



Workshop AgriTech IoT Revolution - Douro

Nathalie dos Santos Guimarães
Investigadora · UTAD / CITAB

16/07/2026



Cofinanciado pela
União Europeia

Deteção remota e agricultura de precisão na monitorização de culturas agrícolas

Plataformas de observação, sensores IoT e modelação preditiva na gestão agrónómica

Nathalie Guimarães

Investigadora · UTAD / CITAB

julho de 2026



Apresentação

Nathalie Guimarães — UTAD / CITAB

- Investigadora na UTAD / CITAB.
- Doutoramento em Deteção Remota e Agricultura de Precisão (UTAD, 2025).
- Investigação aplicada a culturas mediterrânicas: amendoal, vinha e olival.
- Inteligência artificial aplicada à monitorização de culturas




Deteção remota



Aprendizagem
automática



Amendoal ·
vinha · olival



PARTE 1

Porque agora

O verão de 2026 e o que aí vem

ENQUADRAMENTO · JUNHO DE 2026

A Europa em alerta vermelho

Onda de calor extrema em cerca de 24 países · 22–26 de junho de 2026

46 °C

Espanha — recorde de junho

44 °C


França — dia mais quente de sempre

> 50 °C

temperatura do solo (satélite)

O que dizem as fontes

Dados de organismos científicos e meteorológicos



Temperatura da superfície — Copernicus Sentinel-3 (23 jun 2026)

"A Europa é o continente que aquece mais depressa — cerca de +2 °C em 50 anos."

— John Kennedy · WMO

"Junho de 2026 deverá ficar entre os cinco mais quentes de sempre."


— Copernicus Climate Change Service

"Caem recordes à medida que o calor extremo domina a Europa."

— Organização Meteorológica Mundial

Não é só este verão: o que projetam os cenários climáticos

Menos precipitação e mais evapotranspiração até 2041–2070, sobretudo no sul



O que a figura mostra

- (a, b) Precipitação (ΔPr): os tons castanhos indicam menos chuva, sobretudo na Península Ibérica e no Mediterrâneo.
- (c, d) Evapotranspiração (ΔPET): os tons laranja e escuro indicam mais procura de água, em toda a Europa.
- Dois cenários de emissões: SSP1-2.6 (moderado) e SSP5-8.5 (elevado).
- Resultado: menos água disponível e mais procura — maior stress hídrico nas culturas mediterrânicas.

Projeções para 2041–2070 face a 1981–2010, Europa. LL1–LL5: regiões de estudo.

Do calor extremo aos campos

Impactos na agricultura — e a resposta

- Dessecação rápida da vegetação e perda foliar.
- Menor crescimento.
- Mortalidade de plantas jovens e forte stress do gado.
- Perdas de culturas por calor e seca triplicaram em 50 anos.
- Quebras de rendimento até cerca de 3% (calor + seca).

Fontes: IOPscience (Environ. Res. Lett.) · Climate Analytics · Copernicus



Monitorizar com precisão e decidir com dados
é, hoje, essencial.

PARTE 2


Ver a cultura de várias escalas

Satélite, drone e sensores no solo

Agricultura de precisão

Gestão diferenciada: local, dose e momento adequados

- Caracterização da variabilidade intraparcelar.
- Aplicação otimizada de fatores de produção.
- Processo iterativo: observação, análise, decisão, atuação.
- Decisões orientadas por dados, não manuais.



Variabilidade intraparcelar — gestão diferenciada



Do registo manual à monitorização digital contínua

Substituir o registo manual por monitorização digital contínua

ANTES · registo manual

- Visita semanal e leitura pontual
- Chuva apontada a olho no caderno
- Decisão por hábito e memória
- Reage-se quando o estrago já se vê




DEPOIS · monitorização contínua

- Sonda a reportar de 30 em 30 min, 24/7
- Série temporal e histórico automático
- Alerta no telemóvel ao passar o limiar
- Decide-se com o dado, antes do dano

Observação multiescala das culturas

Plataformas complementares de aquisição



Satélite

cobertura ampla, alta frequência



VANT (drone)

resolução à escala da árvore



Sensores IoT

aquisição contínua in-situ


Satélite e drone (VANT): plataformas complementares

Compromissos entre escala, resolução e frequência




	Satélite	VANT
Cobertura	Regional (km)	Parcela
Resolução	10–30 m	centímetros
Frequência	Dias (fixa)	Sob procura
Custo / área	Baixo	Médio
Escala	Cultura	Árvore

Plataformas complementares, não concorrentes.



Resolução



Sentinel 2 (10 m)




Planet Scope (3 m)



VANT (5 - 7 cm)

A mesma parcela, resoluções diferentes


Do satélite ao drone: quanto detalhe se vê num pomar




Satélite
≈ 30 m / pixel



Satélite
≈ 10 m / pixel



Satélite
≈ 3 m / pixel




Drone (VANT)
centímetros

Ilustração esquemática de um pomar visto de cima — do satélite (não se distinguem as árvores) ao drone (cada árvore visível).

Índices de vegetação

Quantificar o vigor das culturas a partir da luz refletida

- A vegetação reflete fortemente no infravermelho próximo (NIR).
- A vegetação sob stress reflete menos no NIR.
- Os índices combinam bandas espectrais para medir o vigor.
- NDVI e SAVI são os índices mais utilizados.




$$\text{NDVI} = (\text{NIR} - \text{Vermelho}) / (\text{NIR} + \text{Vermelho})$$


Assinatura espectral da vegetação

NDVI da mesma parcela, a várias resoluções


Quanto mais fina a resolução, mais variabilidade se vê




Satélite
≈ 30 m / pixel



Satélite
≈ 10 m / pixel



Satélite
≈ 3 m / pixel



Drone (VANT)
centímetros

NDVI ■ Baixo ■ Médio ■ Alto

Ilustração esquemática — mapa de NDVI de uma parcela: de satélite a variação esbate-se; ao detalhe do drone distinguem-se as zonas de menor vigor (vermelho) e de maior vigor (verde).


NDVI – Sentinel 2

29/06/2021

05/08/2021

04/07/2022

18/08/2022



Dados do Satélite Sentinel 2 (10 m)

NDVI

Low

Medium

High


NDVI – PlanetScope

29/06/2021

05/08/2021

04/07/2022

18/08/2022



Dados do Satélite PlanetScope (3 m)

NDVI

- Low
- Medium
- High

NDVI – VANT


Dados de VANT (entre 5 e 7 cm)

29/06/2021

05/08/2021

04/07/2022

18/08/2022



NDVI

● Low

● Medium

● High




PARTE 3

O que é o IoT no campo

Sensores que medem e enviam sozinhos os dados

A Internet das Coisas (IoT) na agricultura

Sensores ligados, telemetria e aquisição automática de dados



Telemetria: LoRa · NB-IoT · GSM

Satélite: Sentinel-2 (acesso aberto)

Da medição pontual à monitorização contínua e automatizada.

Arquitetura de uma rede IoT à escala da parcela

Componentes da infraestrutura instalada no terreno

No terreno · sensores

Sonda de humidade do solo - Estação meteorológica - Sensor na planta



Conetividade

Gateway LoRaWAN — telemetria de baixo consumo



Camada digital

Nuvem - Dashboard (FMIS) - Alertas

Tipologia de sensores

Variáveis medidas no campo, do solo à produção

1

Solo

humidade, temperatura e condutividade

2

Ar

temperatura, humidade, vento, radiação, chuva

3

Planta

molhança foliar, copa, dendrómetro, fluxo de seiva

4

Rega

caudal, pressão e nível de reservatórios

5

Produção

contadores e sensores de colheita

Da aquisição à decisão agronómica

Cadeia de valorização dos dados



Integração de fontes de dados heterogéneas para suporte à decisão.

Aprendizagem automática aplicada

Transformar dados em modelos preditivos



Algoritmos testados

kNN

SVM

Random Forest

XGBoost

SHAP interpretável




PARTE 4

Três casos de uso

Da tese de doutoramento, em amendoal

Aquisição e processamento por drone (VANT)

Do voo aos produtos analíticos



Resolução centimétrica — análise à escala da árvore individual.

Caso A — Identificação de cultivares por VANT

Classificação por aprendizagem automática

- Objetivo: classificação automática de cultivares de amendoeira.
- Aquisição: imagem multiespectral por VANT.
- Classificadores: kNN, SVM, Random Forest e XGBoost.
- Integração de índices espectrais e variáveis estruturais (altura e área de copa).
- Exatidão global de 80% (Random Forest e XGBoost).

90%

exatidão global na identificação de cultivares
(Random Forest e XGBoost)




A integração de informação espectral e estrutural foi determinante.

<https://doi.org/10.1080/01431161.2023.2185913>

Caso B — Estimativa da produção por satélite

Comparação de plataformas orbitais e fusão de dados

- Objetivo: estimar a produção em fase pré-colheita.
- Comparação de Landsat-8, Sentinel-2 e PlanetScope.
- Índices de vegetação (NDVI, SAVI).
- Fusão com dados climáticos e de rega.
- A fusão de dados aumentou a exatidão da estimativa.




Índice NDVI (detecção remota)

Landsat-8 30 m

Sentinel-2 10 m


PlanetScope 3 m




Caso C — Avaliação do estado hídrico

Dados multiespectrais e térmicos (VANT) e modelação interpretável

- Indicador: condutância estomática (estado hídrico foliar).
- Aquisição: VANT multiespectral e infravermelho térmico.
- Predição por modelos de aprendizagem automática.
- Interpretabilidade dos modelos por análise SHAP.
- Suporte a uma gestão da rega dirigida e eficiente.



Área de estudo, aquisição por VANT e equipamento (tese)




Análise SHAP: contribuição das variáveis (tese)

<https://doi.org/10.3390/rs16132467>

Síntese

Contributos da deteção remota e da aprendizagem automática

- Conversão de dados de observação em informação acionável.
- Monitorização contínua e espacialmente explícita.
- Avaliação objetiva e reproduzível das culturas.
- Complementaridade entre plataformas orbitais e VANT.
- Modelação interpretável como suporte à confiança.



Considerações finais

Principais conclusões



1

IoT e deteção remota são abordagens complementares.



2

A integração de dados melhora a decisão agronómica.



3

Aprendizagem automática com resultados interpretáveis.



4

Monitorização precoce para intervenções mais eficientes.



Publicações relevantes

Estudos que sustentam esta apresentação

- 1 **Guimarães, N. et al. (2024).** Remote Sensing Applications in Almond Orchards: A Comprehensive Systematic Review. *Applied Sciences*, 14, 1749.
- 2 **Guimarães, N. et al. (2023).** Almond cultivar identification using machine learning classifiers applied to UAV multispectral data. *Int. J. Remote Sensing*, 44(5).
- 3 **Guimarães, N. et al. (2024).** Comparative Evaluation of Remote Sensing Platforms for Almond Yield Prediction. *AgriEngineering*, 6(1), 15.
- 4 **Guimarães, N. et al. (2024).** Combining UAV Multispectral & Thermal Data with SHAP for Predicting Stomatal Conductance. *Remote Sensing*, 16(13), 2467.
- 5 **Guimarães, N. et al. (2026).** High-Resolution Soil Surface Moisture Projections for European Perennial Crops. *Remote Sensing*, 18(12), 1902.

Obrigada pela atenção

Nathalie Guimarães · UTAD / CITAB

nsguimaraes@utad.pt

ORCID 0000-0002-0636-1099



utad

groNet
Forward

Email geral@agronetforward.pt

[www. agronetforward.pt](http://www.agronetforward.pt)

linkedin.com/company/agronetforward



Cofinanciado pela
União Europeia

Ficha Técnica

Designação do Projeto | AgroNet Forward – Digitalizar o agroalimentar do Douro Tâmega

Nº do projeto | 25447

Promotores |

ADCEIDT – Associação de Desenvolvimento, Criatividade, Empreendedorismo e Inovação do Douro Tâmega

UTAD - Universidade de Trás-os-Montes e Alto Douro

Aviso | COMPETE2030-2025-4

Designação do aviso | Ações Coletivas – Digitalização

Tipologia de Ação | Transição Digital das Empresas

Objetivos | Aproveitar as vantagens da digitalização para os cidadãos, as empresas, os organismos de investigação e as autoridades públicas (FEDER)

Edição e Conteúdos | UTAD



Cofinanciado pela
União Europeia