



Resposta de Sensores Remotos a Doses Variáveis de Fertilizante Azotado em Culturas Forrageiras de Inverno sob Clima Mediterrânico

Dissertação

Curso de Mestrado em Agricultura Sustentável

CAROLINE BRUNELLI

Orientadores: Luís Alcino da Conceição e Raphael Magalhães Gomes Moreira

Elvas, 2025

CAROLINE BRUNELLI

Resposta de sensores remotos a doses variáveis de fertilizante azotado em culturas forrageiras de inverno sob clima mediterrânico

Dissertação apresentada para obtenção do grau de mestre em Agricultura
Sustentável conferido pelo Instituto Politécnico de Portalegre.

Orientador: Prof. Doutor Rafael Magalhães Moreira (Inst. Fed. Espírito
Santo - Brasil);

Arguente principal: Prof. Doutor João Manuel Serrano (Univ. Évora);

Arguente: Prof. Doutor Samuel de Assis Silva (Univ. Federal do Espírito
Santo - Brasil);

Arguente: Profa. Doutora Noémia Farinha (ESBE).

Presidente do Júri: Prof. Doutor José Manuel Rato Nunes (Presidente do
CTC) ou substituto (por delegação de competências);

Classificação: 15 valores

Escola Superior de Biociências de Elvas

2025

Agradecimentos

A jornada deste mestrado foi marcada por aprendizados, desafios e conquistas, e nada disso seria possível sem o apoio e a presença de pessoas especiais ao longo do caminho. Agradeço primeiramente a Deus, por me sustentar em todos os momentos e iluminar meus passos nos dias mais desafiadores. Aos meus orientadores, Luís Alcino da Conceição, Raphael Magalhães Moreira e Luís Silva, minha profunda gratidão pela orientação generosa, pela troca de saberes e por cada conselho que contribuiu para o amadurecimento deste trabalho. Obrigada por acreditarem em mim e pela paciência e dedicação ao longo de todo o processo.

Ao Instituto Federal do Espírito Santo (Ifes), minha instituição de origem, agradeço pela base sólida de formação, pelas oportunidades oferecidas e pelo incentivo constante à pesquisa e à inovação.

Ao Instituto Politécnico de Portalegre (IPP), minha instituição de acolhimento em Portugal, sou grata pela experiência internacional transformadora, pela receptividade e pela qualidade da formação acadêmica que tanto contribuíram para minha trajetória.

Aos professores e colegas do Mestrado em Agricultura Sustentável, agradeço pela convivência, pelas trocas de conhecimento e pelo apoio mútuo ao longo dessa caminhada. Aos amigos e colegas de mestrado que embarcaram nessa jornada junto comigo, meu carinho e gratidão por cada conversa, parceria e incentivo nos momentos difíceis e nos mais felizes.

À minha mãe, Sueli de Oliveira Micael, minha eterna gratidão por todo o amor, apoio incondicional e força que me sustentaram até aqui. Nada disso seria possível sem você. Por fim, a todos que, direta ou indiretamente, contribuíram para a realização deste trabalho, deixo aqui meu mais profundo agradecimento.

Resumo

A intensificação sustentável da produção forrageira em regiões de clima mediterrânico exige soluções tecnológicas que optimizem a utilização de factores de produção agrícola. O presente estudo teve como objetivo avaliar o desempenho de sensores ópticos de proximidade na recomendação e monitorização da fertilização azotada em taxa variável (VRA) em forrageiras de inverno, cultivadas sob clima mediterrânico no Alentejo, Portugal. Foram utilizados o sensor *Greenseeker*® (GS), o sensor multiespectral (MSI) embarcado em drone e o sensor *Augmenta*, baseados no índice de diferença normalizada (NDVI) e em inteligência artificial (IA), para a prescrição em tempo real da adubação azotada.

Os sensores foram avaliados quanto à correlação com parâmetros agronómicos como massa verde (MV), matéria seca (MS), teor de azoto (%N), proteína bruta (%PB), produtividade de proteína bruta (PByield) e eficiência de utilização do azoto (NUp). O sensor *Augmenta* destacou-se ao promover uma redução de 15,23% na dose total de fertilizante azotado aplicado em comparação com a dose fixa de 150 kg ha⁻¹, resultando numa economia de 34,35 kg de fertilizante numa área de 1,5 ha, sem comprometer a produtividade da cultura.

Além disso, o NDVI_Augm apresentou correlações moderadas com MV ($R^2 = 0,52$), PB ($R^2 = 0,38$), Nyield ($R^2 = 0,33$) e NUp ($R^2 = 0,33$), confirmando a sua eficiência na prescrição de adubação com base no vigor vegetativo. O MSI-II apresentou correlações ainda mais expressivas com parâmetros como PB ($R^2 = 0,58$), Nyield ($R^2 = 0,53$) e NUp ($R^2 = 0,53$), indicando a sua sensibilidade às alterações fisiológicas induzidas pela adubação. O sensor GS®, embora de leitura pontual, também se revelou eficaz, com correlação significativa com NUp ($R^2 = 0,55$) e PByield ($R^2 = 0,53$). Conclui-se que a integração dos sensores permite tanto a prescrição precisa de factores de produção como a monitorização eficiente da resposta fisiológica das plantas, promovendo economia, sustentabilidade e maior eficiência agronómica. A adopção desta abordagem representa uma alternativa viável para a intensificação sustentável da produção de forragens em regiões mediterrânicas.

Palavras-chave: Agricultura de precisão; Eficiência de utilização do azoto; NDVI; Sensores ópticos; Taxa variável.

Abstract

The sustainable intensification of forage production in Mediterranean climates requires technological solutions that optimize the use of agricultural inputs. This study aimed to evaluate the performance of proximal optical sensors in recommending and monitoring variable rate nitrogen fertilization (VRA) in winter forage crops cultivated under Mediterranean conditions in Alentejo, Portugal. The *GreenSeeker*® (GS), a multispectral MSI drone sensor, and the Augmenta sensor based on NDVI and artificial intelligence, were used to generate real-time nitrogen application prescriptions.

The sensors were assessed for their correlation with agronomic parameters such as fresh biomass (MV), dry matter (MS), nitrogen content (%N), crude protein (%PB), crude protein yield (PByield) and nitrogen use efficiency (NUp). The Augmenta sensor stood out by promoting a 15.23% reduction in the total nitrogen fertilizer applied compared to a fixed dose of 150 kg ha⁻¹, saving 34.35 kg of fertilizer over 1.5 ha without compromising crop productivity.

Additionally, NDVI_Augm showed moderate correlations with MV ($R^2 = 0.52$), PB ($R^2 = 0.38$), Nyield ($R^2 = 0.33$), and NUp ($R^2 = 0.33$), confirming its effectiveness in prescription based on vegetative vigor. MSI-II (NDVI-UAV after fertilization) showed even stronger correlations with PB ($R^2 = 0.58$), Nyield ($R^2 = 0.53$), and NUp ($R^2 = 0.53$), highlighting its sensitivity to physiological responses induced by nitrogen fertilization. Although *GreenSeeker* operates via point readings, it also proved effective, with significant correlation to NUp ($R^2 = 0.55$) and PByield ($R^2 = 0.53$).

It is concluded that integrating sensors enables both precise input prescription and efficient monitoring of plant physiological responses, fostering cost-effectiveness, sustainability, and improved agronomic efficiency. This approach offers a viable strategy for sustainable forage production intensification in Mediterranean regions.

Key words: Precision agriculture; Variable rate application; NDVI; Optical sensors; Nitrogen use efficiency.

Abreviaturas, Siglas e Acrónimos

AAI – Augmenta Agronomic Index
AdI – Área de Interesse
IV – Índices de Vegetação
AINS – Análise de Sensores
AIN – Azoto Inorgânico
AOC – Agricultura de Conservação
ANOVA – Análise de Variância
AP – Agricultura de Precisão
Aug_Index – Índice Augmenta
B(OH)₃ – Ácido Bórico
C₃ – Plantas com metabolismo fotossintético C₃
C₄ – Plantas com metabolismo fotossintético C₄
Ca – Cálcio
C° – Grau Celsius
CMOS – *Complementary Metal-Oxide-Semiconductor*
CO₂ – Dióxido de Carbono
CPU – Unidade Central de Processamento
CuSO₄ · 5H₂O – Sulfato de Cobre Penta-hidratado
Csa – Clima Mediterrânico (classificação de Köppen)
CV – Coeficiente de Variação
DNA – Ácido Desoxirribonucleico
FA – Fertilização Azotada
FAO – *Food and Agriculture Organization of the United Nations*
GEE – Gases com Efeito de Estufa
GNSS – Sistema Global de Navegação por Satélite
GS® – *GreenSeeker®*
GSK – Índice Gerado pelo Sensor GreenSeeker
Ha – Hectare
HCl – Ácido Clorídrico
Hz – Hertz

IA – Inteligência Artificial
INE – Instituto Nacional de Estatística
INIAV – Instituto Nacional de Investigação Agrária e Veterinária
IPMA – Instituto Português do Mar e da Atmosfera
ISO – Comunicação ISOBUS
IVs – Índices de Vegetação
K – Potássio
Kg – Quilograma
Mg – Magnésio
MP – Megapixels
MS – Matéria Seca
MSI – *Multispectral Sensor Imaging*
MSI-I – Índices Obtidos pelo Drone Multiespectral no Momento I
MSI-II – Índices Obtidos pelo Drone Multiespectral no Momento II
MV – Matéria Verde
N – Azoto
N₂ – Azoto Molecular
N₂O – Óxido Nitroso
Na₂SO₄ · 7H₂O – Sulfato de Sódio Hepta-hidratado
NaOH – Hidróxido de Sódio a 30%
Nc – Normal Climatológica
NDRE – *Normalized Difference Red Edge Index*
Ndt – Nitrogênio diretamente transportado
NDVI – *Normalized Difference Vegetation Index*
NH₃ – Amónia Gasosa
NNI – *Nitrogen Nutrition Index*
%N – Concentração de Azoto na Planta
Nm – Nanômetro
NUE – Eficiência do Uso do Azoto
NUp – Eficiência do Uso do Azoto pela Planta
ODS – Objetivos de Desenvolvimento Sustentável
OMM – Organização Meteorológica Mundial
P – Fósforo

PB – Proteína Bruta (%)

PByield – Produção de Proteína Bruta por Hectare

PEP – Fosfoenolpiruvato Carboxilase

QGIS – Sistema de Informação Geográfica QGIS

RNA – Ácido Ribonucleico

RuBisCo – Ribulose-1,5-bisfosfato carboxilase/oxigenasse

R^2 – Coeficiente de Determinação

Se – Selênio

SIG – Sistema de Informação Geográfica

SPAD – *Soil Plant Analysis Development*

SR – Sensoriamento Remoto

Tm – Temperatura Média

Ton – Tonelada

UE – União Europeia

USD – Dólar dos Estados Unidos

VANTs – Veículos Aéreos Não Tripulados

VRA – *Variable Rate Application*

ZM – Zonas de Maneio

Índice Geral

I. Introdução e Objetivos	I
I.1. Introdução	I
I.2. Objetivos	2
2. Revisão Bibliográfica	4
2.1. Espectrometria na Avaliação de Parâmetros Fisiológicos	4
2.2. Índices de Vegetação	7
2.3. Sensores Remotos de Monitoramento Foliar	10
2.4. Fertilização Azotada em Dose Variável	20
2.5. Culturas Forrageiras de Inverno em Clima Mediterrânico	25
2.6. Interação do N e a Fisiologia Vegetal	27
2.7. Fatores que Afetam a Resposta da Forragem ao N	30
3. Material e Métodos	32
3.1 Características Edafoclimáticas da Área Experimental	32
3.2. Instalação dos ensaios	34
3.3. Adubação de cobertura a taxa variável	35
3.4. Sensores Ópticos de Monitorização	40
3.4.1. Drone MSI Phantom 4 Pro	40
3.4.2. Sensor Ótico GreenSeeker	41
3.5. Coleta inteligente de amostras em campo	43
3.5.1. Criação da malha de amostragem	43
3.5.2. Material de recolha das amostras em campo	44
3.5.3. Recolha de amostras digitais	45
3.5.3. Recolha de amostras vegetais	45
3.6. Análises laboratoriais	47
3.6.1. Humidade Residual	47
3.6.2. Determinação de Nitrogênio e Proteína Bruta	48
3.6.3 Cálculo e Expressão dos Resultados	51
3.7. Tratamento Estatístico	52

3.7.1. Análise de Agrupamento	52
4. Resultados	53
4.1. Estatística descritiva e inferencial	53
4.2. Teste de normalidade e testes de significância	58
4.3. Matriz de correlação	60
4.4. Mapas criados a partir dos pontos de amostragem	62
4.5. Mapa de zonas homogêneas de taxa prescritas	66
5. Discussão	67
5.1. Resposta dos sensores	67
5.2. Correlação entre os sensores e a produtividade	69
5.3. Implicações práticas do uso de sensores em forragens de outono/inverno em clima mediterrânico	70
6. Conclusões	74

Índice de Quadros

Quadro 1 - Principais reações fotoquímicas das plantas.....	4
Quadro 2 - Técnicas de reflectância visível e infravermelha próxima para diagnóstico do estado fisiológico das plantas	7
Quadro 3 - Normal Climatológica incluindo os valores de Tm e P em Elvas.....	28
Quadro 4 - Parâmetros de configuração para aplicação do fertilizante em VRA.....	34
Quadro 5 - Resultados da análise da estatística descritiva e inferencial.....	48
Quadro 6 - Teste de normalidade e teste de significância.....	53
Quadro 7 - Doses de fertilizante aplicada na parcela.....	60

Índice de Figuras

Figura 1 - imagem representativa da interação da luz com uma folha e da fluorescência da clorofila em diferentes comprimentos de onda.....	4
Figura 2 - Curvas de resposta espectral característica da vegetação.	9
Figura 3 - Comprimentos de onda electromagnética quando atingem o alvo convertidos em energia transmitida, absorvida ou reflectida.	10
Figura 4 - Esquema a ilustrar a radiação entre um sensor activo (a) e um sensor passivo (b). .	12
Figura 5 - Constituintes de um sistema de sensor	13
Figura 6 - Classificação dos sistemas dos sensores de acordo com a categoria.....	13
Figura 7 - Princípio sensor-actuador assente no princípio de sensor em linha.....	15
Figura 8 - Processamento de imagens em tempo real e inteligência artificial: o sistema ajusta automaticamente a quantidade de insumos aplicada em cada centímetro do campo.	19
Figura 9 - Identificação e delimitação da área experimental.	27
Figura 10 - Conjunto trator-semeador.	29
Figura 11 - Augmenta Sensor instalado na parte superior frontal da máquina.....	30
Figura 12 - Trator new holland T5.140 dynamic command™.	31
Figura 13 - Augmenta Sensor (esquerda), Augmenta Sensor e os cabos que ligam ao isobus trl4396 e monitor (direita).	32
Figura 14 - Plataforma com as configurações da fertilização em taxa variável em tempo real. .	34
Figura 15 - Drone dji phantom 4 pro v2.0 (à esquerda). Sistema utilizado para manipulação do drone em campo, tablet e controle (à direita).....	36
Figura 16 - Sensor óptico GS® , modelo de sensor portátil.....	37
Figura 17 - Localização dos pontos de amostragem, posicionados de acordo com as taxas prescritas pelo sensor Augmenta.	40
Figura 18 - (A) gabarito metálico quadrado (B) sensor GS®; (C) tesoura elétrica; (D) saco plástico; (E) balança; (F) saco plástico.	41
Figura 19 - coleta dos valores de NDVI com o sensor óptico GS®.....	41
Figura 20 - corte do material vegetal com a tesoura elétrica e pesagem da matéria verde em condições de campo.....	42
Figura 21 - Material vegetativo triturado passando pelo processo de crivagem.....	42
Figura 22 - Cápsulas de porcelana no dessecador para o resfriamento.	43
Figura 23 - Amostras de massa vegetal em estufa; Amostras no dessecador para resfriamento; Pesagem da amostra.	43
Figura 24- Massa vegetal pesada em 0,5g nos tubos de digestão;.....	44
Figura 25 - Adição da mistura catalisadora; Destilação; Titulação.....	45
Figura 26 - Metodologia estatística utilizada.	47
Figura 27 - Cluster Dendrogram.....	50

Figura 28- Análise exploratória por meio de boxplots.	52
Figura 29 - Histogramas das variáveis analisadas.	54
Figura 30 - Matriz de Correlação.	55
Figura 31 - (a) Distribuição espacial da MV da cultura, medida em quilogramas por hectare (kg ha^{-1}). (b) Distribuição espacial do teor de PB da forrageira.....	57
Figura 32 - (a) Distribuição espacial da PByield. (b) Distribuição espacial da NUp.	58
Figura 33 - Distribuição espacial dos valores de NDVI GSK.....	58
Figura 34 - Mapa de zonas homogêneas de taxas de fertilização prescritas pelo sensor Augmenta.	59

I. Introdução e Objetivos

I.1. Introdução

As pastagens constituem um dos biomas de maior abrangência global, estando presentes em 26 % da superfície terrestre e integrando 70 % da área agrícola cultivada. Contribuem significativamente para a segurança alimentar mundial e desempenham um papel relevante na preservação de ecossistemas essenciais, minimizam a degradação do solo, auxiliam na retenção de água e no sequestro de carbono. Contudo, a má gestão dos factores de produção nas pastagens e o sobrepastoreio podem acarretar diversos prejuízos ambientais e económicos (FAO, s.d.). O azoto (N) é um dos três macronutrientes essenciais para o desenvolvimento vegetativo e para a elevada produtividade das culturas, sendo por isso absorvido pelas plantas em grandes quantidades (Alfonso Loret de Mora, 2014; Santos, 2002). A aplicação anual de fertilizantes inorgânicos na União Europeia (UE) totaliza aproximadamente $9,87 \times 10^6$ ton por ano (Eurostat, 2025). Estima-se que pelo menos 50 % desse volume não seja absorvido e assimilado pelas culturas, sendo grande parte perdida no ecossistema através da volatilização, lixiviação e percolação (Liu et al., 2012). Estas perdas reflectem-se em problemas ambientais pela libertação de gases com efeito de estufa (GEE), poluição dos recursos hídricos, acidificação e salinização do solo e, consequentemente, perda de biodiversidade.

Geralmente, os agricultores tendem a fertilizar em excesso devido à falta de informação sobre a variabilidade das condições climáticas e do solo; esta prática resultou, ao longo do tempo, no aumento das concentrações de óxido nitroso (N_2O) na atmosfera, um GEE 298 vezes mais prejudicial do que o dióxido de carbono (CO_2) (Hill-Pearce et al., 2021).

A agricultura de precisão (AP) tem-se desenvolvido cada vez mais nas últimas décadas, especialmente no âmbito da pecuária de precisão. Através do crescente recurso a tecnologias que possibilitam o acesso a informações sobre a variabilidade espacial e temporal das condições do campo, é possível gerir os recursos agrícolas de forma mais dinâmica e eficiente. As práticas propostas pela AP permitem que os agricultores tomem decisões mais informadas, com o intuito de aumentar a produção, reduzir os factores

de produção utilizados e minimizar o impacto ambiental; estas estratégias dependem da precisão da informação.

Deste modo, no âmbito do projecto GEEBovMit, a tese “Resposta de Sensores Remotos a Doses Variáveis de Fertilizante Azotado em Culturas Forrageiras de Inverno sob Clima Mediterrânico” visa integrar tecnologias de AP, utilizando detecção remota por sensores Remotos para otimizar a gestão da fertilização em culturas forrageiras durante o inverno. Estas culturas, essenciais para a alimentação animal, são muitas vezes limitadas por práticas convencionais de fertilização que não consideram a variabilidade espacial e temporal do vigor das plantas e da produção de biomassa, bem como o seu fraccionamento de acordo com os regimes pluviométricos do período de inverno nas regiões mediterrânicas. Com o avanço das tecnologias de sensores, é possível identificar áreas com diferentes necessidades nutricionais, promovendo o uso eficiente de fertilizantes, a sustentabilidade ambiental e a maximização da produtividade.

1.2. Objetivos

Como objetivo geral, pretende-se desenvolver e validar um sistema integrado de apoio à decisão para otimizar a fertilização de culturas forrageiras de inverno, utilizando tecnologias de sensores remotos, visando a eficiência no uso de fertilizantes e a sustentabilidade da produção agrícola.

I. Avaliar a resposta espectral e o desempenho de sensores de proximidade em função de doses variáveis de fertilizante azotado em culturas forrageiras de inverno. Este objetivo foca-se em compreender de que forma os sensores remotos captam variações na biomassa e no teor de N das plantas em diferentes níveis de adubação azotada, considerando as especificidades das culturas forrageiras de inverno.

II. Correlacionar os dados obtidos pelos sensores de proximidade com indicadores agronómicos das culturas forrageiras em condições de clima mediterrânico. Este objetivo visa identificar a relação entre os dados obtidos pelos sensores (e.g., NDVI, índices de reflectância) e parâmetros agronómicos, como produtividade, eficiência de utilização do N e qualidade nutricional das culturas, tendo em conta as condições climáticas e edafoclimáticas características da região mediterrânica.

Sensores: Augmenta, GreenSeeker, MSI (drone).

2. Revisão Bibliográfica

2.1. Espectrometria na Avaliação de Parâmetros Fisiológicos

Os sensores ópticos são capazes de avaliar as propriedades químicas e morfológicas da superfície dos órgãos e das folhas através da reflectância, transmitância e absorção da luz em diferentes comprimentos de onda do espectro electromagnético. A partir dessas medições, os sensores calculam índices que se correlacionam com parâmetros fisiológicos importantes (Xue & Su, 2017).

Jacquemoud & Baret (1990) afirmam que as moléculas de clorofila são essenciais para o processo bioquímico em que as plantas convertem a energia luminosa em energia química. Assim, a concentração de pigmentos clorofiláticos reflecte a saúde e o rendimento da cultura, maior parte do azoto presente nas folhas encontra-se incorporada nas moléculas de clorofila, o que estabelece uma relação direta entre o teor de azoto foliar e a concentração de clorofila. Sendo que a concentração molecular de clorofila pode ser potencialmente estimada através das reflectâncias em 675 nm e 550 nm. Em baixas concentrações, a maior reflectância ocorre na faixa do vermelho visível (675 nm), enquanto em concentrações médias a elevadas a sensibilidade da reflectância é superior na faixa do verde (550 nm).

O comportamento espectral da vegetação verde saudável é determinado pelos pigmentos de clorofila, que se reflectem em toda a faixa da região do visível, onde as maiores absorções de luz ocorrem no intervalo do vermelho (600 a 700 nm) e do azul (400 a 500 nm). A Figura 1 ilustra as variações de cor nos diferentes comprimentos de onda, que indicam distintos níveis de actividade fotossintética relacionados com stress ou outros factores que afectam a saúde da planta. O pico do comprimento de onda situa-se na faixa do verde (500 a 600 nm). Já a radiação solar na faixa do infravermelho próximo (NIR) varia de acordo com a cultura – NIR (750 a 1300 nm) –, sendo reflectida entre 30 e 80% da radiação incidente (Shiratsuchi et al., 2014).




Figura I - Imagem representativa da interação da luz com uma folha e da fluorescência da clorofila em diferentes comprimentos de onda.

O processo de bioconversão da energia está directamente relacionado com a molécula de clorofila “a”, conforme exemplificado no Quadro I, estando esta presente em todas as células sintetizantes (Moreira, 2011).

Quadro I - Principais reacções fotoquímicas das plantas (Moreira, 2011).

Processo	Reacções	Fotorreceptor	Pico do espectro (nm)	Banda espectral (nm)
Síntese de clorofila	Redução da protoclorofila.	Protoclorofila	Azul: 445, Vermelho: 650	350 - 470, 570 - 670
Fotossíntese	Dissociação da água, redução do CO ₂ Acréscimo da fotossíntese.	Clorofilas e carotenóides	Azul: 435, Vermelho: 675 Vermelho: 650, Vermelho distante: 710	350 - 530, 600 – 700 630 - 690, 690 - 730
Reacções no Azul	Acréscimo da fotossíntese.	Carotenóides e flavinas	U.V.: 370 Azul: 445 - 475	350 - 500
Reacções no Vermelho	Germinação da semente, síntese da antocianina, crescimento vegetativo e da semente, crescimento heterotrófico	Fitocromo	Indução pelo Vermelho: 660 Reversão pelo vermelho distante: 710 e 730	570 - 700, 680 - 780

Uarrotta et al., (2018) afirmam que em folhas no estágio de senescência ou que apresentem algum tipo de stress (falta de água, deficiência nutricional ou presença de patogénicos), é possível observar o aumento da concentração de carotenóides em

comparação com as concentrações de clorofila. Os pigmentos carotenóides possuem núcleos de coloração amarela, laranja e vermelha e actuam na protecção das células em situações de stress; assim, quando ocorre o aumento destes pigmentos, as concentrações de clorofila tendem a diminuir em consequência da manipulação ou dos danos nas células vegetais.

O N é um elemento que integra a formação molecular da clorofila, pelo que, se uma planta estiver sob condições de stress nutricional, a concentração de clorofila diminuirá e, consequentemente, haverá menor absorção de energia luminosa. Naturalmente, a cultura manifesta sintomas visuais de deficiência na sua estrutura quando um nutriente essencial, como o N, se encontra pouco disponível na solução do solo. Quando tal ocorre, é possível realizar o diagnóstico através da observação dos sintomas; no entanto, nesta fase já existirão perdas de produtividade. Os métodos analíticos utilizados pelos sensores, através da espectroscopia, podem auxiliar no diagnóstico da deficiência oculta, isto é, quando a planta ainda não desenvolveu sintomas visuais. Quando os nutrientes são adicionados em excesso, não se obtêm ganhos adicionais, apenas perdas de fertilizante por lixiviação ou problemas de fitotoxicidade. Contudo, fornecer a quantidade exacta de insumo, sem originar problemas de excesso ou de escassez, pode ser um desafio (Moreira, 2011; van Maarschalkerweerd & Husted, 2015).

As técnicas rápidas de espectroscopia possibilitam a análise dos elementos essenciais e do estado nutricional da cultura em campo. Estes métodos são céleres e não exigem tratamento prévio das amostras, sendo por isso considerados não destrutivos, através da utilização de sensores aplicados manualmente sobre a cultura, acoplados a máquinas agrícolas ou a veículos aéreos não tripulados (VANTs) (Raven Industries, 2025; Trimble Inc., 2025). As medições destinadas à avaliação da quantidade de nutrientes não são efectuadas directamente; medem-se, sim, compostos biomarcadores ou processos fisiológicos relacionados com o estado nutricional da planta. Estes dados permitem fornecer informações para a determinação da situação nutricional da cultura. É, contudo, necessário considerar quais os factores bióticos e abióticos que podem estar a influenciar os resultados obtidos pelos sensores (van Maarschalkerweerd & Husted, 2015).

2.2. Índices de Vegetação (IVs)

A utilização das leituras obtidas através de sensores ópticos tem-se revelado eficiente para a prescrição do uso de fertilizantes e para o aumento da produção agrícola. Em diversos estudos, a principal preocupação tem sido o desenvolvimento de modelos capazes de converter os índices obtidos por sensores de reflectância em recomendações de fertilização azotada (FA). No entanto, muitos desses trabalhos desconsideram a importância de estabelecer protocolos consistentes para a realização das medições, tendo em conta os factores que podem interferir nos resultados, como a variação da luminosidade, a humidade do solo, o estágio fenológico das plantas e as características específicas de cada área. Essa limitação compromete a fiabilidade e a comparabilidade das leituras, reduzindo a precisão das aplicações de azoto baseadas em sensores. (Kapp-Junior et al., 2020).

Na agricultura, as propriedades da reflectância são analisadas através de combinações matemáticas de diferentes faixas espectrais. Os dados obtidos por essas avaliações estão fundamentados nas características biofísicas e fisiológicas da planta (Atzberger, 2013). Existe uma grande complexidade na interacção entre a radiação e os parâmetros fisiológicos, devido à influência de factores como a iluminação, as condições atmosféricas e os ângulos de visão. Para minimizar a interferência destes factores, recorrem-se aos IVs (Shiratsuchi et al., 2014). Para compreender a criação dos IVs, é necessário ter em conta a composição do solo, a vegetação, as rochas e a água, em relação à resposta espectral da vegetação (Formaggio & Sanches, 2017).

Diversos IVs foram desenvolvidos com finalidades distintas no âmbito da interpretação das necessidades das culturas em campo. Estes índices são aplicados na agricultura para a elucidação de processos fisiológicos especificamente relevantes para a produção agrícola (Brandão, 2009). Alguns destes índices têm como objectivo específico capturar e quantificar os processos fotoquímicos envolvidos na fotossíntese, como, por exemplo, a estimativa dos pigmentos de clorofila presentes no tecido vegetal e a eficiência da radiação na planta (Daughtry, 2000).

As faixas espectrais seleccionadas para a determinação da %N são escolhidas de acordo com a sua sensibilidade às alterações no estado da clorofila da planta, densidade e biomassa que acompanham a carência de N. Estes comprimentos de onda correspondem, em geral, a quatro bandas estreitas: em torno dos 675 nm (máximo de absorção no vermelho), 905 nm (pico de reflexão no NIR), 720 nm (região média da

borda vermelha) e 550 nm (máximo da reflectância no verde). Para aumentar a sensibilidade e a compreensão das características biofísicas, bem como minimizar a variabilidade provocada pela interferência de factores externos, os IVs combinam, em média, 2 a 3 comprimentos de onda (Padilla et al., 2018).

Entre os diferentes índices espectrais estudados por diversos investigadores, que demonstram o crescimento vegetativo, o Índice de Vegetação por Diferença Normalizada (NDVI) é considerado o mais sensível em relação ao pigmento de clorofila presente nas plantas, podendo, portanto, ser utilizado na estimativa das produções agrícolas. Ali et al. (2018); Sharma, Bu, Denton, & Franzen, (2015) demonstram que o sensor óptico GreenSeeker (GS®) calcula o NDVI através da seguinte fórmula:

$$NDVI = (F_{NIR} - F_{RED}) / (F_{NIR} + F_{RED})$$

A determinação do NDVI baseia-se na proporção de radiação infravermelha próxima (NIR) e vermelha (RED) reflectidas pela superfície analisada. O GS® apresenta uma elevada taxa de amostragem (cerca de 1000 Hz), calculando a média dos valores recolhidos e fornecendo o valor final de NDVI a uma taxa de 10 vezes por segundo.

A reflectância em diferentes bandas espectrais da luz emitida permite o cálculo de IVs. O quadro 2 apresenta alguns exemplos de índices de reflectância, a fórmula através da qual são obtidos e o parâmetro biológico medido.

Quadro 2 - Técnicas de reflectância visível e infravermelha próxima para diagnóstico do estado fisiológico das plantas (Adaptado de Peñuelas & Filella, 1998).

Índice	Acrônimo	Fórmula	Parâmetro Biológico Estimado
Índice de Vegetação por Diferença Normalizada	NDVI	$(NIR - Vermelho) / (NIR + Vermelho)$	Biomassa, vigor da planta, teor de clorofila, área foliar
Razão Simples de Infravermelho	RVI	$NIR / Vermelho$	Biomassa, vigor da planta
Índice de Vegetação Ajustado para o Solo	SAVI	$[(NIR - Vermelho) / (NIR + Vermelho + L)] * (1 + L)$ (onde L é um fator de ajuste do solo)	Biomassa em áreas com baixa cobertura vegetal
Índice de Clorofila Verde	Clgreen	$NIR / Verde$	Teor de clorofila

Índice de Razão Vermelho/Borda Vermelha	Red Edge Ratio	NIR / Red Edge	Teor de clorofila, estresse da planta
Índice de Reflectância Fotoquímica	PRI	$(R531 - R570) / (R531 + R570)$	Eficiência do uso da luz, atividade fotossintética
(Continuação)			
Índice de Senescência de Plantas	PSRI	$(\text{Vermelho} - \text{Verde}) / \text{Red Edge}$	Senescência, teor de carotenóides

A relação entre a fonte de luz e a distância na qual for realizada a medição pode interferir nos resultados do NDVI; durante a movimentação do sensor em campo, haverá alterações na altura ou nos ângulos de inclinação e torção em relação ao dossel da cultura. O sensor GS®, por exemplo, pode apresentar interferência nos valores de NDVI devido ao estágio de desenvolvimento vegetativo; a interferência pode ser maior a uma altura de 1,2 m do que a 0,8 m (alturas recomendadas pelo fabricante) (Stocker et al., 2019). Além disso, o NDVI não avalia a diluição fisiológica da concentração de %N na planta em função da biomassa, dificultando a estimativa da matéria seca da cultura no período vegetativo, já que o NDVI se torna insensível ao aumento de biomassa, tornando-se saturado (Silva et al., 2023).

2.3. Sensores Remotos de Monitorização Foliar

A AP consiste num conjunto de técnicas que visam aumentar a eficiência da produção agrícola através da identificação e gestão das características em diferentes áreas de cultivo. Este processo pode ser definido por quatro fases: realizar a recolha de dados sobre as culturas de interesse utilizando sensores, análise detalhada das informações obtidas tendo em consideração as características geográficas, tomada de decisão sobre o manejo agrícola mais adequado e, por fim, aplicação das medidas definidas em campo (Bourgeon et al., 2016).

As explorações agrícolas de precisão envolvem o estudo detalhado das terras cultivadas, características das plantas, condições atmosféricas e níveis de produção. Estas investigações ocorrem através da tecnologia 3S, composta por Sistema de Informação Geográfica (SIG), Sistema de Navegação por Satélite (GNSS) e Sensoriamento Remoto

(RS). Os dados sobre a área cultivada, alterações climáticas e distribuições vegetativas podem ser obtidos e monitorizados através do RS. O SIG e o GNSS são eficientes na análise da distribuição espacial e particularidades de diversos tipos de dados, possibilitando a criação de mapas e gráficos que demonstram a dinâmica dos recursos agrícolas ao longo do tempo (Zhang et al., 2002).

As análises químicas e laboratoriais exigem maior dispêndio de tempo e de recursos; em contrapartida, os sensores de monitorização foliar permitem a avaliação das características fisiológicas que determinam o estado de N na planta. Essas informações são fundamentais para a tomada de decisão da FA com precisão temporal, de forma rápida e prática, sem causar danos à cultura (Motomiya et al., 2009).

Os sensores não são capazes de estimar diretamente a concentração de N nos tecidos vegetativos; contudo, a espectroscopia de reflectância foliar (Figura 2), por meio da análise da interação entre a matéria e a radiação electromagnética, tem demonstrado resultados positivos e promissores, tanto em explorações teóricas como em aplicações práticas no campo. Ela é capaz de indicar a quantidade de moléculas de clorofila presentes nas folhas e, conseqüentemente, é possível estimar a concentração de N na planta (Vouillot et al., 1998).




Figura 2 - Curvas de resposta espectral característica da vegetação (Auster tecnologia, 2020).

Os espectrorradiômetros medem a reflectância foliar através de comprimentos de onda específicos na região do visível e na região do NIR do espectro electromagnético. A reflectância foliar é baixa no espectro visível (400 – 700 nm), pois há uma forte absorção pelos pigmentos fotossintéticos, como as clorofilas e carotenóides. Na faixa espectral

do NIR (700 – 1300 nm), as bandas não apresentam características de forte absorção; a reflectância é determinada pelas características estruturais das folhas, como as discontinuidades. Os valores da reflectância na região do infravermelho médio (1300 – 3000 nm) são variáveis, pois estão interligados à absorção de água e outros constituintes (Peñuelas & Filella, 1998).

Em ocasiões em que a planta se encontra susceptível a algum tipo de stress, verifica-se o aumento na produção de carotenóides e redução na concentração de clorofila; as folhas apresentam aspecto clorótico e, em consequência, a absorção de energia pelos tecidos vegetativos irá diminuir de tal forma que influenciará no aumento da reflectância do visível. Os sensores de monitorização foliar auxiliam na análise do teor de clorofila, possibilitando a estimativa da condição nutricional da cultura em campo; a maior parte da concentração de N foliar está contida nas moléculas de clorofila, existindo uma correlação entre N foliar e o teor de clorofila. Estas ferramentas da AP permitem a recolha e análise de dados importantes para a estimativa da fertilização em condições variáveis de campo, aumentando a eficiência da aplicação (Motomiya et al., 2009).

A uniformidade nas alterações das propriedades ópticas das folhas na faixa de 700 nm sugere um mecanismo que actua independentemente da causa do stress ou da espécie vegetal envolvida (Carter & Knapp, 2001).

A radiação electromagnética emitida pelo sol ou por sensores activos atinge a superfície vegetal e ocorre uma interação entre a energia e o alvo. Essa energia tende a dividir-se em três possíveis reacções: pode ser transmitida, passando directamente pelo alvo; pode ser absorvida e transformada em calor; ou reflectida. As ondas electromagnéticas reflectidas são a fonte de informação para as leituras sensoriais (Figura 3).




Figura 3 - Interação da luz com a estrutura foliar, mostrando os processos de reflexão, absorção e transmissão da radiação. (Santoro, 2020).

As proporções dessas interações são consequência das propriedades do alvo e do comprimento das ondas de radiação. Os comprimentos de onda do espectro electromagnético mais utilizados em agricultura são do NIR e do visível (Molin et al., 2015). A interação entre a energia electromagnética e diferentes alvos materiais é considerada um fenómeno complexo; a energia medida através de sensores é mediada por fótons. Cada matéria expressa uma assinatura espectral única, resultado da sua composição atómica e molecular; essas particularidades definem como a radiação será absorvida, transmitida ou reflectida em diversos comprimentos de onda (Heege , 2013). Actualmente, o uso de sensores ópticos de detecção remota permite a obtenção de imagens em diferentes espectros electromagnéticos que traduzem distintos estados nutricionais e/ou sanitários das culturas através da radiação electromagnética que incide sobre a superfície das mesmas. Os instrumentos de detecção remota activa operam com a sua própria fonte de emissão ou luz, enquanto os de detecção remota passiva dependem da emissão reflectida (Serrano, Shahidian, & Marques da Silva, 2016).

Ao nível do dossel, a combinação entre a reflectância do solo e da vegetação revela a reflectância espectral. A proporção de cada um desses componentes pode variar de acordo com factores externos, como a iluminação (posição do sol e ângulo de visão) e até mesmo a estrutura do dossel. Adicionalmente, para além das análises de reflectância em comprimentos de onda específicos, estão a ser propostos outros IVs de reflectância de alta resolução espectral que podem remover parcialmente as alterações causadas por variáveis externas, a fim de monitorizar o acúmulo de biomassa, a fenologia e a fisiologia das plantas (Peñuelas & Filella, 1998).

A categorização dos sistemas de sensores é feita com base na fonte de energia e no tipo de aquisição de dados, podendo ser classificados como sensores activos ou passivos, imageadores e não imageadores. Os sensores passivos recolhem dados através da detecção da radiação electromagnética natural emitida ou reflectida pela superfície terrestre. No entanto, também é possível criar ondas electromagnéticas controladas para obter informações sobre a interação entre a radiação e a superfície de um determinado alvo, através da medição da reflectância dispersa. Os sensores activos são capazes de emitir a sua própria radiação (Figura 4). A faixa espectral de actuação também classifica o tipo de sensor, como micro-ondas ou óptico. Os sensores ópticos recolhem

e analisam as emissões electromagnéticas reflectidas ou emitidas, identificando e qualificando os alvos de acordo com o seu comportamento espectral (Tullio, 2018).




Figura 4 - Esquema a ilustrar a radiação entre um sensor activo (a) e um sensor passivo (b) (Moreira, 2011).

Os sensores ópticos radiométricos operam geralmente em três níveis de recolha de dados classificados em terrestre, orbital e aéreo (suborbital), estas determinações são baseadas em níveis de altitude de operação dos sensores. Ao nível terrestre, os espectrorradiômetros e radiômetros portáteis são facilmente instalados em máquinas agrícolas para a monitorização próxima. Ao nível orbital, a predominância é dos sensores radiométricos do tipo scanner, que ficam acoplados em satélites e realizam leituras e fornecem imagens de vastas coberturas, e ao nível aéreo, os radiômetros hiperespectrais e as câmaras fotográficas podem ser utilizados para obtenção de imagens através de altitudes elevadas (Molin et al., 2015).

Os sistemas de sensores, na sua configuração fundamental, são constituídos por um colector, podendo ser constituído por um conjunto de antenas, espelhos ou lentes, um sistema detector, responsável pelos registos, implementado por filmes ou dispositivos de detecção, e, por fim, um processador que realiza o tratamento dos dados recolhidos, como demonstrado na Figura 5:




Figura 5 - Constituintes de um sistema de sensor (adaptado de moreira, 2011).

Existem parâmetros principais de um sensor que influenciam na utilização dos dados (Figura 6), que incluem a resolução espacial, ou seja, a capacidade que o sensor possui para discriminar o menor objeto em solo, a resolução espectral que define a largura da banda pela qual a imagem está sendo capturada, a sensibilidade radiométrica do sensor de diferenciar a refletância emitida por diferentes alvos e a faixa dinâmica (Navalgund, Jayaraman & Roy, 2001).




Figura 6 - Classificação dos sistemas dos sensores de acordo com a categoria (Navalgund, 2001).

Esquema de classificação dos sensores de detecção remota exemplifica que os sensores dividem-se em ópticos e de micro-ondas, podendo atuar em modo ativo (quando emitem radiação) ou passivo (quando apenas detetam a radiação natural emitida ou refletida pelos alvos). No domínio óptico, os sensores ativos, como o LIDAR (*Light Detection and Ranging*), emitem pulsos de laser e medem o tempo de retorno da radiação, permitindo obter informações tridimensionais muito precisas sobre a estrutura da vegetação e a topografia. Os sensores ópticos passivos, como os radiômetros e

espectrómetros de imagem, registam a radiação solar refletida e a radiação térmica emitida pela superfície, nas bandas do visível, infravermelho próximo e infravermelho térmico. No domínio das micro-ondas, os sensores ativos, como o RADAR de Abertura Sintética (SAR), emitem micro-ondas e medem o eco refletido, o que possibilita a análise da textura, estrutura e humidade do solo, independentemente das condições atmosféricas. Já os sensores de micro-ondas passivos medem a emissão natural da superfície terrestre em comprimentos de onda longos, sendo utilizados para estimar parâmetros como a humidade do solo e variáveis atmosféricas. Este esquema ilustra, assim, os diferentes tipos de sensores e os seus princípios de funcionamento, bem como as suas principais aplicações na monitorização da superfície terrestre e da vegetação.

Para realizar a recolha de dados das culturas podem ser utilizados sensores multiespectrais e hiperespectrais; estes sensores podem gerar a sua própria luz, como o GS®, ou utilizar sensores passivos (sistemas de imagem) que medem a reflectância transmitida e a fluorescência das folhas. As informações obtidas permitem avaliar as características biofísicas e bioquímicas, possibilitando as determinações quantitativas de N, clorofila e biomassa presente nas plantas (Bourgeon et al., 2016). Os tecidos vegetais são capazes de absorver cerca de 90% da radiação visível (390 a 750 nm) e reflectem 50% do NIR (750 a 1300 nm). A quantidade de %N presente na cultura causa variações na absorção e reflectância das porções do visível e do NIR; esses valores fornecem informações sobre o estado de N na planta. Quando a planta apresenta deficiências nutricionais, há maior reflexão de visível e menos NIR em comparação com culturas em estado nutricional eficiente (Padilla et al., 2018)

Os sensores ópticos podem auxiliar na determinação de parâmetros cruciais no desenvolvimento das culturas agrícolas, como o índice de área foliar, que está relacionado com a distribuição de luz no dossel e interfere directamente na eficiência fotossintética da planta e no impacto do rendimento biológico da cultura. Ensaio com a cultura do trigo mostraram que a deficiência de N, fósforo (P), potássio (K), cálcio (Ca) e magnésio (Mg) é capaz de reduzir as concentrações dos componentes fotossintéticos; desta forma, haverá um aumento na reflectividade na faixa visível, fazendo com que as bordas vermelhas se desloquem na direcção dos comprimentos de onda mais curtos ou mais longos (Tan et al., 2020).

Um dos benefícios esperados do uso de sensores ópticos activos é que estes têm a capacidade de realizar leituras em qualquer momento do dia, pois não sofrem

interferência das variações da radiação solar. Estes equipamentos não necessitam de calibração da reflectância, dado que possuem a sua própria fonte de luz constante. A fonte de luz destes sensores possui alcance limitado, portanto, só podem ser utilizados para detecção proximal (Fitzgerald, 2010).

Ensaio realizados por (Biermacher et al., 2009) demonstraram que o uso de sensores na FA é capaz de reduzir a quantidade de fertilizante aplicado e, assim, minimizar o impacto ambiental. Comparando a utilização de sensores ópticos activos com os métodos de fertilização convencionais em culturas anuais de inverno, em diferentes regiões da Ásia e dos Estados Unidos da América, observou-se que a eficiência do uso de N (NUE) foi 10,4% maior do que a NUE para a abordagem convencional (Aula et al., 2020). De acordo com Nogueira-Martins et al. (2022), as aplicações de N em taxa ou dose variável (VRA), utilizando sensores como o clorofilómetro SPAD-502 (Konica Minolta Sensing Americas, Inc., New Jersey, USA) ou o ClorofiLOG CFL 1030 (Falker, Porto Alegre, BR), apresentam viabilidade económica em áreas superiores a 5 ha e 3 ha, respectivamente.

Quando os sensores actuam ligados a uma unidade central de processamento (CPU), podendo gerar dados capazes de ser processados em tempo real (sensores em linha), torna-se possível a criação de respostas através do comando de actuadores nas respectivas máquinas operadoras (Figura 7).




Figura 7 - Princípio sensor-actuador assente no princípio de sensor em linha (Adaptado de Cedra, 1992).

O utilizador interage com o sistema ou máquina pedindo ou activando um procedimento de calibração de um indicador de avaliação medido a partir de um sensor. O mostrador é o dispositivo que fornece informações ao utilizador. O tratamento electrónico criado pela CPU indica o processamento de dados realizado electronicamente, assente na informação do sensor. Este envia a um actuador que realiza a tarefa desejada, como por exemplo a dose adequada de fertilizante azotado a aplicar face à leitura de indicadores vegetativos da cultura. O sistema de automação permite, assim, em tempo real, criar uma resposta para o uso do factor de produção sem ter de haver um passo intermédio entre a leitura de dados e a conversão em mapas de prescrição.

Assente neste princípio de funcionamento, estes sensores, ao deslocarem-se no campo, avaliam em tempo real as propriedades do solo ou da cultura presente em diferentes zonas e determinam a variação da quantidade de fertilizante que deve ser aplicada (D'Oliveira, 2023). A área que o sensor cobre durante a medição é variável, pois, além de depender da distância entre o dossel e o sensor, a área analisada é influenciada também pela projecção de cada sensor; a característica óptica influencia o ângulo de visão, por exemplo, o GS® possui um feixe de luz fisicamente colimado em paralelo a um receptor capaz de medir a luz reflectida na mesma direcção; a área de medição é rectangular e aumenta de acordo com a altura do sensor e o dossel da cultura em campo (Kipp et al., 2014).

2.4. Fertilização Azotada em Dose Variável

A FA é uma prática essencial para que haja bom rendimento e qualidade das forragens. Em Portugal, esta prática pode englobar tanto a aplicação de fertilizantes minerais como a fertilização biológica proveniente da fixação de azoto por leguminosas incluídas nas forragens. Identificar as necessidades nutricionais da planta no campo, através da variabilidade que ocorre devido aos processos biogeoquímicos que afectam o N, é fundamental para otimizar a eficiência da adubação. Através do conhecimento da variabilidade espacial e temporal das exigências nutricionais da cultura é possível introduzir no manejo técnicas de AP que contribuem para o aumento da produtividade e a redução do uso de factores de produção, consequentemente o impacto ambiental será menor, pois será possível realizar o manejo específico de cada local (Basso et al., 2013; Robertson et al., 2012). Os benefícios proporcionados por essas técnicas estão directamente condicionados à determinação precisa das variabilidades (Basso et al.,

2016). Os métodos convencionais para identificar as características das plantas em áreas de grandes extensões territoriais exigem a recolha de amostras minuciosas e procedimentos laboratoriais de custo elevado (Mutanga et al., 2004).

Na agricultura tradicional é comum a aplicação de fertilizantes azotados em dose única em grandes áreas, porém estudos realizados por Raun et al. (2001) demonstraram que a exigência de N varia em escalas menores de 1 m², o que significa que cada metro quadrado deve ser tratado de forma individual, de acordo com as suas características, em contradição à amostragem em grelha por hectare, que é a forma utilizada na agricultura convencional. Esta descoberta foi fundamentada após diversas amostragens de solo, leituras das plantas com sensores ópticos e análises geoestatísticas.

Em contrapartida às metodologias tradicionais da agricultura convencional, a AP surge com um conjunto de práticas que permitem o conhecimento das variabilidades dentro do campo e possibilitam intervenções localizadas e mais eficientes. Uma das técnicas mais significativas da AP é a Aplicação em Taxa Variável (VRA), uma tecnologia capaz de gerir aplicações em quantidades específicas, previamente determinadas, coerentes com a procura de cada parcela da exploração. Esta viabiliza-se devido ao conhecimento detalhado sobre as características do solo, clima e estado fisiológico das plantas em tempo real. A recolha de dados é feita com a utilização de sensores, imagens de satélite e GNSS, métodos que podem ser utilizados individualmente ou em conjunto, de forma complementar (Molin et al., 2015).

A VRA é capaz de refletir significativamente na proteção climática e no aumento da vantagem económica, garantindo a aplicação precisa dos fatores de produção e minimizando a contaminação do meio ambiente e o desperdício de insumos. Esta técnica reduz a lixiviação de nutrientes e a emissão de GEE, aumentando consequentemente a proteção dos recursos naturais e contribuindo para a melhoria da biodiversidade e da qualidade da atmosfera. Ao diminuir o excesso de insumos, promove a saúde do solo e o aumento produtivo da exploração agrícola. A associação das tecnologias de SR e de fenotipagem com a VRA permite a monitorização abrangente das variáveis em campo e em tempo real, possibilitando a gestão precisa da saúde fisiológica das plantas e das condições edafoclimáticas que influenciam diretamente a exigência de nutrientes pela cultura (Abdalla & Mirzakhani Nafchi, 2024).

Uma das técnicas utilizadas para a implementação e gestão eficaz da FA em VRA é o sensoriamento óptico (Felipetto, 2022). Através da interpretação das leituras realizadas

pelos sensores em campo é possível obter informações sobre a distribuição de %N na planta em diferentes parcelas. Estes dados permitem ajustar a aplicação de fertilizante azotado de acordo com a variabilidade espacial e as necessidades da cultura. Estes equipamentos têm a capacidade de avaliar de forma não destrutiva e em tempo real as condições nutricionais das plantas e o acúmulo de biomassa, através do estudo da interação entre a radiação e o dossel vegetal (Betül Rufaioğlu et al., 2002).

Um exemplo de sensor óptico utilizado é o GS®, que, através da sua própria fonte de luz, realiza a medição da refletância da planta. O dispositivo analisa a biomassa e o vigor da cultura e calcula o NDVI. A partir das informações obtidas pelo sensor é possível ajustar a fertilização de N em diferentes parcelas do talhão (Rutto, 2009).

Diferentes ensaios (Amaral et al., 2015; Kapp-Junior et al., 2020; Sharma et al., 2015; Shaver et al., 2011) demonstraram que o uso do sensor GS® influenciou a taxa de aproveitamento de N na cultura do milho, ao analisar a quantidade de biomassa e o teor de clorofila. Vários autores afirmam que a quantidade de tecido verde presente nas folhas influencia diretamente a refletância da copa na região visível e no NIR. No espectro *Red Edge* do sensor, o comprimento de onda de 710 nm apresentou melhor desempenho na previsão de rendimento do milho em comparação com 735 nm (Sharma et al., 2015).

Os índices obtidos por intermédio de faixas de onda de borda vermelha apresentaram resultados superiores aos gerados com faixas de onda vermelha na quantificação de N no trigo. Da mesma forma, estudos comprovaram que o índice NDRE é mais eficiente do que o NDVI na cultura do milho (Amaral et al., 2015).

Em áreas com variações de densidade e idade das plantas, o sensor apresenta limitações na determinação exata dos índices de NDVI, devido à saturação em valores elevados de biomassa, além da ausência de linearidade em zonas com níveis elevados de azoto, como por exemplo em pastagens com manchas de urina resultantes de animais em pastoreio (Hooper et al., 2017). Outros fatores relacionados com o stresse ambiental, como o stresse hídrico, que influencia a dispersão da luz pelas estruturas celulares vegetais, também afetam a precisão do NDVI (Sharma, Bu, Denton, & Franzen, 2015).

O GS® foi utilizado para medições de NDVI em diferentes estádios de crescimento do trigo, em várias horas do dia. A utilização do sensor resultou num rendimento económico de 55 kg N ha⁻¹ em cobertura, causando um aumento de 33% no rendimento de grãos e um retorno económico de 189,50 USD ha⁻¹. Para garantir a precisão das

leituras espectrais do sensor é necessário um planejamento consistente, tendo em consideração a hora do dia (Kapp-Junior et al., 2020).

Um dos sensores mais recentes disponíveis no mercado é o sensor Augmenta, que se destaca pela sua tecnologia avançada de visão computacional e inteligência artificial, oferecendo uma solução mais completa para otimizar a aplicação de fatores de produção e garantir maior eficiência no manejo das culturas (Raven Industries, 2023). O Augmenta permite o ajuste dinâmico de prescrições e a implementação de aplicações VRA em tempo real. O sistema baseia-se na aquisição e análise de dados visuais através de uma câmara integrada. A instalação do sensor no topo da cabine do trator ou da máquina operadora pode ser feita em equipamentos que utilizam a norma ISOBUS (ISO 11783-1:2017, 2023). O sensor é capaz de monitorizar e analisar diversos fatores ambientais específicos da parcela agrícola. Através do uso de IA, o sensor processa as imagens capturadas, traduzindo-as em prescrições de aplicação que são automaticamente implementadas pela máquina operadora – distribuidor de adubo ou pulverizador. Um dos aspetos que distingue este sensor dos demais é o cálculo de um índice de vegetação proposto pelo fabricante, denominado *Augmenta Agronomic Index (AAI)*. Este índice reflete o estado de saúde e o vigor da planta em tempo real, fornecendo uma avaliação dinâmica e precisa das condições da cultura (Figura 8).




Figura 8 - Processamento de imagens em tempo real e inteligência artificial: o sistema ajusta automaticamente a quantidade de insumos aplicada em cada centímetro do campo (Future Farming, 2019).

O Augmenta utiliza os princípios do NDVI, combinado com IA, para estimar a biomassa verde e o vigor da planta. O cálculo do AAI é autocalibrado, adaptando-se às condições específicas de cada cultura. Esta característica pode garantir a precisão e a fiabilidade das informações geradas, independentemente da variabilidade edafoclimática. De acordo com as indicações do fabricante, o sensor está calibrado para culturas de soja, milho, feijão, cereais, trigo, cevada, colza e algodão, podendo reduzir significativamente os fatores a aplicar em 7% em N, 15% em herbicidas e até 6% em fungicidas (Raven Industries, 2025).

Os drones MSI, sensores multiespectrais embarcados, são ferramentas que também auxiliam na obtenção de informações precisas sobre o estado nutricional da cultura em campo por meio dos IVs. Os índices gerados possibilitam a compreensão dos parâmetros biofísicos da exploração agrícola através da análise da atividade fotossintética, cor, estrutura e fração de cobertura do solo, entre outros fatores relevantes para a determinação da tomada de decisão na aplicação de fatores de produção (Cavalcante et al., 2022).

Os dados obtidos através do SR realizado com os drones fornecem medições em alta resolução espacial e temporal das características da lavoura para aplicações agrícolas. Com essas informações, é possível dividir a área cultivada em zonas de manejo (ZM). A delimitação das ZM constitui uma forma de determinar a variabilidade espacial do campo e, dessa forma, possibilita a gestão diferenciada de fatores de produção em diferentes áreas produtivas (Camicia et al., 2018).

Bragagnolo, Amado, Nicoloso, Santi e Fiorin (2013) conduziram um experimento de VRA com base nas leituras feitas por um sensor de espectrometria óptica (N-sensor), a fim de avaliar a produtividade e a eficiência do VRA prescrito por um sensor óptico na cultura do milho. O estudo indicou uma redução média de 20% na aplicação de fertilizante em comparação com as técnicas convencionais, sem comprometer o rendimento da cultura. Nos blocos onde foi realizada a VRA recomendada através dos dados obtidos pelo sensor, os autores relatam um incremento médio de 12% na produtividade e uma diminuição de cerca de 25% do N lixiviado no solo.

Neste contexto, os autores Aula et al. (2020) comprovam a eficiência dos sensores para a fertilização azotada (FA) em dose variável. Bragagnolo (2014) constatou que as aplicações realizadas com base no sensor óptico na cultura do milho aumentaram a absorção de N em 11,8% em comparação com a fertilização em dose uniforme. A

produção de grãos foi superior em resposta à fertilização em dose em todas as áreas experimentais.

2.5. Culturas Forrageiras de Inverno em Clima Mediterrânico

De acordo com a *Food and Agriculture Organization of the United Nations* (FAO, 2018) e (Bancayan Hinostroza & Olortegui Chamoli, 2023), as pastagens naturais são consideradas a principal fonte de alimento e de nutrientes para o gado em sistema de pastoreio, sendo essenciais para a produção global de alimentos. O sistema de pastagens é considerado o mais acessível e de menor custo (De Paula Corrêdo et al., 2019).

Ferreira (2016) afirma que a composição das forragens, que constituem uma percentagem importante da alimentação e nutrição de animais herbívoros, é extremamente variável devido ao grande número de fatores que interferem na sua formação, nomeadamente: a família botânica predominante na biomassa vegetal, o estágio fisiológico da planta durante o corte, as estruturas morfológicas e as alterações na qualidade do tecido vegetativo, que podem influenciar o processo de conservação da forragem de forma benéfica ou ocasionando perdas.

As alterações climáticas têm impacto significativo na produção de forragens de qualidade para a alimentação animal, pois a temperatura, a composição atmosférica e a precipitação influenciam diretamente o crescimento vegetativo das culturas forrageiras e o acúmulo de biomassa (Adar et al. 2024). A elevação da concentração atmosférica de CO₂ tem demonstrado, em diversos estudos, um efeito estimulante sobre o crescimento e o acúmulo de biomassa das plantas com metabolismo fotossintético C₃, como o azevém. Este efeito deve-se à maior disponibilidade de CO₂ como substrato para a fotossíntese e à redução da fotorrespiração, o que resulta numa maior assimilação líquida de carbono e, consequentemente, num incremento da produtividade vegetal (Ainsworth & Long, 2005). No entanto, o impacto positivo do CO₂ elevado pode ser limitado pela disponibilidade de nutrientes, em particular de azoto, e pela disponibilidade hídrica, uma vez que o crescimento adicional apenas se mantém quando os recursos edáficos são suficientes para sustentar a produção de novos tecidos. Assim, embora o aumento de CO₂ possa favorecer a produção de forragens, a resposta das plantas depende fortemente das condições de fertilidade do solo e de regime hídrico, sendo necessário um equilíbrio entre estes fatores para que o potencial de crescimento seja plenamente alcançado (Sillén & Dieleman, 2012).

Estes impactos podem verificar-se em todo o mundo, contudo, devido às características geográficas e ambientais das regiões de clima mediterrânico, as culturas tornam-se ainda mais vulneráveis aos efeitos do clima (Adar et al., 2024). O ecossistema mediterrânico caracteriza-se por instabilidades climáticas e pela distribuição irregular da precipitação, o que ocasiona períodos de baixo rendimento nas forragens. Face a estas condições, as plantas forrageiras desempenham um papel imprescindível na alimentação e nutrição dos ruminantes, pois podem assegurar provisões em quantidade e qualidade adequadas (Carita et al., 2019).

As variações atmosféricas resultam em alterações climáticas numa determinada região, manifestando-se em baixas ou altas temperaturas e humidades. Estes fatores influenciam diretamente o desenvolvimento fisiológico das plantas, podendo impedi-lo ou favorecê-lo, de acordo com a adaptabilidade de cada espécie. As variações de temperatura e de humidade limitam o crescimento de várias espécies forrageiras. De modo geral, os processos metabólicos de assimilação de nutrientes iniciam-se em temperaturas superiores a 0 °C, atingem o seu potencial máximo e estabilizam-se a 35 °C, paralisando em períodos acima de 45 °C. As temperaturas elevadas interferem no processo de respiração celular, reduzindo a capacidade energética da planta e duplicando ou triplicando a produção de CO₂ (Juscafresa, 1982). Nas plantas C₃, como o azevém, típicas do clima mediterrânico, as temperaturas elevadas reduzem a eficiência fotossintética devido ao aumento da fotorrespiração, processo em que a enzima Rubisco utiliza oxigénio em vez de dióxido de carbono, causando perda de carbono fixado e menor produção de biomassa. Em condições de calor e défice hídrico, comuns nos verões mediterrânicos, o fecho estomático limita ainda mais a entrada de CO₂, agravando a redução na assimilação de carbono e na eficiência do uso de nutrientes. Assim, a combinação de altas temperaturas e escassez de água resulta numa forte limitação fisiológica ao crescimento e produtividade das plantas C₃ (Peñuelas & Filella, 2022).

Em regiões com clima irregular, como o mediterrânico, os sistemas pecuários em regime extensivo possuem grande relevância. Em Portugal, 51,7% da área agrícola é ocupada por pastagens permanentes, essenciais para a produção extensiva. O último Recenseamento Agrícola, realizado em 2009 (Instituto Nacional de Estatística [INE], 2021), demonstrou que houve um aumento de 10,6% na bovinicultura, sendo dois terços desse aumento relativo a animais explorados em regime extensivo e um terço a animais

em confinamento, que pastam em determinadas épocas do ano. No caso da ovinicultura, não se registaram diferenças relevantes, enquanto a produção de caprinos diminuiu 11,5%. Contudo, os grandes rebanhos, com mais de 500 animais, cresceram 27,6% (Instituto Nacional de Estatística, 2019). Em 2021, a produtividade em bovinos, ovinos e caprinos aumentou, respetivamente, 5,3%, 9,3% e 14,8% em relação a 2020 (Instituto Nacional de Estatística [INE], 2022). Com base nestes dados, Basso et al. (2016) destacam a crescente necessidade de produção e conservação de forragem de qualidade para os períodos de escassez, dado ser um dos principais componentes da alimentação de ruminantes. Esta necessidade é ainda maior devido à dependência de Portugal da importação de matérias-primas destinadas à alimentação animal.

Nas regiões mediterrânicas, é comum que os produtores realizem a aplicação de 30% do fertilizante na época da sementeira, incorporando os restantes 70% na fase de desenvolvimento do caule. As técnicas de Agricultura de Precisão (AP) permitem que os produtores considerem as características de variação espacial e temporal da área produtiva e, assim, possam tomar decisões específicas para cada zona com necessidades distintas (Basso et al., 2016).

2.6. Interação do N com os Processos Fisiológicos das Forragens

O N está entre os macronutrientes principais para o crescimento vegetativo e, na maioria dos casos, pode ser o elemento limitante para a produção vegetal. Nas plantas, encontra-se presente em quantidades correspondentes a 1%–5% da matéria seca total e a 40%–50% do protoplasma celular, constituindo diversos compostos organominerais complexos essenciais ao metabolismo vegetal. Entre estes, destacam-se: os aminoácidos; as proteínas, em constante processo de degradação e síntese vitais; as nucleoproteínas, como o DNA (*ácido desoxirribonucleico*) e o RNA (*ácido ribonucleico*), que atuam na hereditariedade genética; a clorofila, primeira molécula fixadora de energia luminosa imprescindível à fotossíntese; e a ribulose-1,5-bisfosfato carboxilase oxigenase (RuBisCo), enzima responsável pela incorporação do CO₂ durante o processo fotossintético.

As plantas apresentam preferências de assimilação do N sob a forma amoniacal (NH₄⁺) ou nítrica (NO₃⁻), dependendo de características genéticas e ambientais, tais como a solução do solo e a disponibilidade do elemento. Em solos mal drenados, ácidos e com baixas temperaturas, as raízes tendem a absorver preferencialmente N-NH₄⁺. Já em

solos com condições ideais de temperatura e humidade, a maioria das plantas prefere o N-NO_3^- presente na solução do solo, uma vez que o N-NH_4^+ se encontra adsorvido aos colóides do solo e, por conseguinte, a planta tem de despende mais energia para o absorver (Santos, 2002).

De acordo com Primavesi et al. (2006), o nitrato presente no solo é proveniente da adição de fertilizantes azotados ou da mineralização da matéria orgânica. Quando o NO_3^- existente na solução do solo não é absorvido pelas plantas nem metabolizado pelos microrganismos, torna-se altamente suscetível à lixiviação, por ser um ânion não adsorvido pelos colóides do solo, que possuem cargas negativas. Durante o período das chuvas, o N percolado pode contaminar os lençóis freáticos, impactando negativamente a saúde ambiental e contribuindo para processos de eutrofização nos cursos de água, com consequente desequilíbrio dos ecossistemas naturais.

O N diretamente transportado (Ndt) é facilmente acessível às culturas e contribui para o aumento da área foliar, influenciando o crescimento vegetativo e, consequentemente, o acúmulo de biomassa (Lehmeier et al., 2013). Contudo, devido à sua alta mobilidade, o Ndt é vulnerável a perdas por percolação, volatilização e desnitrificação. Assim, torna-se necessário desenvolver estratégias para maximizar a sua eficiência de uso e reduzir os impactos ambientais (Gomide, 2020). A biomassa colhível é determinada tanto pela absorção de N através de fontes naturais ou fertilização como pela sua assimilação pelo sistema fisiológico da planta (Sun et al., 2008).

A concentração de N nos tecidos metabólicos e a proporção dos compartimentos estruturais das plantas variam entre espécies com biomassa semelhante. Esta diferença manifesta-se entre plantas C_3 e C_4 , em função da anatomia foliar e do metabolismo de assimilação do CO_2 . Em condições nutricionais favoráveis, as plantas C_4 utilizam cerca de 75% da quantidade de N exigida pelas plantas C_3 para produzir a mesma biomassa. Isto deve-se ao facto de a enzima PEP carboxilase, presente nas plantas C_4 , ter maior afinidade pelo CO_2 do que a enzima RuBisCo, característica das plantas C_3 . Os tecidos metabólicos vegetais, ricos em N, estão em menor proporção nas plantas C_4 relativamente à sua biomassa total. Além disso, a morfologia das plantas C_3 resulta num aproveitamento estimado 25% inferior da radiação solar, em comparação com uma cultura C_4 (Lemaire, 1997).

As leguminosas possuem a capacidade de estabelecer simbiose com bactérias do género *Rhizobium*. Nos nódulos radiculares, estas bactérias fixam o N_2 atmosférico,

convertendo-o em NH_3 , que é sintetizado pelas estruturas fisiológicas da planta. Contudo, quando o solo dispõe de N disponível, a simbiose tende a ser reduzida, dado que a cultura satisfaz as suas necessidades com o N já acessível. Já as gramíneas dependem exclusivamente do N presente no solo, pelo que a sua deficiência constitui um fator limitante para o desenvolvimento. Assim, em pastagens compostas por gramíneas, verifica-se maior resposta à FA (O'Connor MB, 1982).

2.7. Fatores que Afetam a Resposta da Forragem ao N

As diferenças botânicas entre as espécies de forragem influenciam a resposta da cultura ao N. Como as espécies leguminosas e gramíneas possuem respostas diferenciadas, a composição da pastagem interfere na resposta à fertilização. Contudo, as aplicações de N também afetam a composição da pastagem. Esta afirmação resulta de 158 ensaios realizados em consorciações de azevém perene e trevo na Nova Zelândia. O'Connor MB (1982) administrou explorações com 100 kg N/ha na primavera e no outono; os resultados mostraram que as gramíneas suprimem os trevos pelo sombreamento, uma vez que respondem mais à FA, alterando a composição da pastagem. Apesar disso, o rendimento do trevo nem sempre se reduz significativamente. Feyter et al. (1985) obtiveram resultados semelhantes. Em explorações dominadas por *Trifolium repens*, a proporção de leguminosa não diminuiu relativamente às gramíneas, possivelmente devido a cortes extras que evitam o sombreamento. Conclui-se que a redução dos trevos pela FA pode ser minimizada através de manejo adequado ou pastoreio (Smith et al., 2000).

Wedderburn et al. (1990), no norte da Nova Zelândia, verificaram que ecótipos de azevém perene (*Lolium perenne*) respondem diferentemente ao N. Amostras de 60 locais mostraram que plantas de encostas íngremes com grave deficiência de N responderam menos à fertilização do que amostras de ambientes menos estressados. Assim, o azevém tolerante à deficiência de N não responde bem à fertilização após alívio da deficiência. Inicialmente, as pastagens respondem à fertilização azotada com rápida absorção do N aplicado; após a assimilação, a planta aumenta o crescimento e o perfilhamento. Em *Lolium perenne*, a fertilização com N aumentou em 34% o número de perfilhos em relação à cultura não fertilizada (Sun et al., 2008).

Durante o alongamento dos perfilhos reprodutivos, os nutrientes são direcionados para esta fase, reduzindo a atividade metabólica nos perfilhos vegetativos e provocando a sua

senescência, independentemente da fertilização. O desenvolvimento do perfilho reprodutivo limita-se à expansão de tecidos já formados e não à formação de novos, restringindo a resposta da gramínea ao N (Sun et al., 2008).

Feyter et al. (1985) verificou que nem sempre o efeito residual da FA aumenta a densidade da pastagem; em alguns casos, pode até reduzir o rendimento. Geralmente, o primeiro e o segundo cortes apresentam respostas positivas, enquanto o quarto e quinto corte mostram respostas mais baixas, e o terceiro corte resultados inconsistentes.

Ali et al. (2014) afirmam que as perdas de N aplicado no sistema solo-planta-animal são significativas. A baixa eficiência resulta da prática comum de aplicar fertilizante uniformemente em áreas com necessidades diferentes, desconsiderando a heterogeneidade espacial do solo e das plantas. A necessidade nutricional, capacidade de absorção e resposta vegetal à adubação variam consideravelmente. Recomendações gerais sem considerar esta variabilidade resultam em uso ineficiente do N, dada a elevada dinâmica temporal e espacial das condições de campo.

O clima durante a estação de crescimento influencia fortemente a resposta das plantas ao N. Em zonas de sequeiro, a disponibilidade hídrica limita a absorção de N; com água suficiente, a planta absorve nutrientes eficientemente, mas em déficit hídrico a resposta à fertilização é limitada. Normalmente, os produtores decidem aplicar N com base no estágio de desenvolvimento da cultura, sem considerar parâmetros climáticos (Basso et al., 2016).

As estratégias de incorporação de N no sistema solo-planta-animal não são generalizáveis, pois cada sistema possui particularidades. Embora a FA aumente o crescimento vegetativo, existe um ponto de saturação: doses elevadas de N reduzem a eficiência de utilização e impactos ambientais negativos. Ainda assim, devido à intensificação da atividade pecuária, existem múltiplas aplicações de N durante a época das águas (Pereira et al., 2022; Peng, Chen & Yang, 2020).

Para gerir eficientemente a FA, é fundamental compreender a dinâmica de absorção e distribuição de N no sistema fisiológico da planta. A concentração crítica de azoto (%N_c) corresponde ao teor mínimo de azoto necessário para que a planta atinja o seu crescimento vegetativo máximo. Este conceito é essencial para avaliar o estado nutricional da cultura, uma vez que concentrações inferiores a este valor indicam deficiência de azoto, resultando em menor desenvolvimento e redução da produtividade. Por outro lado, valores superiores à concentração crítica não proporcionam ganhos

adicionais de crescimento e podem conduzir ao desperdício de fertilizante e a impactos ambientais negativos. Assim, a determinação da %Nc permite otimizar a fertilização azotada, ajustando a aplicação às reais necessidades fisiológicas da planta (Silva et al., 2024).

Conhecer as variações e limitações metabólicas e genéticas de absorção e assimilação de N pelas forragens permite planejar fertilizações que aumentem a eficiência fisiológica. Esta eficiência depende do conhecimento do ciclo cultural e das variações espaciais e temporais que interferem fenotipicamente na cultura (Silva et al., 2023).

3. Material e Métodos

3.1 Características Edafoclimáticas da Área Experimental

O experimento decorreu entre 30 de outubro de 2024 e 27 de março de 2025, numa área não irrigada de 1,50 ha, na Herdade da Comenda – Centro de Inovação do Instituto Nacional de Investigação Agrária e Veterinária (INIAV), em Elvas, região do Alentejo (Portugal), com coordenadas locais 4706572,00 N; 784908,00 W. Os limites da parcela (Figura 9) foram georreferenciados utilizando o software de sistema de informação geográfica QuantumGIS (QGIS), versão 3.28.4.




Figura 9 - Identificação e delimitação da área experimental.

De acordo com as classificações climáticas de Köppen (1900), o clima da região caracteriza-se por verões secos e quentes, e invernos frios com elevada pluviosidade, definindo-se como clima Csa Mediterrânico. Em conformidade com as especificações da Organização Meteorológica Mundial (OMM), as características climáticas são determinadas por valores médios plurianuais e por diferentes elementos meteorológicos, considerando que um período de 30 anos é estatisticamente representativo para esta caracterização. Atualmente o período de referência climatológica utilizado pelo Instituto Português do Mar e da Atmosfera (IPMA) corresponde ao intervalo 1991–2020. Nesse período, são disponibilizados valores médios mensais e anuais dos principais elementos climáticos, como a temperatura média do ar (°C) e a precipitação total (mm), para diferentes estações meteorológicas em Portugal, incluindo a estação de Elvas, os quais estão representados no quadro 3.

Quadro 3 - Normal Climatológica incluindo os valores de Tm e P em Elvas (IPMA; 2024).

Mês	Temperatura (C°)	Precipitação (mm)
Outubro	17,4	58,6
Novembro	12,5	75,1
Dezembro	9,7	92,6
Janeiro	8,6	63,1
Fevereiro	10,2	54,6
Março	12,3	39,6
Abril	14,1	51,2

Segundo a classificação da FAO, o solo na área experimental é o Luvisolo, que corresponde aos solos mediterrânicos Pag e Sr (Cardoso, 1974). O Horizonte Pag possui coloração marrom variando a marrom-acinzentada ou cinza claro. A sua composição textural predominante é arenosa ou franco-arenosa, ocasionalmente pode apresentar minerais de quartzo de granulometria grosseira ao longo do perfil do solo. Esse horizonte apresenta estrutura pedológica não agregada ou com a presença de agregados finos. O horizonte de diagnóstico Sr apresenta uma coloração de marrom a marrom-avermelhada, com uma abundância típica de elementos grosseiros que se

encontram distribuídos verticalmente pelo perfil. Neste horizonte a estrutura pedológica típica é granular fina com grau de desenvolvimento moderado a fraco.

3.2. Instalação dos ensaios

A zona experimental, delimitada em 1,50 ha, foi estabelecida com a espécie azevém anual (*Lolium multiflorum* L.). Esta gramínea apresenta elevada palatabilidade, com produção expressiva de forragem e sementes, e elevada capacidade de resistência, sendo particularmente adequada para a produção de forragem em regiões com verões de altas temperaturas e invernos amenos (Franca, Loi, & Davies, 1998).

A cultura de azevém anual foi semeada com uma entrelinha de 0,18 m e profundidade de 0,01 m (Figura 10). A densidade de sementeira foi de 1 400 sementes m², aplicadas em 30 de outubro de 2024. Antes da semeadura, em 28 de outubro de 2024, foram aplicadas doses suficientes de fósforo (16,1 kg ha⁻¹ P₂O₅) e potássio (13,8 kg ha⁻¹ K₂O), juntamente com uma dose de N (27,6 kg ha⁻¹ N) distribuída uniformemente para garantir a emergência correta da cultura. A irrigação também foi realizada de forma uniforme, utilizando um sistema de aspersão, até que o solo atingisse a capacidade de campo, permitindo a emergência adequada da cultura.



Figura 10 – Conjunto trator – semeador.

3.3. Adubação de cobertura a taxa variável

Para a realização deste experimento, no dia 5 de março de 2025, o sensor foi instalado num trator New Holland, posicionado a 2,8 m de altura em relação à superfície do solo. O campo de visão do sensor corresponde a dez vezes a altura do ponto de instalação, pelo que, para a aquisição dos dados neste estudo, o campo de visão determinado pelo sensor foi de 28 m (Figura 11).



Figura 11 - Augmenta Sensor instalado na parte superior frontal da máquina.

O trator New Holland T5.140 Dynamic Command™ foi utilizado para a instalação do sensor Augmenta e para a distribuição de adubo em taxa variável. Este modelo está equipado com um motor FPT de 4,5 L e 140 cv, transmissão 24x24 Dynamic Command™, com 8 marchas sob carga e 3 gamas. O sistema hidráulico de centro fechado, com vazão de até 110 L/min, garante a capacidade de acionamento dos implementos agrícolas utilizados. Adicionalmente, o trator possui tomada de potência (PTO) traseira com múltiplas velocidades (540/540E/1000 rpm). As dimensões e o peso aproximado do trator são 5 500 kg sem carga. O sistema de comunicação entre a máquina e os implementos segue o protocolo ISO TR14396 (New Holland, 2025). Para a aplicação da VRA, foi utilizado um distribuidor de adubo Amazone ZA-TS 4200, acoplado ao trator. Este equipamento é um espalhador centrífugo de elevada precisão, projetado para a distribuição uniforme de fertilizantes granulados, permitindo ajustes automáticos da dose de aplicação com base em mapas de prescrição ou leituras em tempo real. O sistema integra tecnologia de controlo eletrónico e sensores que garantem a dosagem exata conforme a velocidade de deslocamento e as condições do terreno, assegurando uma aplicação eficiente e sustentável dos nutrientes (AMAZONE-Werke H. Dreyer GmbH & Co. KG., 2025). O uso deste equipamento foi essencial para

a execução da fertilização diferenciada em campo, possibilitando a implementação prática da metodologia VRA-Live no presente estudo (Figura 12).



Figura 12 - Trator new holland T5.140 dynamic command™ e distribuidor de adubo Amazone ZA-TS.

Para a realização das aplicações VRA, foi utilizado o sensor óptico Augmenta Field Analyzer (Raven Industries Inc., South Dakota, EUA), que integra tecnologias de visão computacional e inteligência artificial (IA) com o objetivo de otimizar o uso de insumos agrícolas. O sensor foi instalado na parte superior da cabine do trator (Figura 13), em equipamento compatível com o protocolo ISOBUS. O sistema operou através da captura de imagens da vegetação em tempo real, que foram processadas por algoritmos de IA gerando prescrições agronômicas específicas, imediatamente aplicadas pelo distribuidor de adubo. O sensor augmenta é compatível com a aplicação de fertilizantes azotados, fungicidas, herbicidas e reguladores de crescimento, ajustando automaticamente a dosagem conforme a variabilidade intra-talhão detetada (Raven Industries, 2025).



Figura 13 - Sensor Augmenta (esquerda); Sensor Augmenta e os cabos que ligam ao isobus trl4396 e monitor (direita).

Após a instalação do sensor na máquina agrícola, procedeu-se à etapa de calibração. O primeiro passo consistiu em ligar o sensor e estabelecer a conexão sem fios, via Wi-Fi e protocolo ISO, para garantir a integração entre o sensor, a máquina e o implemento de distribuição de fertilizante. A regulação do distribuidor de adubo foi ajustada para a relação de engrenagens 17/51, e a largura de trabalho definida em 28 m. Para esta aplicação de calibração, foi determinado um limite específico na plataforma Field OPS New Holland, numa zona utilizada como referência para a parametrização do sensor.

A fertilização em taxa variável em tempo real na área avaliada foi executada no dia 6 de março de 2025, seguindo as prescrições do sensor augmenta. Antes da operação, estabeleceu-se a conexão Wi-Fi entre o sensor e a máquina; em seguida, foi possível aceder à plataforma de operação de campo. Nesta plataforma foram inseridos os dados pertinentes ao experimento, incluindo a regulação do implemento, a largura de aplicação, informações de campo, data e a seleção da operação de interesse, especificamente a aplicação de fertilizante em taxa variável em tempo real.

Para a configuração da operação de aplicação em VRA em tempo real, foram determinados na plataforma os parâmetros apresentados no quadro 4.

Quadro 4 - Parâmetros de configuração para aplicação do fertilizante em VRA.

Parâmetro	Operação/valor definido
Operação	Fertilização em dose variável em tempo real
Tipo de Cultivo	Pastagem
Largura de trabalho	28 metros
Fertilizante utilizado	Nitro 27 - 0 - 0
Dose máxima aplicada	150 kg/ha ⁻¹
Dose mínima aplicada	75 kg/ha ⁻¹

O quadro 4 apresenta os parâmetros configurados na plataforma do sensor óptico aumenta para a execução da operação de FA em VRA em tempo real. A largura de trabalho de 28 metros foi determinada em função da altura de instalação do sensor, garantindo uma leitura adequada e uniforme da área monitorizada. A dose máxima aplicada, de 150 kg/ha, foi estipulada com base em ensaios anteriores, nos quais se verificou que essa quantidade era suficiente para assegurar o desenvolvimento adequado da cultura. A dose mínima, por sua vez, correspondeu a 50% da dose reduzida, sendo definida em campo especificamente para este estudo, de forma a permitir a comparação entre diferentes níveis de aplicação de azoto. A cultura selecionada foi a pastagem, por se enquadrar melhor nos objetivos e parâmetros da investigação. No entanto, apesar de se tratar de uma produção destinada à forragem, esta opção não estava disponível no sistema operacional do sensor, tendo sido, por isso, classificada como pastagem.

O fertilizante Nitro 27–0–0, composto por 27% de N, foi selecionado para suprir as necessidades nutricionais da forragem. As doses mínima e máxima foram definidas com base no potencial produtivo e na variabilidade da biomassa detectada, permitindo ajustes dinâmicos e localizados, de acordo com o estado nutricional das plantas (Figura 14).




Figura 14 - Plataforma com as configurações da fertilização em taxa variável em tempo real.

A dose máxima estabelecida deve corresponder à recomendação do agrónomo responsável; neste caso, foi definida com base no histórico da parcela e em informações de experimentos anteriores.

O operador definiu a percentagem de variação da dose, que podia ser até 50% inferior à dose máxima recomendada. As doses aplicadas foram ajustadas de forma dinâmica pelo sensor, variando entre a dose mínima recomendada e a dose máxima prescrita.

O sensor avaliou e identificou áreas de baixo, médio e alto potencial produtivo. Em zonas de alto potencial, a dose aplicada foi superior, visando atingir a produtividade máxima; em áreas de baixo potencial, a taxa de aplicação foi reduzida, minimizando o desperdício de insumos em locais menos produtivos.

3.4. Sensores Ópticos de Monitorização

3.4.1. Drone MSI Phantom 4 Pro

O plano de voo utilizado para a aquisição das imagens multiespectrais nos momentos I (MSI_I) e momento II (MSI_II) foi previamente definido de forma a garantir a cobertura total e homogénea da área experimental. Os voos foram realizados com altitude constante e trajetórias paralelas, assegurando uma sobreposição longitudinal e lateral adequada entre as imagens (superior a 70%) para permitir o processamento fotogramétrico e a geração de ortomosaicos de elevada precisão. O drone foi programado através de software de planeamento automático, mantendo uma velocidade estável e parâmetros idênticos nos dois momentos de monitorização, de modo a garantir

a comparabilidade dos dados recolhidos. A orientação das linhas de voo foi ajustada segundo a direção predominante do vento e as condições de luminosidade no momento das operações, contribuindo para a qualidade e consistência das imagens obtidas.

O drone multiespectral (MSI) foi utilizado neste estudo no dia 5 de março (Momento I) para monitorizar a área experimental antes da aplicação da fertilização de cobertura. A monitorização foi realizada por volta do meio-dia, período considerado ideal para a aquisição de imagens multiespectrais, uma vez que o ângulo solar se encontra mais elevado e a incidência de sombras é mínima. Esta condição de iluminação reduz a interferência de variações na radiância superficial causadas por diferenças na intensidade luminosa ao longo do dia, permitindo assim a obtenção de dados espectrais mais homogêneos, precisos e comparáveis entre as diferentes zonas da parcela. O modelo DJI Phantom 4 RTK Multiespectral (Da-Jiang Innovations Science and Technology Co., Ltd., Shenzhen, Guangdong, China, 2025) (Figura 15) possuía sistema de transmissão integrado OcuSync HD e estava equipado com um sensor CMOS de 1 polegada, com resolução efetiva de 20 megapixels (MP); as imagens foram processadas em resolução 4K. A câmara multiespectral Phantom 4 (SZ DJI Technology Co., Shenzhen, China) foi utilizada para recolher informações utilizando uma composição RGB, três bandas pancromáticas – azul (B), verde (G) e vermelho (R) – e duas bandas multiespectrais – *red-edge* (RE) e infravermelho próximo (NIR) –, a 2 MP com obturador global, num suporte estabilizado de 3 eixos, compondo seis bandas que cobrem diferentes faixas do espectro de luz.

No dia 27 de março (Momento II), novas imagens foram obtidas, seguindo as mesmas condições e procedimentos de aquisição utilizados no momento I, posteriormente analisadas no software QGIS v.3.28.4. Com base nos valores de NDVI observados, foram determinadas as zonas de baixa, média e alta produtividade, com o objetivo de definir os pontos para a coleta das amostras.

Nos momentos de aquisição MSI_I e MSI_II, não foi realizada qualquer calibração radiométrica ou geométrica adicional. No entanto, todas as bandas espectrais utilizadas para o cálculo dos índices vegetativos foram obtidas a partir do mesmo sensor multiespectral embarcado no drone, garantindo a consistência interna das medições. Assim, assegurou-se que os dados recolhidos apresentassem coerência espectral entre

os diferentes voos e condições de luz, à semelhança do procedimento descrito por Silva et al. (2025).

Este cuidado metodológico é fundamental para que as comparações entre os momentos de aquisição sejam válidas, uma vez que a uniformidade do sensor minimiza variações decorrentes de fatores externos, como a intensidade luminosa ou as condições atmosféricas. Dessa forma, a consistência radiométrica foi mantida sem a necessidade de aplicar correções adicionais em pós-processamento, assegurando a fiabilidade dos valores de reflectância utilizados na análise espectral.



Figura 15 - Drone DJI Phantom 4 RTK Multispectral (à esquerda). Sistema utilizado para manipulação do drone em campo, tablet e controle (à direita).

3.4.2. Sensor Ótico GS®

O GS® (Trimble Inc., Sunnyvale, Califórnia, EUA, 2025) (Figura 16) foi utilizado como sensor óptico portátil ou montado em máquinas agrícolas para medir a refletância da vegetação e avaliar a saúde das plantas em tempo real. O GS® emite pulsos de luz vermelha (Red: ~660 nm) e infravermelha próxima (NIR: ~770–800 nm) sobre a vegetação. A planta absorve parte dessa luz e reflete outra parte, dependendo do seu estado fisiológico.

- Luz vermelha (Red, ~660 nm): A clorofila absorveu fortemente essa luz para a fotossíntese, de modo que folhas saudáveis apresentaram baixa refletância nesta faixa.
- NIR (~770–800 nm): As células das folhas refletiram fortemente essa luz devido à estrutura interna do tecido vegetal; quanto mais saudável e densa a vegetação, maior foi essa refletância.
- Valores próximos de +1 (0,7 a 1,0): indicaram vegetação densa e saudável.
- Valores próximos de 0: indicaram vegetação escassa, stress hídrico ou solos descobertos.
- Valores negativos: geralmente indicaram superfícies sem vegetação (água, rochas, solo nu).



Figura 16 - Sensor óptico GS[®], modelo de sensor portátil.

Neste estudo, o sensor óptico proximal GS[®] foi utilizado para a recolha dos dados de reflectância da forragem em condições de luminosidade estável, num período do dia em que a radiação solar apresentava menor interferência, de forma a evitar sombras e reflexos excessivos que pudessem comprometer a precisão das medições. O equipamento foi operado à altura recomendada pelo fabricante, de aproximadamente 1 metro acima do dossel da cultura, assegurando a consistência na leitura dos índices vegetativos. Antes do início das medições, procedeu-se à calibração do sensor em superfície de referência neutra, garantindo a fiabilidade dos valores registados. As leituras foram realizadas em 20 pontos de amostragem previamente definidos na área

experimental, correspondentes às zonas de recolha de biomassa, de modo a permitir a correlação directa entre os dados espectrais e as variáveis produtivas e nutricionais analisadas.

3.5. Coleta inteligente de amostras em campo

3.5.1. Criação da malha de amostragem

O número de pontos amostrais, bem como os procedimentos de análise espacial e interpolação de dados, foram definidos de forma a assegurar a representatividade da área experimental, a robustez estatística e a fiabilidade das estimativas espaciais obtidas. A definição de 20 pontos amostrais (dos quais 19 foram utilizados nas análises, após a exclusão de um outlier) teve por objetivo captar a variabilidade espacial existente na parcela, considerando diferenças locais de relevo, textura e fertilidade do solo, que influenciam diretamente a produtividade e o estado nutricional da cultura (McBratney et al., 2003; Vieira et al., 2010). Este número de pontos constitui um compromisso entre a resolução espacial necessária para caracterizar padrões locais e as limitações práticas associadas ao tempo de campo e às análises laboratoriais. Segundo Cambardella et al. (1994) e Isaaks & Srivastava (1989), entre 15 e 30 amostras bem distribuídas são geralmente suficientes para ajustar modelos de variograma de forma fiável em áreas experimentais homogêneas, permitindo a caracterização da dependência espacial de variáveis agronómicas.

O mapa com a distribuição dos pontos amostrais foi gerado a partir dos dados do drone no momento II e das taxas prescritas pelo sensor Augmenta, garantindo a correspondência espacial entre as zonas de manejo identificadas e as áreas de coleta. Os pontos amostrais foram distribuídos de modo sistemático e estratificado, cobrindo toda a área experimental e assegurando a representatividade das diferentes zonas observadas. Cada ponto foi georreferenciado com recurso a um recetor GNSS/RTK, assegurando precisão centimétrica e permitindo a integração directa com os dados obtidos pelos sensores remoto e pelas taxas prescritas pelo sistema Augmenta. Esta abordagem permitiu que as medições espectrais e as observações de campo estivessem espacialmente alinhadas, facilitando a análise conjunta e a modelação da variabilidade espacial das variáveis estudadas.

A análise espacial foi conduzida com base em métodos geoestatísticos, através do cálculo e ajuste do variograma empírico, que descreve a relação entre a semivariância e a

distância entre as observações (Journel & Huijbregts, 1978; Vieira et al., 1983). O variograma empírico foi ajustado a modelos teóricos (esférico, exponencial ou gaussiano), selecionados de acordo com a melhor adequação visual e a minimização do erro de ajuste. Os parâmetros obtidos (nugget, sill e range) permitiram avaliar o grau de dependência espacial e orientar o raio de busca utilizado na interpolação. Foi também verificada a presença de anisotropia, avaliando-se o comportamento do variograma em diferentes direções, de modo a identificar possíveis variações estruturais no campo experimental.

A interpolação espacial dos dados foi realizada por krigagem ordinária, método amplamente reconhecido pela sua capacidade de gerar estimativas não enviesadas e de incorporar a estrutura espacial modelada pelo variograma (Isaaks & Srivastava, 1989; Goovaerts, 1997). A escolha da krigagem, em detrimento de métodos determinísticos como a ponderação inversa da distância (IDW), justifica-se pela sua robustez estatística e pela possibilidade de quantificar a incerteza associada às estimativas (Oliver & Webster, 2015). Os parâmetros da krigagem, incluindo o modelo do variograma, o raio de busca e o número de vizinhos, foram definidos com base nas características do campo e no alcance espacial identificado, garantindo coerência nas estimativas. A resolução da grelha interpolada foi ajustada à densidade de amostragem e à resolução espacial do sensor multiespectral, evitando a criação de padrões artificiais (Moral, 2010).

A validação das superfícies interpoladas foi efetuada através de validação cruzada do tipo *leave-one-out*, utilizando indicadores como o erro médio, o erro médio absoluto e a raiz do erro quadrático médio, que permitem avaliar o viés e a precisão das estimativas (Deutsch & Journel, 1998). Foram ainda produzidos mapas de variância de krigagem, representando a incerteza associada a cada estimativa e fornecendo informação adicional sobre a fiabilidade espacial dos resultados. Durante a análise exploratória, foi identificado um ponto amostral com valores espectrais e produtivos inconsistentes, sem justificativa físico-agronómica plausível, que afetava negativamente o ajuste do variograma, aumentando o *nugget* e alterando o *range*. Após a sua exclusão, constatou-se uma melhoria significativa na coerência espacial e na precisão das estimativas, motivo pelo qual o ponto foi removido das análises finais.

O mapa resultante da krigagem (Figura 17) foi integrado com os índices de vegetação obtidos pelas imagens multiespectrais MSI_II e com as taxas prescritas pelo sensor Augmenta, permitindo estabelecer correlações e avaliar a consistência entre diferentes

escalas e métodos de observação. Essa integração possibilitou a validação cruzada entre os dados de campo e de sensoriamento remoto, bem como a construção de modelos preditivos para estimar variáveis produtivas e nutricionais a partir de índices espectrais. Assim, a combinação entre um plano de amostragem adequado, uma análise espacial rigorosa e o uso de métodos geoestatísticos de interpolação permitiu caracterizar de forma precisa a variabilidade espacial da cultura e fundamentar as análises subsequentes de eficiência da fertilização e resposta da forragem às diferentes doses aplicadas.




Figura 17- Localização dos pontos de amostragem, posicionados de acordo com as taxas prescritas pelo sensor Augmenta.

3.5.2. Material de recolha das amostras em campo

Para a obtenção de amostras em campo, foram utilizados os seguintes materiais: um gabarito metálico quadrado de 0,25 m² para delimitar a área de interesse (AdI) onde a amostra foi coletada (Figura 18A); o sensor óptico GS[®] para a obtenção dos valores dos índices NDVI (Figura 18B); uma cortadeira elétrica para o corte e extração da biomassa (Figura 18C); um saco para pesagem da matéria verde úmida em campo (Figura 18D); uma balança para pesagem da amostra no local (Figura 18E); e um saco plástico para armazenamento das amostras (Figura 18F).



Figura 18 - (A) gabarito metálico quadrado (B) sensor GS®; (C) tesoura elétrica; (D) saco plástico; (E) balança; (F) saco plástico.

3.5.3. Recolha de amostras digitais

Para além da recolha de valores obtidos pelo AAI e drone nas Adl's delimitadas, foram feitas as leituras dos valores de NDVI com o sensor GS® (Figura 19).



Figura 19 - Coleta dos valores de NDVI com o sensor óptico GS®.

3.5.3. Recolha de amostras vegetais

Em seguida, o material vegetal foi cortado com uma tesoura elétrica e acondicionado em um saco plástico previamente tarado (peso do saco: 0,08 kg), para a pesagem da massa verde das amostras em condições de campo. Essas amostras foram utilizadas em laboratório para determinação de N% e proteína bruta (Figura 20).



Figura 20 - Corte do material vegetal com a tesoura elétrica e pesagem da matéria verde em condições de campo.

Após a pesagem da matéria verde em campo, as amostras foram armazenadas em sacos plásticos individuais, devidamente identificados (Figura 21), para registro da massa verde. Posteriormente, as amostras foram colocadas em estufa por um período de 24 horas a 60 °C para a remoção da umidade. Após esse processo, as amostras foram novamente pesadas para a determinação da massa seca.



Figura 21 - Armazenamento das amostras em sacos plásticos.

3.6. Análises laboratoriais

3.6.1. Umidade Residual

A determinação da umidade residual foi realizada em laboratório pelo método gravimétrico. As amostras foram submetidas aos processos de trituração e crivagem (Figura 22) e, em seguida, armazenadas em sacos de papel devidamente identificados. Para a análise da umidade residual, foram utilizadas cápsulas de porcelana, cada uma identificada conforme a quantidade de amostras. As cápsulas foram inicialmente colocadas em estufa por 40 minutos a 105 °C, a fim de eliminar a umidade superficial.

Após esse período, foram transferidas para um dessecador para resfriamento sem absorção de umidade. Depois de aproximadamente 20 minutos, cada cápsula foi pesada e o valor registrado. Posteriormente, cerca de 2 g de material vegetal foram colocados em cada cápsula. As amostras permaneceram em estufa por 4 horas a 105 °C, sendo posteriormente resfriadas e pesadas novamente. A diferença entre o peso da amostra verde e da amostra seca representou a umidade residual (Figura 23).



Figura 22 - Material vegetativo triturado passando pelo processo de crivagem.




Figura 23 - Amostras de massa vegetal em estufa; Amostras no dessecador para resfriamento; Pesagem da amostra.

3.6.2. Determinação de N e Proteína Bruta

Para o processo de determinação do teor de N e da proteína bruta, as amostras foram pesadas em aproximadamente 0,5 gramas e adicionadas em tubos de ensaio (Figura 25).



Figura 24- Massa vegetal pesada em 0,5g nos tubos de digestão.

O processo seguiu mediante o esquema de Weende, que se baseia na quantificação de N total presente na amostra por meio do método de Kjeldahl (Horwitz, 2006). Envolveu as seguintes etapas principais:

- **Digestão:** Aproximadamente 0,5 g de cada amostra de material orgânico foram pesadas e colocadas num tubo de digestão, ao qual se adicionaram 18 ml de ácido sulfúrico concentrado (H_2SO_4). Para acelerar o processo, foi adicionada uma mistura catalisadora de 1 l g composta por 800 g de sulfato de sódio (Na_2SO_4), 40 g de sulfato de cobre penta-hidratado ($CuSO_4 \cdot 5H_2O$) e 1,6 g de selênio (Se) (Figura 25). As amostras permaneceram no digestor a 400 °C durante 2 horas.
- **Destilação:** Após a digestão, as amostras foram resfriadas e neutralizadas pela adição de hidróxido de sódio a 30 % (NaOH). Nesta etapa, o sulfato de amônio foi convertido em amônia gasosa (NH_3). A amônia libertada foi então destilada e recolhida num recipiente contendo 50 mL de ácido bórico ($B(OH)_3$), mantendo a destilação até atingir um volume total de 150 mL (Figura 25).
- **Titulação:** A substância destilada foi titulada (Figura 28) com uma solução de ácido clorídrico (HCL) até se obter uma coloração rosa permanente. O volume de HCL consumido no processo foi registado pelo titulador e anotado (Figura 25).



Figura 25 – Adição da mistura catalisadora; Destilação; Titulação.

3.6.3 Cálculo e Expressão dos Resultados

O teor de N total presente nas amostras analisadas é dado pela expressão:

$$N_t = V/m \cdot f \cdot 100 / (100 - H_r)$$

em que:

N_t – Teor de N total (N) da amostra, expresso em %;

V – Volume de ácido clorídrico gasto na titulação, em ml;

m – Massa da toma de amostra (6.l), em g;

f - Concentração do ácido clorídrico, em normalidade;

H_r – Humidade residual.

Para determinação do teor de proteína bruta o teor total de N foi multiplicado pelo fator convencional 6,25.

Este cálculo também permite calcular a quantidade de rendimento de PByeld por unidade de área (PB_y ; kg PByeld ha^{-1})

$$NU_p = MS \times N\%$$

Onde:

NU_p: Teor de N absorvido pela planta

MS: Matéria seca vegetal

N%: Conteúdo de nitrogênio da planta

3.7. Tratamento Estatístico

Inicialmente, os dados foram organizados e analisados no software R 4.3.2, sendo realizadas análises descritivas univariadas com o auxílio do pacote psych v. 2.4.3 (CRAN Repository). Foram obtidas medidas de tendência central e de dispersão (média, mediana, desvio padrão e coeficiente de variação) para as variáveis MV, MS, N, PB, PB_{yield}, NU_p, bem como para os índices espectrais NDVI_Aug, MSI-I, MSI-II (drone) e GSK (Índice gerado pelo sensor GS[®]).

A normalidade das variáveis dependentes foi verificada através do teste de Shapiro-Wilk para cada uma das variáveis contínuas. Adicionalmente, foram gerados histogramas para visualização da distribuição dos dados e boxplots para identificar possíveis outliers e comparar a distribuição das variáveis em função dos tratamentos.

3.7.1. Análise de Agrupamento

Com o intuito de identificar padrões nos dados e possíveis agrupamentos naturais entre os pontos amostrados, procedeu-se à realização de uma classificação. Os agrupamentos foram visualizados através de dendrograma.

As variáveis com distribuição não normal foram analisadas pelo teste de Kruskal–Wallis, enquanto aquelas com distribuição normal foram analisadas mediante ANOVA, conforme apresentado na figura 26.




Figura 26 - Metodologia estatística utilizada (Silva et al., 2024).

Os coeficientes de correlação foram classificados de acordo com a sua intensidade e significância estatística. A análise de sensibilidade foi efetuada utilizando modelos matemáticos adequados para simular as respostas das variáveis económicas. Os resultados foram apresentados graficamente, de forma a facilitar a interpretação e a comparação dos impactos entre os diferentes cenários avaliados.

Para explorar as relações entre os índices espectrais captados pelos sensores e os indicadores agronómicos das culturas, realizou-se uma análise de correlação bivariada utilizando o coeficiente de correlação de Pearson. Antes da análise, as variáveis categóricas foram removidas do conjunto de dados, e foi construída a matriz de correlação apenas para as variáveis contínuas. A visualização gráfica das correlações foi efetuada através de matrizes de dispersão (scatter plots).

4. Resultados

4.1. Estatística descritiva e inferencial

A análise foi conduzida com o objetivo de caracterizar e comparar os dados obtidos a partir da amostragem de 20 pontos numa área experimental de 1 ha cultivada com azevém anual. Os parâmetros analisados incluíram matéria verde (MV, kg ha⁻¹), matéria seca (MS, kg ha⁻¹), teor de N (%), proteína bruta (PB, %), proteína bruta total (PByield,

kg ha⁻¹), N absorvido (NUp, kg ha⁻¹), índice de vegetação NDVI obtido pelo sensor Augmenta (NDVI_Augm) e os índices espectrais MSI_I, MSI_II e GSK.

Inicialmente, foi realizada uma análise descritiva para cada variável, considerando medidas de tendência central e dispersão. Em seguida, aplicou-se o teste de Shapiro-Wilk para verificar a normalidade dos dados. De acordo com o resultado deste teste, as variáveis com distribuição normal foram submetidas à análise de variância (ANOVA), enquanto as que apresentaram distribuição não normal foram analisadas através do teste não paramétrico de Kruskal-Wallis. Estas análises permitiram avaliar a variabilidade espacial dos atributos estudados e a sua relação com o desenvolvimento da cultura em diferentes pontos da área experimental.

Quadro 5 - resultados da análise da estatística descritiva e inferencial.

	MV (kg ha ⁻¹)	MS (kg ha ⁻¹)	%azoto	PB (%)	PB (kg ha ⁻¹)	NUp (kg ha ⁻¹)	NDVI_ Augm	MSI_I	MSI_II	GSK
no. Samples	19	19	19	19	19	19	19	19	19	19
min	5800.00	501.54	1.49	9.31	54.72	8.76	0.40	0.50	0.44	0.57
max	20400.00	5079.31	3.56	22.23	664.92	106.39	0.44	0.72	0.85	0.85
mean	11033.33	2402.87	2.22	13.87	329.25	52.68	0.42	0.65	0.72	0.72
median	10000.00	2130.20	2.12	13.23	279.70	44.75	0.42	0.64	0.72	0.74
sd	4100.07	1259.07	0.53	3.31	165.05	26.41	0.01	0.05	0.10	0.07
cv	37.16	52.40	23.89	23.89	50.13	50.13	2.69	8.03	14.13	9.49

Com base nos dados apresentados no quadro 5, que resume os resultados obtidos a partir de 19 pontos amostrados na área de estudo, procedeu-se a uma análise descritiva com o objetivo de compreender a variabilidade dos parâmetros produtivos, nutricionais e espectrais da cultura. Embora os dados tenham sido inicialmente recolhidos em 20 pontos, apenas 19 foram considerados válidos para a análise, uma vez que um ponto foi identificado como outlier nas análises estatísticas exploratórias.

Observou-se que a MV variou entre 5.800,00 e 20.400,00 kg ha⁻¹, com média de 11.033,33 kg ha⁻¹ e coeficiente de variação (cv) de 37,16%, indicando uma variação moderada a elevada entre os pontos de amostragem. A MS apresentou média de 2.402,87 kg ha⁻¹, com valores mínimos e máximos de 501,54 e 5.079,31 kg ha⁻¹, respetivamente, além de um elevado cv de 52,40%, sugerindo significativa heterogeneidade no acúmulo de biomassa seca, possivelmente relacionada à variabilidade da fertilidade ou umidade do solo e densidade da forragem.

Em relação à composição nutricional, o teor de N (%) variou de 1,49% a 3,56%, com média de 2,22% e cv de 23,89%, evidenciando diferenças na eficiência de absorção de N

entre os pontos. A PB, tanto em percentagem quanto em kg ha^{-1} , também apresentou ampla variação: de 9,31% a 22,23% (média de 13,87%) e de 54,72 a 664,92 kg ha^{-1} (média de 329,25 kg ha^{-1}), com cv elevado de 50,13%. Esta amplitude reflete variações expressivas na qualidade nutricional da forragem produzida.

O NUp apresentou média de 52,68 kg ha^{-1} , oscilando entre 8,76 e 106,39 kg ha^{-1} , com cv de 50,13%, indicando significativa variabilidade na eficiência de uso do N aplicado.

Quanto aos índices espectrais, o NDVI_Augmenta apresentou baixa variação, com valores entre 0,40 e 0,44 (média de 0,42 e cv de apenas 2,69%), sugerindo homogeneidade no vigor vegetativo medido por este índice, possivelmente devido a limitações do NDVI em detectar diferenças subtis em estádios avançados de desenvolvimento da cultura. Estudos como o de Vian et al. (2023) observaram que, em estádios mais avançados do milho (V7 e V8), o NDVI tende a saturar, tornando-se menos eficaz na distinção de diferenças no potencial produtivo entre áreas. Além disso, conforme destacado por EOSDA (2022), a saturação do NDVI ocorre quando a reflectância no infravermelho próximo continua a aumentar, enquanto a reflectância no vermelho se mantém constante, limitando a capacidade do índice em refletir com precisão a saúde da vegetação em estágios avançados.

Por outro lado, os índices MSI I e MSI II apresentaram maior variação, especialmente o MSI II, com cv de 14,13%. O índice GSK, por sua vez, apresentou média de 0,72 com cv de 9,49%, indicando relativa homogeneidade, embora ainda exista variação suficiente para justificar a sua análise.

Em síntese, os parâmetros com maior variação, como MS, PB (kg ha^{-1}) e NUp, destacam-se por evidenciar a heterogeneidade espacial da área experimental. Estas variações reforçam a importância da adoção de práticas de manejo site-specific, especialmente no que se refere à FA, visando maior eficiência agronômica e sustentabilidade do sistema produtivo.

O dendrograma (Figura 30) foi gerado a partir da análise de agrupamento hierárquico dos 19 pontos amostrados, sem outliers, utilizando o método de ligação de Ward. A formação de quatro grupos distintos indica a existência de variabilidade espacial nas características analisadas, que incluem variáveis produtivas (MV, MS), nutricionais (PB, % de N, NUp) e índices espectrais (NDVI, MSI I, MSI II, GSK) (Figura 30).




Figura 27 - Cluster Dendrogram.

O dendrograma apresentado na figura 30 representa o resultado da análise de agrupamento hierárquico, realizada com o método de ligação Ward.D, que agrupou os pontos amostrados de acordo com a semelhança multivariada entre os parâmetros produtivos, nutricionais e espectrais da cultura. O eixo vertical (Height) indica a distância ou dissimilaridade entre os grupos, ou seja, quanto maior o valor, mais distintos são os grupos entre si. A partir do corte aplicado ao dendrograma, representado pelas caixas vermelhas, foi possível identificar cinco grupos principais de pontos amostrados. O primeiro grupo é constituído pelos pontos 5, 7, 8 e 9, que apresentam a menor distância de ligação, indicando elevada semelhança interna entre eles. Estes pontos correspondem a locais com características produtivas e espectrais muito próximas, sugerindo condições de resposta da cultura. O segundo grupo é formado pelos pontos 11, 15, 3, 12, 16, 6 e 14, sendo um dos grupos mais numerosos e com dissimilaridade moderada. Representa uma zona relativamente homogênea da área experimental, com valores médios para os parâmetros avaliados, podendo estar associada a uma região de produtividade e estado

nutricional intermédio. O terceiro grupo inclui os pontos 4 e 19 e, embora pequeno, destaca-se por estar isolado antes da fusão com os grupos vizinhos, o que indica que possui características particulares dentro do conjunto de dados. No entanto, o ponto 19 apresentou valores extremos em alguns parâmetros e foi identificado como outlier, sendo posteriormente excluído das análises estatísticas subsequentes. O quarto grupo é composto pelos pontos 10, 13 e 17 e apresenta uma ligação relativamente próxima ao quinto grupo, embora com diferenças subtis, possivelmente associadas a variações de fertilidade ou de resposta espectral à adubação. Por fim, o quinto grupo é formado pelos pontos 1, 2 e 18, que demonstram forte correlação entre si, mas com uma distância relativamente elevada em relação aos restantes grupos, o que sugere um comportamento distinto, provavelmente associado a áreas com características produtivas mais elevadas, com valores espectrais diferenciados, refletindo uma resposta particular da cultura às condições ambientais ou de manejo. De forma geral, o dendrograma permitiu identificar padrões de semelhança entre os pontos amostrados, agrupando-os em conjuntos coerentes do ponto de vista produtivo e nutricional.

Essa estratificação espacial reforça a presença de variabilidade intra-parcelar no campo experimental, confirmando a importância do uso de ferramentas de Agricultura de Precisão, como sensores ópticos e análises multivariadas, para identificar zonas de manejo específicas e otimizar a aplicação de insumos.




Figura 28 - Análise exploratória por meio de boxplots.

Nos boxplots apresentados na figura 31, observa-se que a MV e MS demonstram ampla variação, refletindo diferenças no crescimento e desenvolvimento das forragens em função do manejo azotado e das condições microambientais. A dispersão mais acentuada em MS indica maior heterogeneidade na acumulação de biomassa seca entre os pontos avaliados. As variáveis nutricionais, teor de azoto total (TN) e PB, mostram menor amplitude interquartil e ausência de outliers significativos, sugerindo maior uniformidade na composição química do material vegetal, apesar da variação produtiva observada. A variável PByield, que integra produtividade e qualidade, apresenta distribuição relativamente equilibrada, enquanto a NUp revela maior variabilidade, evidenciando diferenças na capacidade das plantas em converter o azoto aplicado em proteína.

Entre os índices espectrais, o NDVI_Augm apresenta distribuição homogênea, com ligeira dispersão de valores, indicando pouca variação da resposta espectral vegetativa. Por outro lado, os índices MSI_I e MSI_II, correspondentes ao NDVI obtido por VANT antes e depois da aplicação do fertilizante, respetivamente, permitem observar a evolução do estado da cultura ao longo do ciclo. O MSI_I mostra menor variação, refletindo condições iniciais relativamente homogêneas, enquanto o MSI_II apresenta ligeiro aumento na mediana e dispersão mais ampla, indicando resposta diferenciada das

plantas à fertilização, com zonas de maior incremento no vigor vegetativo após a aplicação de N. O índice GSK apresenta comportamento semelhante, reforçando a estabilidade das medições espectrais no conjunto dos pontos.

De forma geral, os resultados evidenciam heterogeneidade espacial moderada nas variáveis produtivas e uma resposta espectral clara à FA.

4.2. Teste de normalidade e testes de significância

A análise estatística das variáveis estudadas incluiu a aplicação do teste de normalidade de Shapiro-Wilk, seguido da escolha dos testes de significância adequados conforme o comportamento dos dados. O objetivo foi verificar a distribuição dos dados para definir se seriam utilizados testes paramétricos (como a ANOVA) ou não paramétricos (como o Kruskal-Wallis).

Quadro 6 - Teste de normalidade e teste de significância.

	Shapiro-Wilk (p-value)	Teste de significância
MV (kg ha ⁻¹)	0,0128	Kruskal-Wallis
MS (kg ha ⁻¹)	0,0354	Kruskal-Wallis
%N	0,0066	Kruskal-Wallis
PB (%)	0,0066	Kruskal-Wallis
PB (kg ha ⁻¹)	0,4779	ANOVA
NUp (kg ha ⁻¹)	0,4779	ANOVA
NDVI_Augm	0,2633	ANOVA
MSI_I	0,0532	ANOVA
MSI_II	0,0451	Kruskal-Wallis
GSK	0,5635	ANOVA

Os resultados do teste de Shapiro-Wilk indicaram que as variáveis MV, MS, %N, PB (%) e MSI_II apresentaram valores inferiores a 0,05, o que demonstra que seus dados não seguem uma distribuição normal. Para essas variáveis, optou-se pela aplicação do teste de Kruskal-Wallis, que não exige normalidade dos dados.

Por outro lado, as variáveis PB (kg ha⁻¹), NUp (kg ha⁻¹), NDVI_Augm, MSI_I e GSK apresentaram valores superiores a 0,05, indicando que os dados podem ser

considerados normalmente distribuídos. Assim, foi utilizada a ANOVA para essas variáveis.

A figura 29 apresenta os histogramas das variáveis analisadas no estudo, fornecendo uma representação visual da distribuição de frequência dos dados.




Figura 29 - Histogramas das variáveis analisadas.

As variáveis MV, MS, TN e PB (%) apresentaram distribuições assimétricas, com tendência à direita (assimetria positiva), evidenciando que a maior parte dos valores está concentrada em faixas mais baixas, com alguns valores extremos elevados. Isso confirma os resultados do teste de normalidade de Shapiro-Wilk, que indicaram distribuição não normal para essas variáveis.

As variáveis PByield e NUp também mostraram certa assimetria, embora de forma menos acentuada. Essa distribuição reforça a decisão de aplicar testes não paramétricos, como o de Kruskal-Wallis, nessas variáveis em caso de dúvida quanto à homogeneidade da variância ou da forma da curva.

Por outro lado, variáveis como NDVI_Augm, MSI_I, MSI_II e GSK apresentaram distribuições mais simétricas e próximas da normalidade. Os histogramas dessas variáveis mostram uma dispersão de dados relativamente uniforme em torno da média, o que está de acordo com os valores do teste de Shapiro-Wilk, que não rejeitaram a hipótese de normalidade. Isso justificou o uso da análise ANOVA nesses casos.

4.3. Matriz de correlação

Para compreender a relação entre as variáveis dependentes do estudo, foi criada uma matriz de correlação, com resultados apresentado na figura 30.




Figura 30 - Matriz de Correlação.

A análise da matriz de correlação de Spearman (Figura 33) evidenciou relações significativas entre variáveis agrônomicas e índices espectrais, sendo a MV um dos principais indicadores de desempenho produtivo. Observou-se correlação muito forte entre MV e MS ($R^2 = 0,85$), PB ($R^2 = 0,95$), produção PByield ($R^2 = 0,92$) e NUp ($R^2 = 0,85$), indicando que o incremento em biomassa está diretamente associado ao aumento

na qualidade nutricional e eficiência de absorção de nutrientes. A variável NUp também apresentou correlação moderada com PB e PByield ($R^2 = 0,42$), reforçando a relevância da nutrição azotada na formação da composição proteica da forragem. No que tange aos índices espectrais, o MSI II destacou-se com correlação moderada com PB ($R^2 = 0,58$) e forte com o parâmetro GSK ($R^2 = 0,70$), evidenciando sua aplicabilidade no monitoramento remoto de atributos fisiológicos das plantas.

A matriz de correlação (Figura 33) indica que o NDVI_Augm teve correlações positivas e moderadas com importantes variáveis agronômicas, tais como MV ($R^2 = 0,52$), PB ($R^2 = 0,38$), PByield ($R^2 = 0,33$), NUp ($R^2 = 0,33$) e %N ($R^2 = 0,38$). Esses resultados demonstram que o AAI foi eficiente na prescrição da FA.

No que diz respeito à avaliação da resposta da cultura por meio dos índices MSI_II e GSK, observou-se que ambos apresentaram correlações moderadas a fortes com variáveis fisiológicas e nutricionais. O MSI_II correlacionou-se com PB ($R^2 = 0,58$), PByield ($R^2 = 0,53$), NUp ($R^2 = 0,53$) e %N ($R^2 = 0,58$), sugerindo que este índice foi sensível à variação na absorção e acúmulo de N induzida pela adubação em taxa variável. De maneira semelhante, o GSK apresentou correlações relevantes com MV ($R^2 = 0,47$), PB ($R^2 = 0,58$), PByield ($R^2 = 0,53$), NUp ($R^2 = 0,55$) e %N ($R^2 = 0,58$), evidenciando sua capacidade de refletir alterações no estado nutricional da planta. Ambos os índices apresentaram correlação fraca com o NDVI_Augm ($R^2 = 0,24$).

4.4. Mapas criados a partir dos pontos de amostragem

Os mapas de distribuição espacial da produtividade de MV e do teor de PB da parcela cultivada com azevém, submetida à adubação azotada em taxa variável estão expressos na figura 31, na imagem (a), observa-se a variabilidade espacial da MV (kg ha^{-1}), com destaque para áreas de maior acúmulo de biomassa localizadas predominantemente nas regiões central e sul da parcela experimental. As zonas com tonalidades mais escuras representam os maiores valores de produtividade, variando entre 18512,54 e 17330,21 kg ha^{-1} , enquanto as áreas mais claras indicam menor desempenho produtivo, inferior a 7467,67 kg ha^{-1} . Na imagem (b), é apresentada a distribuição espacial do teor de proteína

bruta (%), com maior concentração de PB nas regiões norte e sudoeste da área experimental, evidenciada pelas colorações mais escuras. Os teores variaram entre 20,79% e 10,81%, refletindo o efeito da adubação azotada sobre a qualidade nutricional da forrageira.




Figura 31 - (a) Distribuição espacial da MV da cultura, medida em quilogramas por hectare (kg ha^{-1}). (b) Distribuição espacial do teor de PB da forrageira.

A figura 32 apresenta os mapas de distribuição espacial da produtividade de PByield e da NUp na forrageira submetida à adubação azotada em taxa variável. Na imagem (a), observa-se a variabilidade espacial da produtividade de PByield (kg ha^{-1}), com valores superiores (591,31 a 517,62 kg ha^{-1}) concentrados nas regiões central e sudeste da área experimental, evidenciados pelas tonalidades mais escuras. As regiões mais claras, situadas ao norte e em partes do sul da área, indicam menor rendimento de proteína, com valores inferiores a 124,59 kg ha^{-1} . Já na imagem (b), visualiza-se a distribuição espacial da NUp, expressa em kg de proteína bruta por kg de N aplicado. As zonas de maior eficiência (9,61 a 8,63 kg kg^{-1}) estão concentradas principalmente no setor central e sudoeste da parcela, enquanto os menores valores de eficiência (< 1,93 kg kg^{-1}) ocorrem nas bordas norte e sul da área.




Figura 32 - (a) Distribuição espacial da PByield. (b) Distribuição espacial da NUp.

A figura 33 apresenta o mapa de distribuição espacial dos valores de NDVI obtidos por meio do sensor óptico GS®. Os valores de NDVI variaram entre 0,60 e 0,82, refletindo diferenças no vigor vegetativo da forrageira em resposta à adubação azotada em taxa variável. As regiões com maiores valores de NDVI (0,82 a 0,76), representadas pelas tonalidades mais escuras, concentram-se nas áreas centrais e nordeste da parcela experimental, indicando maior densidade de biomassa e atividade fotossintética. Por outro lado, as áreas com menores valores (inferiores a 0,67), evidenciadas pelas cores alaranjadas e amareladas, estão localizadas principalmente nas regiões sul e sudeste, sugerindo menor desenvolvimento das plantas.




Figura 33 - Distribuição espacial dos valores de NDVI GSK.

4.5. Mapa de zonas homogêneas de taxa prescritas

A figura 34 apresenta o mapa de zonas homogêneas de taxas de FA prescritas pelo sensor óptico Augmenta. As zonas foram delimitadas com base na variabilidade espacial observada na área experimental, agrupando regiões com características agronômicas semelhantes, a fim de otimizar a aplicação de insumos. As taxas de fertilizante prescrito variaram de 0,5 a 0,9 (valores relativos), distribuídas em quatro classes. As áreas com maiores taxas (0,8 a 0,9), representadas pelas tonalidades mais escuras, estão concentradas principalmente no setor sul da área, indicando regiões com maior demanda nutricional. Em contrapartida, as zonas com menores taxas (0,5 a 0,6), em tons mais claros, estão localizadas de forma fragmentada ao longo da área, sugerindo menor necessidade de adubação.




Figura 34 - Mapa de zonas homogêneas de taxas de fertilização prescritas pelo sensor Augmenta.

Para detalhar ainda mais a aplicação em taxa variável, o quadro 7 apresenta as doses totais de fertilizante aplicadas por zona homogênea, juntamente com uma comparação com um cenário hipotético de aplicação em taxa fixa.

Quadro 7 - Doses de fertilizante aplicada na parcela.

Classe	Ensaio	Área (ha)	Representatividade (%)	Dose de fertilizante a aplicar (kg ha^{-1})	Fertilizante gasto por classe (kg)
Testemunho	Taxa fixa	1,5	100	150	225
1	Taxa variável	0,002	0,14	90	0,180
2		0,017	1,18	105	1,785
3		0,741	49,39	120	88,920
4		0,739	49,29	135	99,765

O quadro 7 apresenta informações sobre a área, o percentual de representatividade, a dose de fertilizante recomendada por hectare e o total aplicado em cada zona homogênea, conforme a estratégia de aplicação VRA. Para efeito de comparação, inclui-se uma linha com a Taxa Fixa Hipotética, que simula a aplicação uniforme de 150 kg ha^{-1} em toda a área de 1,5 hectares, totalizando um consumo de 225 kg de fertilizante.

Na estratégia de aplicação em VRA, a área foi segmentada em quatro classes (1, 2, 3 e 4), conforme as recomendações geradas pelo sensor Augmenta. Cada classe reflete um nível distinto de necessidade nutricional, com doses de fertilizante que variam entre 90 kg ha^{-1} para a Classe 1 e 135 kg ha^{-1} para a Classe 4. Apesar das Classes 1 e 2 corresponderem a áreas muito reduzidas (0,002 ha e 0,017 ha, respectivamente), as Classes 3 e 4 abrangeram praticamente toda a área da parcela, representando cerca de 50% cada.

A quantidade total de fertilizante aplicada com a estratégia VRA foi obtida somando-se os valores utilizados em cada classe: 0,180 kg na Classe 1, 1,785 kg na Classe 2, 88,920 kg na Classe 3 e 99,765 kg na Classe 4, totalizando 190,65 kg. Esse resultado evidencia uma redução significativa no uso de fertilizante em comparação à aplicação em taxa fixa. Especificamente, a aplicação em taxa variável proporcionou uma economia de 34,35 kg de fertilizante na área de 1,5 hectares, o que equivale a uma redução de 22,9 kg por hectare. Com base na dose recomendada de 150 kg ha^{-1} , o uso do sensor Augmenta possibilitou uma diminuição aproximada de 15,23% na quantidade total de fertilizante utilizada.

5. Discussão

5.1. Resposta dos sensores

A utilização de sensores ópticos no monitoramento da adubação azotada tem-se mostrado uma prática eficaz na agricultura de precisão, permitindo ajustar as doses de fertilizantes com base nas reais necessidades das plantas e reduzir desperdícios. O uso de índices de vegetação, como o NDVI, tem contribuído para uma gestão mais racional do azoto, promovendo ganhos de produtividade e sustentabilidade ambiental (Raun et al., 2001; Padilla et al., 2018; Aula et al., 2020).

Neste estudo, o sensor Augmenta que realiza recomendações em tempo real com base em medições espectrais, apresentou correlações positivas com as variáveis agronômicas %N, PB, NUp e PByield. Estes resultados estão de acordo com pesquisas recentes que destacam o potencial de sensores ópticos para estimar a absorção de N e prever a produtividade em culturas forrageiras e de cereais (Zsebő et al., 2024; Papadopoulos et al., 2023).

O MSI-I, capturado antes da aplicação de N, apresentou correlações mais fracas com as variáveis agronômicas, refletindo o estado inicial da cultura e a limitação nutricional antes da adubação. Em contrapartida, o MSI-II, obtido após a aplicação, mostrou correlações mais fortes com MV, MS e NUp, indicando que o sensor foi capaz de detetar as alterações fisiológicas induzidas pela fertilização. Estes resultados corroboram estudos que apontam a importância do momento da aquisição das imagens para a precisão das estimativas de produtividade e teor de N (Maresma et al., 2020). Segundo Papadopoulos et al. (2023), os valores de NDVI estão intimamente relacionados com as taxas de fertilização e a produtividade final, demonstrando a sensibilidade do índice em acompanhar o desenvolvimento vegetativo da cultura.

O GS®, apesar de realizar leituras pontuais, apresentou correlações moderadas com MV, MS e NUp, destacando-se como uma ferramenta complementar eficaz para o manejo do N em campo. Estudos anteriores demonstram que sensores proximais como o GreenSeeker® podem ser utilizados para o ajuste dinâmico das doses de fertilizante, melhorando a eficiência de uso do nutriente e contribuindo para a uniformidade do desenvolvimento da cultura (Ahmed et al., 2024; Maresma et al., 2020).

A aplicação em taxa variável (VRA) orientada pelo sensor Augmenta demonstrou elevada eficiência agronômica e potencial de redução no uso de fertilizantes. Na área experimental de 1,5 ha, a aplicação convencional em dose fixa de 150 kg N ha⁻¹ resultaria

num consumo total de 225 kg de N. Contudo, a aplicação realizada com base nas recomendações do Augmenta totalizou 190,65 kg de N, representando uma economia de 15,23% sem redução da produtividade. Este resultado evidencia a capacidade do sensor em ajustar as doses de forma localizada, mantendo o rendimento e otimizando a eficiência de uso do N.

O NDVI_Augm demonstrou sensibilidade à variabilidade nutricional e ao potencial produtivo das áreas monitorizadas, mostrando-se eficaz na identificação de zonas com diferentes níveis de vigor e necessidade de N. Tal capacidade de adaptação é essencial em sistemas forrageiros sob condições mediterrânicas, caracterizados por elevada heterogeneidade espacial. Estes resultados estão de acordo com estudos que evidenciam o potencial dos sensores multiespectrais em proporcionar reduções significativas no uso de N, sem comprometer a produtividade (Maresma et al., 2020; Zsebő et al., 2024).

Os resultados obtidos neste trabalho são consistentes com os de Zsebő et al. (2024), que relataram reduções médias de 7,8% no uso de N e aumentos de produtividade superiores a 10% em trigo de inverno através da utilização de sensores ópticos em tempo real. De forma semelhante, Fabbri et al. (2025), ao comparar estratégias de adubação azotada na região da Toscana ao longo de quatro campanhas (2018–2022), verificaram que abordagens de VRA baseadas em NDVI e Nitrogen Nutrition Index (NNI) permitiram reduzir significativamente a aplicação de N sem afetar o rendimento nem a qualidade dos grãos, além de otimizarem parâmetros tecnológicos relevantes para a indústria.

5.2. Correlação entre os sensores e a produtividade

A análise de correlação entre os sensores e os parâmetros produtivos revelou uma forte relação entre os índices espectrais e variáveis-chave como NUp, PByield e Nyield, confirmando a sensibilidade dos sensores ópticos em captar as alterações fisiológicas resultantes do manejo da fertilização. A matriz de dispersão evidenciou que os valores de NDVI e outros índices derivados dos sensores aumentaram de forma consistente com a elevação das doses de N aplicadas, refletindo a resposta das plantas ao fornecimento do nutriente. Estes resultados validam a hipótese de que os sensores ópticos, quando utilizados de forma integrada e em diferentes momentos do ciclo da cultura, são ferramentas eficazes para monitorizar a resposta das plantas à adubação (Pires et al., 2014; Povh, 2012).

A associação entre o NDVI e a produtividade tem sido amplamente documentada na literatura científica, sendo o índice reconhecido como um indicador robusto do vigor vegetativo e do estado nutricional das culturas (Maresma et al., 2020; Papadopoulos et al., 2023). No presente estudo, a variação do NDVI acompanhou as diferenças nas doses recomendadas pelo sensor Augmenta Field Analyzer™, sugerindo que o modelo de prescrição foi eficaz em adaptar as aplicações de N ao potencial produtivo local. Essa adaptação está em consonância com os princípios da agricultura de precisão, que visam otimizar o uso de insumos agrícolas com base na variabilidade espacial e temporal das lavouras (Fabbri et al., 2025).

Resultados semelhantes foram relatados por Georgiadis (2023), num estudo conduzido na Austrália durante a safra de 2020/2021, onde o sistema Augmenta Field Analyzer™ foi aplicado em áreas de trigo sob manejo VRA. O autor observou uma economia média de 7,8% no uso de fertilizantes, associada a um aumento de 11,2% na produtividade, atingindo 8.000 kg ha⁻¹ nas áreas com VRA, em comparação com 7.200 kg ha⁻¹ em áreas de dose fixa. Além disso, foi registrada uma redução de 14,4% na aplicação de N em zonas com maior índice de vegetação (AUG-Index), sem prejuízo da produtividade, o que demonstra o potencial do sensor em promover um manejo mais racional e sustentável. Adicionalmente, o projeto europeu Econutri (2023) incorporou tecnologias de agricultura de precisão, incluindo o sensor óptico Augmenta Field Analyzer, com o objetivo de promover a aplicação em taxa variável de fertilizantes azotados em culturas extensivas. Os resultados apontaram para uma redução entre 4,4% e 6,3% no consumo de fertilizantes, mantendo ou aumentando a produtividade. Constatou-se também uma diminuição do impacto ambiental, evidenciada pela redução do risco de lixiviação de nitratos e pela mitigação das emissões atmosféricas de amônia. Estes resultados reforçam a importância dos sensores ópticos inteligentes na promoção de sistemas agrícolas mais eficientes e sustentáveis, alinhados com os objetivos da transição agroecológica na União Europeia.

Estudos adicionais confirmam a utilidade dos sensores ópticos, em especial do NDVI, na previsão de rendimento e no acompanhamento da nutrição azotada. Wang, Tian, Yao, Zhu & Cao (2014) demonstraram que o NDVI apresenta forte correlação com a produtividade e o teor de N em diferentes estádios fenológicos, sendo mais sensível durante o alongamento do colmo e o enchimento dos grãos. De forma semelhante, Zhou et al., (2017) observaram que índices derivados de reflectância multiespectral

podem ser utilizados para prever a produtividade final e o conteúdo proteico dos grãos com elevada precisão.

A integração entre sensores remotos e sistemas automatizados de recomendação, como o Augmenta, revela-se, assim, uma ferramenta promissora para o manejo de precisão da fertilização, permitindo a redução de custos e impactos ambientais sem comprometer o desempenho agronômico. A correlação positiva entre os índices espectrais e as variáveis produtivas reforça o potencial da tecnologia no aperfeiçoamento da NUE, contribuindo para uma agricultura mais sustentável e baseada em dados.

5.3. Implicações práticas do uso de sensores em forragens de outono/inverno em clima mediterrânico

A utilização de sensores ópticos no manejo de culturas forrageiras de outono e inverno sob condições de clima mediterrânico apresenta implicações práticas de elevada relevância para a sustentabilidade e a eficiência produtiva dos sistemas agrícolas. Este tipo de clima, caracterizado por invernos húmidos e verões quentes e secos, impõe desafios específicos à gestão do N, nomeadamente a elevada variabilidade na disponibilidade hídrica, as perdas por lixiviação durante o inverno e a reduzida taxa de mineralização durante o verão. Nestes contextos, a adoção de tecnologias de agricultura de precisão, como sensores ópticos remotos e proximais, permite ajustar as doses de fertilizantes de acordo com a dinâmica espacial e temporal das culturas, otimizando o uso de N e reduzindo impactos ambientais (Quebrajo et al., 2015).

A integração de sensores como o Augmenta e o GS® no manejo de forragens representa uma estratégia inovadora para aumentar a eficiência da fertilização. Estes dispositivos permitem monitorizar em tempo real o estado nutricional das plantas e adaptar a dose aplicada em função do vigor e do crescimento do dossel vegetal. Estudos recentes demonstraram que o uso de sensores multiespectrais em culturas forrageiras sob clima mediterrânico permite reduzir em média entre 10 e 20% a aplicação de N, sem comprometer a produtividade. Tal resultado deve-se à capacidade dos sensores em identificar zonas de maior ou menor resposta ao fertilizante, evitando tanto a aplicação excessiva como a subfertilização, aspetos críticos em solos com elevada heterogeneidade (Pulina et al., 2025).

A combinação de dados espectrais com indicadores agronômicos e análises laboratoriais permite o desenvolvimento de modelos de previsão mais robustos, capazes de associar

parâmetros fisiológicos, como o teor de clorofila e o conteúdo de proteína bruta, à resposta produtiva das culturas. Essa abordagem integrada tem sido destacada como essencial para aumentar a precisão da estimativa da absorção de N e da previsão de rendimento, sendo a calibração dos sensores com base em dados locais um requisito fundamental para a sua utilização eficiente em pastagens e forragens de inverno (Padilla et al., 2018; Silva et al., 2025).

Os benefícios do uso de sensores ópticos vão além da otimização da adubação. A sua utilização contribui significativamente para a mitigação de impactos ambientais, reduzindo o risco de lixiviação de nitratos e a emissão de gases de efeito estufa associados à FA. Em regiões mediterrânicas, onde os recursos hídricos são limitados e as flutuações climáticas são acentuadas, o manejo racional do N é essencial para assegurar a resiliência dos sistemas agrícolas. O monitoramento contínuo proporcionado pelos sensores permite ajustar o manejo às variações meteorológicas sazonais, fator especialmente relevante em anos de seca ou excesso de precipitação (Aranguren et al., 2019; Ravikumar et al., 2024).

A incorporação destas tecnologias insere-se no conceito de agricultura 5.0, que integra sensores, GNSS, IA e análise de dados geoespaciais para apoiar a tomada de decisão em tempo real. Esta integração facilita a gestão de sistemas forrageiros de forma mais eficiente e precisa, promovendo a intensificação sustentável da produção, com aumento de produtividade sem a expansão da área cultivada nem a degradação dos recursos naturais (Mesías-Ruiz et al., 2023).

Os resultados obtidos reforçam que a utilização de sensores ópticos no manejo de forragens de outono e inverno em clima mediterrânico pode conduzir a uma agricultura mais precisa, inteligente e sustentável. Estas tecnologias permitem alinhar os sistemas produtivos com as metas europeias de redução de emissões e uso eficiente de nutrientes, estabelecidas no Pacto Ecológico Europeu e na Estratégia “Do Prado ao Prato” (European Commission, 2020). Quando associadas a outros indicadores agronómicos, as tecnologias de sensoriamento demonstram elevado potencial para otimizar o desempenho produtivo, melhorar a NUE e contribuir de forma concreta para a transição agroecológica dos sistemas agrícolas mediterrânicos.

5.4. Perspectivas Futuras

A presente dissertação evidenciou o potencial do uso de sensores ópticos no apoio à adubação azotada em culturas forrageiras de inverno, sob condições de clima mediterrânico, contribuindo para o avanço de práticas agrícolas mais sustentáveis e baseadas em dados. No contexto da Agricultura Sustentável, campo no qual este trabalho está inserido, os resultados obtidos apontam para diversas possibilidades de continuidade e aprofundamento da pesquisa, tanto em nível técnico-científico quanto em sua aplicação prática junto aos sistemas produtivos.

Como desdobramento imediato, sugere-se a realização de novos ensaios experimentais que envolvam diferentes espécies forrageiras, sistemas de manejo do solo, níveis de fertilização e ambientes edafoclimáticos diversos. Essa ampliação permitirá avaliar a consistência dos modelos de prescrição gerados a partir dos sensores ópticos e adaptar as recomendações conforme especificidades locais. Além disso, estudos de médio e longo prazo que correlacionem o uso de sensores com indicadores de sustentabilidade, como eficiência no uso de nutrientes, produtividade por unidade de insumo e emissões evitadas de GEE poderão fornecer subsídios importantes para políticas públicas e programas de incentivo à agricultura de base tecnológica e ambientalmente responsável. Sob a ótica da sustentabilidade, destaca-se ainda a importância de integrar tecnologias de AP com princípios biológicos e de manejo conservacionista. O uso racional de fertilizantes nitrogenados, orientado por ferramentas como os sensores ópticos, contribui diretamente para a mitigação de impactos ambientais associados ao excesso de insumos, como a lixiviação de nitrato e a eutrofização de corpos hídricos. Assim, a adoção dessas ferramentas tecnológicas dialoga com os Objetivos de Desenvolvimento Sustentável (ODS), especialmente os relacionados à segurança alimentar, produção responsável e combate às mudanças climáticas.

Adicionalmente, recomenda-se o fortalecimento de estratégias de transferência de tecnologia e capacitação técnica junto a agricultores, cooperativas e agentes de assistência técnica e extensão rural. A disseminação dos conhecimentos gerados por

esta pesquisa, aliada a programas de formação continuada, poderá favorecer a adoção consciente e eficaz dessas tecnologias, promovendo sistemas de produção mais eficientes, resilientes e adaptados às transformações climáticas.

Por fim, futuras investigações poderão explorar a integração entre sensores ópticos e outras ferramentas digitais emergentes, como imagens de satélite, redes de sensores em tempo real e algoritmos de inteligência artificial, a fim de desenvolver sistemas mais robustos de monitoramento e tomada de decisão. Essa abordagem integrada alinha-se à proposta de uma Agricultura 5.0 sustentável, que concilia inovação tecnológica, algoritmos inteligentes e responsabilidade socioambiental.

6. Conclusões

Os resultados deste estudo demonstraram que a aplicação de fertilização em tempo real permitiu reduzir em 15,23% a quantidade total de azoto utilizada, diminuindo assim os custos de produção e o impacto ambiental, sem comprometer a produtividade da cultura. Apesar da eficácia observada, é importante considerar que este tipo de processo requer a integração de tecnologias avançadas de sensores e atuadores, cujo custo de aquisição e manutenção ainda representa um fator limitante. Por esse motivo, futuros estudos deverão concentrar-se na análise económica e na viabilidade de adoção deste sistema de fertilização em diferentes contextos produtivos.

Os valores de NDVI obtidos pelo drone no momento da aplicação apresentaram correlações fracas com os parâmetros agronómicos avaliados, refletindo a condição fisiológica inicial das plantas antes da assimilação do fertilizante. Em contrapartida, o NDVI captado pelo drone após a adubação apresentou correlações mais expressivas com variáveis como MV, MS e Nyield, sugerindo que as respostas espectrais do sensor aéreo foram sensíveis às alterações fisiológicas provocadas pela adubação azotada em taxa variável.

O sensor proximal GS® apresentou correlações moderadas com MV, MS e NUp, destacando-se pela sua capacidade de leitura pontual em campo, embora mais limitada em cobertura quando comparada à análise aérea proporcionada pelo drone. Esta diferença demonstra que ambos os tipos de sensores possuem funções complementares: enquanto o sensor remoto permite uma visão espacial abrangente da área, o sensor proximal fornece dados precisos e localizados, essenciais para validação e calibração das informações espectrais.

Dessa forma, conclui-se que o uso combinado do índice NDVI_Augm para prescrição e dos sensores MSI_II e GS® para monitoramento da resposta das plantas constitui uma abordagem eficaz para a gestão da adubação em VRA. Essa integração permite simultaneamente otimizar o uso de insumos e avaliar de forma detalhada o desempenho

fisiológico e produtivo da cultura, aumentando a eficiência agronómica e a sustentabilidade do sistema de produção.

Os benefícios decorrentes da adoção de tecnologias VRA tendem a ser mais significativos em explorações agrícolas de maior dimensão e variam conforme o tipo de cultura cultivada. Por este motivo, a redução dos custos operacionais e o aumento da rentabilidade devem ser avaliados considerando estas variáveis, de modo a estimar com maior precisão o retorno económico do investimento. Além disso, a utilização de estratégias diversificadas de VRA proporciona ao produtor informações detalhadas sobre a variabilidade espacial da área cultivada, permitindo decisões agronómicas mais assertivas em ciclos subsequentes.

Um exemplo prático é o uso da aplicação variável de N para identificar zonas de baixa produtividade dentro do talhão, possibilitando ajustes no manejo e o aperfeiçoamento contínuo da fertilização. Para além dos benefícios económicos, a adoção dessa tecnologia gera impactos socioambientais positivos, como a redução da exposição dos trabalhadores rurais a agentes potencialmente tóxicos e a promoção de um ambiente de trabalho mais seguro. Paralelamente, a diminuição da frequência de reabastecimentos contribui para operações mais curtas e eficientes. No entanto, é importante salientar que muitos desses benefícios, embora relevantes, são de difícil quantificação direta, o que pode representar um obstáculo à valorização plena da tecnologia por parte dos seus utilizadores finais.

7. Referências

Abdalla, A., & Mirzakhani Nafchi, A. (2024). *Development and evaluation of an affordable variable rate applicator controller for precision agriculture*. *AgriEngineering*, 6(4), 4639-4657. <https://doi.org/10.3390/agriengineering6040265>

Adar, S., Paz-Kagan, T., Argaman, E., Dubinin, M. V., & Sternberg, M. (2024). *Identifying climatic drivers of forage quantity and quality in Mediterranean rangelands using remote sensing*. *Science of The Total Environment*, 957, 177797. <https://doi.org/10.1016/j.scitotenv.2024.177797>

Ainsworth, E. A., & Long, S. P. (2005). *What have we learned from 15 years of free-air CO₂ enrichment (FACE)? A meta-analytic review of the responses of photosynthesis, canopy properties and plant production to rising CO₂*. *New Phytologist*, 165(2), 351–372. <https://doi.org/10.1111/j.1469-8137.2004.01224.x>

Ahmed, A., Ali, M., Basir, A., Hussain, I., & Tiwari, T. P. (2024). *Enhancing wheat productivity in Pakistan through nitrogen management and NDVI monitoring with GreenSeeker*. *Journal of Applied Research in Plant Sciences*, 5(2), 355–363. <https://doi.org/10.38211/joarps.2024.05.291>

Alfonso Loret de Mora, O. B. (2014). *Suelos, desertificación, agricultura: Ecunha-Huambo (Angola)*. Universidad Internacional de Andalucía. <http://hdl.handle.net/10334/2709>

Ali, A. M., Abou-Amer, I., & Ibrahim, S. M. (2018). *Using GreenSeeker active optical sensor for optimizing maize nitrogen fertilization in calcareous soils of Egypt*. *Archives of Agronomy and Soil Science*, 64(8), 1083-1093. <https://doi.org/10.1080/03650340.2017.1411589>

Ali, A. M., Ibrahim, S. M., & Bijay-Singh. (2020). *Wheat grain yield and nitrogen uptake prediction using atLeaf and GreenSeeker portable optical sensors at jointing growth stage*. *Information Processing in Agriculture*, 7(3), 375–383. <https://doi.org/10.1016/j.inpa.2019.09.008>

Amaral, L. R., Molin, J. P., Portz, G., Finazzi, F. B., & Cortinove, L. (2015). *Comparison of crop canopy reflectance sensors used to identify sugarcane biomass and nitrogen status*. *Precision Agriculture*, 16(1), 15–28. <https://doi.org/10.1007/s11119-014-9377-2>

AMAZONE-Werke H. Dreyer GmbH & Co. KG. (2025). ZA-TS Mounted Spreader. AMAZONE.

<https://amazone.net/en/products-digital-solutions/agricultural-technology/fertilising-technology/mounted-spreader/za-ts-mounted-spreader-51506>

Aranguren, M., Castellón, A., Aizpurua, A., & Ortega, R. (2019). Crop sensor-based in-season nitrogen management of winter wheat in a temperate-Mediterranean climate. *Remote Sensing*, 11(9), 1094. <https://doi.org/10.3390/rs11091094>

Atzberger, C. (2013). Advances in remote sensing of agriculture: Context description, existing operational monitoring systems and major information needs. *Remote Sensing*, 5(2), 949–981. <https://doi.org/10.3390/rs5020949>

Aula, L., Omara, P., Nambi, E., Oyebiyi, F. B., & Raun, W. R. (2020). Review of Active Optical Sensors for Improving Winter Wheat Nitrogen Use Efficiency. *Agronomy*, 10(8), 1157. <https://doi.org/10.3390/agronomy10081157>

Bancayan Hinostroza, L. G., & Olortegui Chamoli, S. (2023). *La caracterización de las zonas ganaderas del distrito de Calzada para la implementación de sistemas silvopastoriles, región San Martín* [Dissertação de mestrado]. Universidad Continental. <https://hdl.handle.net/20.500.12394/17019>

Basso, B., Fiorentino, C., Cammarano, D., & Ritchie, J. T. (2013). Wheat yield response to spatially variable nitrogen fertilizer in a Mediterranean environment. *European Journal of Agronomy*, 51, 65-70. <https://doi.org/10.1016/j.eja.2013.06.007>

Basso, B., Dumont, B., Cammarano, D., Pezzuolo, A., Marinello, F., & Sartori, L. (2016). Environmental and economic benefits of variable rate nitrogen fertilisation in a nitrate vulnerable zone. *Science of the Total Environment*, 545–546, 227–235. <https://doi.org/10.1016/j.scitotenv.2015.12.104>

Biermacher, J. T., Epplin, F. M., Brorsen, B. W., Solie, J. B., & Raun, W. R. (2009). Economic feasibility of site-specific optical sensing for managing nitrogen fertilizer for growing wheat. *Precision Agriculture*, 10(3), 213–230. <https://doi.org/10.1007/s11119-008-9092-y>

Bragagnolo, J., Amado, T. J. C., Nicoloso, R. S., Santi, A. L., & Fiorin, J. E. (2013). Optical crop sensor for variable-rate nitrogen fertilization in corn: II – Indices of fertilizer

efficiency and corn yield. *Revista Brasileira de Ciência do Solo*, 37(5), 1299–1309. <https://doi.org/10.1590/S0100-06832013000500019>

Bragagnolo, J. (2014). *Fertilização nitrogenada à dose variada na cultura do milho* [Tese de doutoramento, Universidade Federal de Santa Maria]. Universidade Federal de Santa Maria.

Brandão, Z. N. (2021). *Estimativa da produtividade e estado nutricional da cultura do algodão irrigado via técnicas de sensoriamento remoto* [Tese de doutoramento, Universidade Federal de Campina Grande]. Universidade Federal de Campina Grande.

Bourgeon, M.-A., Gée, C., Debuissou, S., Paoli, J.-N., & Villette, S. (2016). *Field radiometric calibration of a multispectral on-the-go sensor dedicated to the characterization of vineyard foliage*. *Computers and Electronics in Agriculture*, 123, 184–194. <https://doi.org/10.1016/j.compag.2016.02.019>

Carita, T., Carneiro, J. P., Crespo, J. P., Barradas, A., & Santos Silva, J. (2019, 30 de janeiro). *Potencialidade do território para a produção de forragens*. AGROTEC. <https://www.agrotec.pt/noticias/potencialidade-do-territorio-para-a-producao-de-forragens/>

Camicia, R. G. M., Maggi, M. F., Souza, E. G., Bazzi, C. L., Konopatzki, E. A., Michelon, G. K., & Pinheiro, J. B. S. (2018). *Productivity of soybean in management zones with application of different sowing densities*. *Ciência Rural*, 48(12), e20180532. <https://doi.org/10.1590/0103-8478cr20180532>

Cambardella, C. A., Moorman, T. B., Novak, J. M., Parkin, T. B., Karlen, D. L., Turco, R. F., & Konopka, A. E. (1994). *Field-scale variability of soil properties in central Iowa soils*. *Soil Science Society of America Journal*, 58(5), 1501–1511. <https://doi.org/10.2136/sssaj1994.03615995005800050033x>

Cardoso, J. C. (1974). *A classificação dos solos de Portugal – Nova versão*. *Boletim de Solos*, 17, 14–46.

Carter, G. A., & Knapp, A. K. (2001). *Leaf optical properties in higher plants: Linking spectral characteristics to stress and chlorophyll concentration*. *American Journal of Botany*, 88(4), 677–684. <https://doi.org/10.2307/2657068>

- Cavalcante, W. S. S., Silva, N. F., & Teixeira, M. B. (2022). *Tecnologias e inovações no uso de drones na agricultura / Technologies and innovations in the use of drones in agriculture*. Brazilian Journal of Development, 8(1), 7108–7117. <https://institutoscientia.com/wp-content/uploads/2022/08/capitulo-agrarias-20.pdf>
- Cedra, C. (1992). *Les tracteurs agricoles* (pp. 398). Cemagref Éditions. Coll. Formagri. ISBN 2-85362-259-2.
- D'Oliveira, P. S., Hott, M. C., Andrade, R. G., & Magalhães Junior, W. C. P. (2023). *Aplicações da agricultura de precisão em pastagens* (Circular Técnica, 127). Juiz de Fora, MG: Embrapa Gado de Leite.
- Daughtry, C. S. T. (2000). *Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance*. *Remote Sensing of Environment*, 74(2), 229–239. [https://doi.org/10.1016/S0034-4257\(00\)00113-9](https://doi.org/10.1016/S0034-4257(00)00113-9)
- De Paula Corrêdo, L., de Assis de Carvalho Pinto, F., Queiroz, D. S., Valente, D. S. M., & de Melo Villar, F. M. (2019). *Nitrogen variable rate in pastures using optical sensors*. *Semina: Ciências Agrárias*, 40(6), 2917–2932. DOI: 10.5433/1679-0359.2019v40n6Supl2p2917
- Deutsch, C. V., & Journel, A. G. (1998). *GSLIB: Geostatistical software library and user's guide* (2.^a ed.). Oxford University Press.
- Econutri. (2023). *European Project Econutri: Smart Nutrient Management in Precision Agriculture*. European Commission. <https://cordis.europa.eu/project/id/EcoNutri>
- European Commission. (2020). *Farm to Fork Strategy – For a fair, healthy and environmentally-friendly food system*. European Union. https://food.ec.europa.eu/horizontal-topics/farm-fork-strategy_en
- Eurostat. (2025). *Use of mineral fertilisers in the EU continues to decline*. Eurostat. <https://ec.europa.eu/eurostat/web/products-eurostat-news/w/ddn-20250704-3>
- Fabbri, C., Masi, E., Rossi, G., & Tóth, Z. (2025). *Evaluation of nitrogen management strategies using Sentinel-2 imagery in Mediterranean cereal systems*. *Agricultural Systems*, 231, 104960. <https://doi.org/10.1016/j.agsy.2024.104960>

FAO. (2018). *Sustainable livestock development in the Americas: A multistakeholder strategy for achieving Sustainable Development Goals*. FAO Regional Office for Latin America and the Caribbean.

Farming Future. (2019). *Augmenta makes VRA fertilisation 100% autonomous*. Farming Future. <https://farmingfuture.com/augmenta>

Feyter, C., O'Connor, M. B., & Addison, B. (1985). *Effects of rates and times of nitrogen application on the production and composition of dairy pastures in Waikato district, New*

Food and Agriculture Organization of the United Nations. (s.d.). Grasslands, rangelands and forage crops. FAO. <https://www.fao.org/grasslands-and-rangelands/en/>

Zealand. *New Zealand Journal of Experimental Agriculture*, 13, 247-252. <https://doi.org/10.1080/03015521.1985.10426090>

Felipetto, R. (2022). *Sensoriamento óptico na agricultura de precisão: princípios e aplicações* [Trabalho de conclusão de curso, Universidade Federal de Santa Maria]. Universidade Federal de Santa Maria.

Fitzgerald, G. J. (2010). *Characterizing vegetation indices derived from active and passive sensors*. *International Journal of Remote Sensing*, 31(16), 4335–4348. <https://doi.org/10.1080/01431160903258217>

Formaggio, A. R., & Sanches, I. D. A. (2017). *Sensoriamento remoto em agricultura*. Oficina de Textos.

Franca, A., Loi, A., & Davies, W. J. (1998). Selection of annual ryegrass (*Lolium rigidum* Gaudin) for adaptation to semi-arid conditions. *European Journal of Agronomy*, 9(1), 71-78. [https://doi.org/10.1016/S1161-0301\(98\)00024-0](https://doi.org/10.1016/S1161-0301(98)00024-0)

Georgiadis, N., Mangidis, V., Vogiatzi, C., Papachristos, K., & Cavalaris, C. (2020). *Real-time variable rate applications of nitrogen in wheat using multispectral camera system*. Kosmos Publishers – Research Article. <https://kosmospublishers.com/real-time-variable-rate-applications-of-nitrogen-in-wheat-using-multispectral-camera-system/>

Goovaerts, P. (1997). *Geostatistics for natural resources evaluation*. New York: Oxford University Press.

Gomide, C. (2020). *Eficiência do uso de nitrogénio em sistemas agrícolas tropicais*. Sete Lagoas: Embrapa Milho e Sorgo.

Heege, H. J. (Ed.). (2013). *Precision in crop farming: Site specific concepts and sensing methods: Applications and results*. Springer. <https://doi.org/10.1007/978-94-007-6760-7>

Hill-Pearce, R. E., Hillier, A., Mussell Webber, E., Charoenpornpukdee, K., O'Doherty, S., Mohn, J., Zellweger, C., Worton, D. R., & Brewer, P. J. (2021). Characterisation of gas reference materials for underpinning atmospheric measurements of stable isotopes of nitrous oxide. *Atmospheric Measurement Techniques*, 14(8), 5447–5458. <https://doi.org/10.5194/amt-14-5447-2021>

Hooper, P., Kerr, G., & Black, A. (2017). Understanding the effect of canopy density and nitrogen stress on NDVI in pastures. *Grass and Forage Science*, 72(4), 635–646. <https://doi.org/10.1111/gfs.12272>

Horwitz, W. (2006). *Official methods of analysis of AOAC International*. AOAC International.

Isaaks, E. H., & Srivastava, R. M. (1989). *An introduction to applied geostatistics*. New York: Oxford University Press.

Instituto Nacional de Estatística. (2021). *Recenseamento Agrícola 2019 – Análise dos principais resultados*. INE. https://www.ine.pt/xportal/xmain?xpid=INE&xpgid=ine_publicacoes&PUBLICACOESpub_boui=546331902&PUBLICACOESmodo=2

Instituto Nacional de Estatística. (2022). *Estatísticas Agrícolas – 2021*. INE. https://www.ine.pt/xportal/xmain?xpid=INE&xpgid=ine_publicacoes&PUBLICACOESpub_boui=569300481&PUBLICACOESmodo=2

Instituto Português do Mar e da Atmosfera (IPMA). (2024). *Normal climatológica – Elvas 1991-2020 (Estação n.º 835)*. IPMA. https://www.ipma.pt/bin/file.data/climate-normal/cn_91-20_ELVAS.pdf

International Organization for Standardization. (2023). *ISO 11783-1:2017 – Tractors and machinery for agriculture and forestry — Serial control and communications data network — Part 1: General standard for mobile data communication*. ISO. <https://www.iso.org/standard/67477.html>

Jacquemoud, S., & Baret, F. (1990). *PROSPECT: A model of leaf optical properties spectra*. *Remote Sensing of Environment*, 34(2), 75–91. [https://doi.org/10.1016/0034-4257\(90\)90100-Z](https://doi.org/10.1016/0034-4257(90)90100-Z)

Journel, A. G., & Huijbregts, C. J. (1978). *Mining geostatistics*. London: Academic Press.

Juscafresa, B. (1982). *Forragens: fertilização e valor nutritivo*. Publicações Europa-América.

Kapp-Junior, C., Guimarães, A. M., & Caires, E. F. (2020). *Nitrogen fertilization for wheat following soybean and interfering factors on spectral reflectance readings*. *SN Applied Sciences*, 2, Article 1798. <https://doi.org/10.1007/s42452-020-03599-w>

Kim, Y., Glenn, D. M., Park, J., Ngugi, H. K., & Lehman, B. L. (2012). *Characteristics of active spectral sensor for plant sensing*. *Transactions of the ASABE*, 55(1), 293–301. <https://doi.org/10.13031/2013.41239>

Kipp, S., Mistele, B., Baresel, P., & Schmidhalter, U. (2014). *High-throughput phenotyping early plant vigour of winter wheat*. *European Journal of Agronomy*, 52(1), 271–278. <https://doi.org/10.1016/j.eja.2013.08.009>

Köppen, W. (1900). *Die Warmezonen der Erde als Grundlage der Klimakunde* [The thermal zones of the Earth as the basis of climatology]. Verlag von Gebrüder Borntraeger.

Lehmeier, C. A., Wild, M., & Schnyder, H. (2013). *Nitrogen stress affects the turnover and size of nitrogen pools supplying leaf growth in a grass*. *Plant Physiology*, 162(4), 2095–2105. <https://doi.org/10.1104/pp.113.219311>

Lemaire, G., Jeuffroy, M. H., & Gastal, F. (2008). *Diagnosis tool for plant and crop N status in vegetative stage: Theory and practices for crop N management*. *European Journal of Agronomy*, 28(4), 614–624. <https://doi.org/10.1016/j.eja.2008.01.005>

Li, F., Miao, Y., Zhang, F., Cui, Z., Li, R., Chen, X., Zhang, H., Schröder, J., Raun, W. R., & Jia, L. (2009). *In-season optical sensing improves nitrogen-use efficiency for winter wheat*. *Soil*

Science Society of America Journal, 73(5), 1566-1574.
<https://doi.org/10.2136/sssaj2008.0150>

Liu, A., Li, Z., Zhang, D., Cui, Z., Zhan, L., Xu, S., Zhang, Y., Dai, J., Li, W., Nie, J., Yang, G., Li, C., & Dong, H. (2022). *One-off basal application of nitrogen fertilizer increases the biological yield but not the economic yield of cotton in moderate fertility soil*. Field Crops Research, 288, 108702. <https://doi.org/10.1016/j.fcr.2022.108702>

Maresma, Á., Chamberlain, L., Tagarakis, A., Kharel, T., Godwin, G., Czymmek, K. J., & Ketterings, Q. M. (2020). *Accuracy of NDVI-derived corn yield predictions is impacted by time of sensing*. Computers and Electronics in Agriculture, 169, 105236. <https://doi.org/10.1016/j.compag.2020.105236>

McBratney, A. B., Santos, M. L. M., & Minasny, B. (2003). *On digital soil mapping*. Geoderma, 117(1–2), 3–52. [https://doi.org/10.1016/S0016-7061\(03\)00223-4](https://doi.org/10.1016/S0016-7061(03)00223-4)

Mesías-Ruiz, G. A., Pérez-Ortiz, M., Dorado, J., de Castro, A. I., & Peña, J. M. (2023). *Boosting precision crop protection towards Agriculture 5.0 via machine learning and emerging technologies: A contextual review*. Frontiers in Plant Science, 14, Article 1143326. <https://doi.org/10.3389/fpls.2023.1143326>

Molin, J. P., Amaral, L. R., & Colaço, A. F. (2015). *Agricultura de precisão*. Oficina de Textos.
<https://www.bibliotecaagptea.org.br/agricultura/precisao/livros/AGRICULTURA%20DE%20PRECISAO%20-%20OFICINA%20DE%20TEXTOS.pdf>

Moral, F. J. (2010). Comparison of different geostatistical approaches to map climate variables: Application to precipitation. *International Journal of Climatology*, 30(4), 620-631. <https://doi.org/10.1002/joc.1913>

Moreira, M. A. (2011). *Fundamentos do sensoriamento remoto e metodologias de aplicação*. Instituto Nacional de Pesquisas Espaciais (INPE).

Motomiya, A. V. de A., Molin, J. P., & Chiavegato, E. J. (2009). *Utilização de sensor óptico ativo para detectar deficiência foliar de nitrogénio em algodoeiro*. Revista Brasileira de Engenharia Agrícola e Ambiental, 13(2), 137-145. <https://doi.org/10.1590/S1415-43662009000200005>

- Mutanga, O., & Skidmore, A. K. (2004). Integrating imaging spectroscopy and neural networks to map grass quality in the Kruger National Park, South Africa. *Remote Sensing of Environment*, 90(1), 104–115. <https://doi.org/10.1016/j.rse.2003.12.004>
- Navalgund, R. R. (2001). *Remote sensing*. Resonance, 6(12), 51-60. <https://doi.org/10.1007/BF02913767>
- Nogueira-Martins, R., Pinto, F. de A. de C., Moura, A. D. de, Siqueira, W. da C., & Villar, F. M. de M. (2022). *Economic feasibility of optical sensors for variable rate nitrogen fertilization in corn*. Idesia, 40(4). <https://doi.org/10.4067/S0718-34292022000400101>
- O'Connor, M. B. (1982). *Nitrogen fertilisers for the production of out-of-season grass*. In P. B. Lynch (Ed.), *Nitrogen fertilisers in New Zealand agriculture* (pp. 65-76). Wellington: New Zealand Institute of Agricultural Science.
- Oliver, M. A., & Webster, R. (2015). *Basic steps in geostatistics: The variogram and kriging*. SpringerBriefs in Agriculture. <https://doi.org/10.1007/978-3-319-15865-5>
- Padilla, F. M., Gallardo, M., Peña-Fleitas, M. T., De Souza, R., & Thompson, R. B. (2018). *Proximal optical sensors for nitrogen management of vegetable crops: A review*. Sensors, 18(7), 2083. <https://doi.org/10.3390/s18072083>
- Papadopoulos, G., Mavroeidis, A., Roussis, I., Kakabouki, I., & Bilalis, D. (2023). *Evaluation of tillage & fertilization in Carthamus tinctorius L. using remote sensing*. Smart Agricultural Technology, 4, Article 100158. <https://doi.org/10.1016/j.atech.2022.100158>
- Pulina, A., Cammarano, D., Piseddu, F., Deiana, L., Sassu, A., Deidda, A., Gambella, F., Seddaiu, G., & Roggero, P. P. (2025). *Predicting the nitrogen content of Mediterranean forage crops: A remote sensing approach*. European Journal of Agronomy, 164, article 127518. <https://doi.org/10.1016/j.eja.2025.127518>
- Peng, Y., Chen, H. Y. H., & Yang, Y. (2020). *Global pattern and drivers of nitrogen saturation threshold of grassland productivity*. Functional Ecology, 34, 1979–1990. <https://doi.org/10.1111/1365-2435.13622>
- Pereira, L. E. T., [outros autores], & [corresponding author]. (2022). *Current scenario and perspectives for nitrogen fertilization strategies on tropical perennial grass pastures: a review*. Agronomy, 12(9), 2079. <https://doi.org/10.3390/agronomy12092079>

Penuelas, J., & Filella, I. (2022). *Plants and water in a changing world: a physiological and ecological perspective*. Rendiconti Lincei. Scienze Fisiche e Naturali. <https://doi.org/10.1007/s12210-022-01084-7>

Peñuelas, J., & Filella, I. (1998). Visible and near-infrared reflectance techniques for diagnosing plant physiological status. *Trends in Plant Science*, 3(4), 151-156. [https://doi.org/10.1016/S1360-1385\(98\)01213-8](https://doi.org/10.1016/S1360-1385(98)01213-8)

Pires, J. L. F., Corassa, G. M., Strieder, M. L., Dalmago, G. A., Cunha, G. R., Santi, A., Silva Júnior, J. P. da, Santi, A. L., Santos, H. P. dos, Pasinato, A., & Remor, C. (2014). *Uso de sensor óptico ativo para caracterização do perfil de NDVI em dosséis de trigo submetidos a diferentes estratégias de manejo*. In A. C. de C. Bernardi, J. de M. Naime, A. V. de Resende, L. H. Bassoi, & R. Y. Inamasu (Eds.), *Agricultura de precisão: resultados de um novo olhar* (pp. 279–286). Embrapa.

Povh, F. P. (2012). *Gestão da adubação nitrogenada em milho utilizando sensoriamento remoto* [Tese de doutoramento, Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo]. <http://www.teses.usp.br/teses/disponiveis/11/11136/tde-23032012-094140/>

Primavesi, O., Primavesi, A. C., Corrêa, L. de A., Silva, A. G. da, & Cantarella, H. (2006). *Lixiviação de nitrato em pastagem de coastcross adubada com nitrogênio*. *Revista Brasileira de Zootecnia*, 35(3), 683–690. Sociedade Brasileira de Zootecnia.

Quebrajo, L., Pérez-Ruiz, M., Rodriguez-Lizana, A., & Agüera, J. (2015). *An Approach to Precise Nitrogen Management Using Hand-Held Crop Sensor Measurements and Winter Wheat Yield Mapping in a Mediterranean Environment*. *Sensors*, 15(3), 5504-5517. <https://doi.org/10.3390/s150305504>

Raun, W. R., Solie, J. B., Johnson, G. V., Stone, M. L., Lukina, E. V., Thomason, W. E., & Schepers, J. S. (2001). *In-season prediction of potential grain yield in winter wheat using canopy reflectance*. *Agronomy Journal*, 93(1), 131–138. <https://doi.org/10.2134/agronj2001.931131x>

Raven Industries (2023). *Raven announces strategic integration of Augmenta, enhances automated technology portfolio*. GlobeNewsWire. <https://www.globenewswire.com/news-release/2023/03/13/2625749/0/en/Raven->

Announces-Strategic-Integration-of-Augmenta-Enhances-Automated-Technology-Portfolio.html

Raven Industries, Inc. (2025). *Augmenta Field Analyzer* [Página de produto]. <https://portal.ravenprecision.com/augmenta-field-analyzer>

Ravikumar, S., Geethalakshmi, V., Pazhanivelan, S., Kannan, P., Annamalai, S., Hwang, S. Robertson (2024). *Real-time nitrogen monitoring and management to augment N use efficiency and ecosystem sustainability: A review*. Journal of Hazardous Materials Advances, 16, 100466. <https://doi.org/10.1016/j.hazadv.2024.100466>

Robertson, M. J., Llewellyn, R. S., Mandel, R., Lawes, R., Bramley, R. G. V., Swift, L., Metz, N., & O'Callaghan, C. (2012). *Adoption of variable rate fertiliser application in the Australian grains industry: Status, issues and prospects*. Precision Agriculture, 13(2), 181–199. <https://doi.org/10.1007/s11119-011-9236-3>

Rufaioğlu, B., Kaplan, F., & Bilgili, A. V. (2002). *Nitrogen fertilisation recommendations using optical sensors*. https://www.researchgate.net/publication/383219157_NITROGEN_FERTILIZATION_RECOMMENDATIONS_USING_OPTICAL_SENSORS?enrichId=rgreq-e8fb40d2e4ef888b4933266ac3c244c8-XXX

Rutto, E. (2009, outubro). *History of GreenSeeker technology*. Oklahoma State University. https://www.researchgate.net/publication/280531720_History_of_Green_Seeker_Technology

Santoro, M. (2020, 17 de janeiro). *Índices de vegetação na agricultura: Um guia prático para o produtor*. Blog da Aegro. <https://aegro.com.br/blog/indice-de-vegetacao/>

Santos, J. Q. (2002). *Fertilidade do solo e nutrição de plantas* (2.^a ed.). Lisboa: Instituto Superior de Agronomia.

Serrano, J. M., Shahidian, S., & Marques da Silva, J. R. (2016). *Monitoring pasture variability: optical OptRx® crop sensor versus GrassMaster II capacitance probe*. Environmental Monitoring and Assessment, 188(2), 117. <https://doi.org/10.1007/s10661-016-5126-5>

Sharma, L. K., Bu, H., Denton, A., & Franzen, D. W. (2015). Active-Optical Sensors Using Red NDVI Compared to Red Edge NDVI for Prediction of Corn Grain Yield in North Dakota, U.S.A. *Sensors*, 15(11), 27832-27853. <https://doi.org/10.3390/s151127832>

Shaver, T. M., Khosla, R., Westfall, D. G., & Reich, R. M. (2011). *Evaluation of two crop canopy sensors for nitrogen variability assessment in irrigated maize. Precision Agriculture*, 12(4), 620–636. DOI 10.1007/s11119-011-9229-2

Shiratsuchi, L. S., Brandão, Z. N., Vicente, L. E., Victoria, D. de C., Ducati, J. R., Oliveira, R. P., & Vilela, M. de F. (2014). *Sensoriamento remoto: conceitos básicos e aplicações na agricultura de precisão*. In A. C. de C. Bernardi, J. de M. Naime, A. V. de Resende, L. H. Bassoi, & R. Y. Inamasu (Eds.), *Agricultura de precisão: resultados de um novo olhar* (pp. 58-73). Brasília, DF: Embrapa.

Sillén, W. M. A., & Dieleman, W. I. J. (2012). *Effects of elevated CO₂ and N fertilization on plant and soil carbon pools of managed grasslands: A meta-analysis*. *Biogeosciences*, 9, 2247-2258. <https://doi.org/10.5194/bg-9-2247-2012>

Silva, L., Barbosa, S., Carita, T., D'Antonio, P., Lidon, F. C., & Conceição, L. A. (2025). *Reflectance-based assessment of nitrogen status in ryegrass and mixed ryegrass-clover intercropping fodder crops*. *Smart Agricultural Technology*, 11(10), 101046. <https://doi.org/10.1016/j.atech.2025.101046>

Silva, L., Barbosa, S., Lidon, F. C., Santos-Silva, J., & Conceição, L. A. (2024). *Measuring the influence of key management decisions on the nitrogen nutritional status of annual ryegrass-based forage crops*. *Agronomy*, 14(8), Article 1817. <https://doi.org/10.3390/agronomy14081817>

Silva, L., Conceição, L. A., Lidon, F. C., & Maças, B. (2023). *Remote monitoring of crop nitrogen nutrition to adjust crop models: A review*. *Agriculture*, 13(4), 835. <https://doi.org/10.3390/agriculture13040835>

Smith, D., Thom, E. R., & Clark, D. A. (2000). *Pasture species mixtures for dairy farms in New Zealand*. *Proceedings of the New Zealand Grassland Association*, 62, 29–33. <https://doi.org/10.33584/jnzg.2000.62.2392>

Stocker, V., de Souza, E. G., Johann, J. A., Beneduzzi, H. M., & de Oliveira e Silva, F. (2019). *Effect of height, tilt and twist angles of an active reflectance sensor on NDVI*

measurements. *Engenharia Agrícola*, 39(special issue), 96–108. <https://doi.org/10.1590/1809-4430-Eng.Agric.v39nep96-108/2019>

Sun, X., Luo, N., Longhurst, B., & Luo, J. (2008). *Fertiliser nitrogen and factors affecting pasture responses*. *The Open Agriculture Journal*, 2(1), 35-42. <https://doi.org/10.2174/1874331500802010035>

Tan, C. W., Zhang, P. P., Zhou, X. X., Wang, Z. X., Xu, Z. Q., Mao, W., Li, W. X., Huo, Z. Y., Guo, W. S., & Yun, F. (2020). *Quantitative monitoring of leaf area index in wheat of different plant types by integrating NDVI and Beer-Lambert law*. *Scientific Reports*, 10(1), 57750. <https://doi.org/10.1038/s41598-020-57750-z>

Trimble Inc. (2025). *GreenSeeker Handheld crop sensor* [Página de produto]. <https://ww2.agriculture.trimble.com/product/greenseeker-handheld-crop-sensor/>

Tullio, L. (Org.). (2018). *Aplicações e princípios do sensoriamento remoto 2* (Vol. 2). Atena Editora. <https://doi.org/10.22533/at.ed.482180110>

Uarrota, V. G., Stefen, D. L. V., Leolato, L. S., Gindri, D. M., & Nerling, D. (2018). Revisiting carotenoids and their role in plant stress responses: From biosynthesis to plant signaling mechanisms during stress. In *Antioxidants and Antioxidant Enzymes in Higher Plants* (pp. 207-232). Springer. https://doi.org/10.1007/978-3-319-75088-0_10

van Maarschalkerweerd, M., & Husted, S. (2015). Recent developments in fast spectroscopy for plant mineral analysis. *Frontiers in Plant Science*, 6, Article 169. <https://doi.org/10.3389/fpls.2015.00169>

Vieira, S. R., Hatfield, J. L., Nielsen, D. R., & Biggar, J. W. (2010). *Geostatistical theory and applications to variability of some agronomical properties*. *Hilgardia*, 51(3), 1–75. <https://doi.org/10.3733/hilg.v51n03p075>

Vouillot, M. O., Huet, P., & Boissard, P. (1998). *Early detection of N deficiency in a wheat crop using physiological and radiometric methods*. *Agronomie*, 18(2), 117–130. <https://hal.science/hal-00885874v1>

Wang, L., Tian, Y., Yao, X., Zhu, Y., & Cao, W. (2014). Predicting grain yield and protein content in wheat by fusing multi-sensor and multi-temporal remote-sensing images. *Field Crops Research*, 164, 178-188. <https://doi.org/10.1016/j.fcr.2014.05.001>

Wedderburn, M. E., Thorrold, B. S., & Crush, J. R. (1990). *Variation in nitrogen response among perennial ryegrass ecotypes from northern New Zealand*. *New Zealand Journal of Agricultural Research*, 33(4), 545–553. <https://doi.org/10.1080/00288233.1990.10428464>

WMO. (2017). *WMO Guide to Climatological Practices* (WMO-No. 100). World Meteorological Organization.

Xue, J., & Su, B. (2017). *Significant remote sensing vegetation indices: A review of developments and applications*. *Journal of Sensors*, 2017, Article ID 1353691. <https://doi.org/10.1155/2017/1353691>

Zhang, N., Wang, M., & Wang, N. (2002). *Precision agriculture — a worldwide overview*. *Computers and Electronics in Agriculture*, 36(2-3), 113-132. [https://doi.org/10.1016/S0168-1699\(02\)00096-0](https://doi.org/10.1016/S0168-1699(02)00096-0)

Zhou, X., Zheng, H. B., Xu, X. Q., He, J. Y., Ge, X. K., Yao, X., Tian, Y. C., & Cao, W. X. (2017). *Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery*. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 246-255. <https://doi.org/10.1016/j.isprsjprs.2017.05.003>

Zsebő, S., Bede, L., Kukorelli, G., Kulmány, I. M., Milics, G., Stencinger, D., Teschner, G., Varga, Z., Vona, V., & Kovács, A. J. (2024). *Yield Prediction Using NDVI Values from GreenSeeker and MicaSense Cameras at Different Stages of Winter Wheat Phenology*. *Drones*, 8(3), 88. <https://doi.org/10.3390/drones8030088>