18	1.53	0.25	0.85
VI-T2-CI-B19	1.56	0.24	0.81
VI-T2-CI-B20	1.45	0.29	0.91
V2-T2-C1-B11	2.11	0.28	1.29
V2-T2-C1-B12	1.78	0.29	1.35
V2-T2-C1-B13	1.74	0.32	1.15
V2-T2-C1-B14	1.81	0.30	1.23
V2-T2-C1-B15	1.98	0.29	1.10
V2-T2-C1-B16	1.96	0.28	1.13
V2-T2-C1-B17	2.02	0.24	1.07
V2-T2-C1-B18	1.71	0.29	1.01
V2-T2-C1-B19	1.79	0.28	1.09
V2-T2-C1-B20	1.78	0.31	1.04
V3-T2-C1-B11	1.58	0.18	1.39
V3-T2-C1-B12	1.26	0.13	1.30
V3-T2-C1-B13	1.26	0.15	1.22
V3-T2-C1-B14	1.19	0.14	1.15
V3-T2-C1-B15	1.36	0.15	1.29
V3-T2-C1-B16	1.32	0.15	1.31
V3-T2-C1-B17	1.33	0.12	1.19
V3-T2-C1-B18	1.33	0.16	1.23
V3-T2-C1-B19	1.39	0.15	1.29
V3-T2-C1-B20	1.33	0.18	1.46

Amostra	N	P	K
VI-T0-CI-B11	1.61	0.22	0.83
VI-T0-CI-B12	1.43	0.28	0.85
VI-T0-CI-B13	1.56	0.23	0.91
VI-T0-CI-B14	1.70	0.23	0.91
VI-T0-CI-B15	1.56	0.21	0.97
VI-T0-CI-B16	1.78	0.24	0.79
VI-T0-CI-B17	1.29	0.29	0.87
VI-T0-CI-B18	1.33	0.34	0.91
VI-T0-CI-B19	1.22	0.32	0.79
VI-T0-CI-B20	1.36	0.30	0.83
V2-T0-C1-B11	1.46	0.36	1.21
V2-T0-C1-B12	1.57	0.31	0.96
V2-T0-C1-B13	1.53	0.30	1.00
V2-T0-C1-B14	1.46	0.35	1.06
V2-T0-C1-B15	1.58	0.37	1.02
V2-T0-C1-B16	1.61	0.32	1.00
V2-T0-C1-B17	1.54	0.34	1.06
V2-T0-C1-B18	1.49	0.34	1.06
V2-T0-C1-B19	1.50	0.30	0.98
V2-T0-C1-B20	1.95	0.25	1.01
V3-T0-C1-B11	1.26	0.18	1.44
V3-T0-C1-B12	1.12	0.17	1.16
V3-T0-C1-B13	1.22	0.17	1.30
V3-T0-C1-B14	1.33	0.15	1.02
V3-T0-C1-B15	1.22	0.17	1.06
V3-T0-C1-B16	1.40	0.18	1.31
V3-T0-C1-B17	1.29	0.18	1.48
V3-T0-C1-B18	1.57	0.18	1.33
V3-T0-C1-B19	1.71	0.13	1.10
V3-T0-C1-B20	1.67	0.14	1.28

Nota: Teor de nutrientes, expresso em %, na matéria seca.

Anexo IV - Resultados das análises químicas de C2 - T1 e T0 das três variedades em estudo

Amostra	N	P	K
VI-T1-C2-B11	1.50	0.15	1.02
VI-T1-C2-B12	1.53	0.15	0.83
VI-T1-C2-B13	1.64	0.21	1.36
VI-T1-C2-B14	1.42	0.21	1.05
VI-T1-C2-B15	1.32	0.19	0.87
VI-T1-C2-B16	1.25	0.19	0.86
VI-T1-C2-B17	1.50	0.22	0.84
VI-T1-C2-B18	1.29	0.25	1.00
VI-T1-C2-B19	1.25	0.23	0.97
VI-T1-C2-B20	1.37	0.22	1.23
V2-T1-C2-B11	1.67	0.21	1.17
V2-T1-C2-B12	1.26	0.30	1.25
V2-T1-C2-B13	1.29	0.34	1.36
V2-T1-C2-B14	1.22	0.33	1.16
V2-T1-C2-B15	1.25	0.38	1.27
V2-T1-C2-B16	1.22	0.33	1.27
V2-T1-C2-B17	1.32	0.31	1.23
V2-T1-C2-B18	1.43	0.30	1.28
V2-T1-C2-B19	1.43	0.41	1.40
V2-T1-C2-B20	1.46	0.32	1.26
V3-T1-C2-B11	1.77	0.16	1.06
V3-T1-C2-B12	1.43	0.19	1.08
V3-T1-C2-B13	1.43	0.21	1.19
V3-T1-C2-B14	1.39	0.20	1.29
V3-T1-C2-B15	1.52	0.19	1.34
V3-T1-C2-B16	1.42	0.18	1.29
V3-T1-C2-B17	1.32	0.19	1.22
V3-T1-C2-B18	1.36	0.19	1.40
V3-T1-C2-B19	1.37	0.20	1.38
V3-T1-C2-B20	1.36	0.24	1.39

Amostra	N	P	K
VI-T0-C2-B11	1.30	0.32	1.11
VI-T0-C2-B12	1.47	0.24	1.01
VI-T0-C2-B13	1.29	0.22	0.99
VI-T0-C2-B14	1.60	0.22	1.04
VI-T0-C2-B15	1.32	0.23	1.08
VI-T0-C2-B16	1.22	0.24	1.03
VI-T0-C2-B17	1.33	0.21	1.05
VI-T0-C2-B18	1.32	0.26	0.95
VI-T0-C2-B19	1.29	0.25	0.94
VI-T0-C2-B20	1.49	0.24	1.08
V2-T0-C2-B11	1.32	0.35	1.27
V2-T0-C2-B12	1.43	0.35	1.30
V2-T0-C2-B13	1.26	0.37	1.29
V2-T0-C2-B14	1.32	0.34	1.28
V2-T0-C2-B15	1.32	0.39	1.41
V2-T0-C2-B16	1.33	0.36	1.31
V2-T0-C2-B17	1.39	0.36	1.40
V2-T0-C2-B18	1.50	0.35	1.28
V2-T0-C2-B19	1.39	0.43	1.45
V2-T0-C2-B20	1.67	0.32	1.46
V3-T0-C2-B11	1.40	0.24	1.33
V3-T0-C2-B12	1.36	0.21	1.41
V3-T0-C2-B13	1.38	0.22	1.41
V3-T0-C2-B14	1.40	0.21	1.29
V3-T0-C2-B15	1.40	0.22	1.25
V3-T0-C2-B16	1.39	0.20	1.26
V3-T0-C2-B17	1.39	0.18	1.20
V3-T0-C2-B18	1.32	0.21	1.29
V3-T0-C2-B19	1.44	0.21	1.22
V3-T0-C2-B20	1.39	0.20	1.20

Nota: Teor de nutrientes, expresso em %, na matéria seca.