

**UNIVERSIDAD POLITÉCNICA DE MADRID**  
Escuela Técnica Superior de Ingeniería Agronómica Alimentaria y de  
Biosistemas



**Aplicación de sensores multiespectral y  
térmico a bordo de UASs para la  
caracterización de la variabilidad del  
viñedo (cv. Merlot) en Yepes (Toledo)**

**TESIS DOCTORAL**

Presentada para optar al título de Doctor por:

**Luz Karime Atencia Payares**

Máster en Estrategias y Tecnologías para el Desarrollo

Madrid, 2024



UNIVERSIDAD POLITÉCNICA DE MADRID  
Escuela Técnica Superior de Ingeniería Agronómica  
Alimentaria y de Biosistemas

**Doctorado en Tecnología Agroambiental para una Agricultura  
Sostenible**

**Aplicación de sensores multiespectral y  
térmico a bordo de UASs para la  
caracterización de la variabilidad del  
viñedo (cv. Merlot) en Yepes (Toledo)**

## **TESIS DOCTORAL**

Presentada para optar al título de Doctor por:

**Luz Karime Atencia Payares**

Máster en Estrategias y Tecnologías para el Desarrollo

Bajo la dirección de:

Dra. María V. Gómez del Campo García-Valcárcel

Dra. Ana María Tarquis Alfonso

Madrid, 2024

Título: Aplicación de sensores térmico y multispectral a bordo de UASs para la caracterización de suelo y estado hídrico del viñedo (cv. Merlot) en Yepes (Toledo)

Title: Application of multispectral and thermal sensors on board UASs for the characterization of vineyard (cv. Merlot) variability in Yepes (Toledo)

Autor: Luz Karime Atencia Payares

Programa de Doctorado: Tecnología Agroambiental para una Agricultura Sostenible

Dirección de tesis:

Dr. Ingeniero Agrónomo María V. Gómez del Campo García-Valcárcel, Catedrática de Universidad, Universidad Politécnica de Madrid (Directora)

Dr. Ingeniero Agrónomo Ana María Tarquis Alfonso, Catedrática de Universidad, Universidad Politécnica de Madrid (Codirectora)

Revisores externos:

Tribunal de tesis:

Fecha de defensa:

Esta tesis ha sido financiada por la Comunidad de Madrid a través de convocatorias de subvenciones para la realización del Doctorado Industrial IND2020/AMB-17341.

*A mi familia*



# Tabla de contenido

Agradecimientos	vii
Abstract	viii
Resumen	xi
Doctorado Industrial	xiv
Lista de figuras	xv
Lista de tablas	xviii
Abreviaturas y acrónimos	xxi
1. Introducción	1
1.1 Retos agronómicos para el manejo de la heterogeneidad de las parcelas .....	1
2.1 Teledetección aplicada a la Agricultura .....	2
2.1.1 Base teórica .....	2
2.1.2 Plataformas .....	6
2.1.3 Sensores .....	8
2.2 Uso de sensores para caracterización de suelos .....	17
2.2.1 Propiedades de los horizontes del suelo .....	17
2.2.2 Clasificación de suelos. USDA y FAO .....	24
2.2.3 Prezonificación y zonificación .....	25
2.2.4 Sensores térmicos sobre UASs para diferenciación de suelos.....	29
2.2.5 Sensores multiespectrales para diferenciación de suelos y desarrollo vegetativo .....	30
2.3 Uso de sensores para caracterización del estado hídrico de las plantas .....	32
2.3.1 Indicadores del estado hídrico de las plantas .....	32
2.3.2 Sensores térmicos para caracterización del estado hídrico de las plantas.....	37
2. Objetivos de investigación	40
2 Material y métodos	41
3.1 Zona de estudio .....	41
3.1.1 Ubicación.....	41
3.1.2 Clima.....	42
3.1.3 Material vegetal .....	44
3.2 Equipos empleados .....	47
3.3 Ensayo 1: Caracterización de suelo .....	48
3.3.1 Localización y descripción de las viñas del Ensayo 1 .....	48
3.3.2 Parámetros evaluados .....	50

3.4	Ensayo 2: Caracterización del estado hídrico de las plantas .....	60
3.4.1	Localización y descripción de las viñas del Ensayo 2 .....	60
3.4.2	Parámetros evaluados .....	63
3.5	Análisis de datos .....	74
4	Resultados .....	76
4.1	Clima .....	76
4.2	Parámetros evaluados Ensayo 1: Caracterización del suelo .....	79
4.2.1	Prezonificación .....	79
4.2.2	Descripción de propiedades físicas y químicas de los horizontes. Clasificación.....	81
4.2.3	Zonificación .....	86
4.2.4	Características de las cepas.....	87
4.2.5	Caracterización del suelo con sensores térmico y multiespectral a bordo de UAS.....	98
4.2.6	Caracterización de las cepas mediante sensor multiespectral instalado en UAS.....	101
4.3	Parámetros evaluados Ensayo 2: Caracterización del estado hídrico de las plantas .....	105
4.3.1	Descripción de propiedades físicas y químicas de los horizontes. Clasificación.....	105
4.3.2	Características de las cepas.....	106
4.3.3	Caracterización de las cepas mediante sensores térmicos a bordo de UAS.....	128
5	Discusión .....	135
5.1	Discusión Ensayo 1: Caracterización de suelo.....	136
5.2	Discusión Ensayo 2: Caracterización estado hídrico de las plantas .....	140
6	Conclusiones .....	147
7	Referencias .....	151
8	Material complementario .....	174

# Agradecimientos

Primero que todo agradecer a mi directora María Gómez del Campo, por apoyarme y guiarme en todo este proceso. Su orientación y compromiso fueron fundamentales para superar los desafíos y alcanzar nuestros objetivos. A mi codirectora, Ana M Tarquis, su experiencia y dedicación fueron claves para el avance del proyecto. Agradezco sinceramente todas las reuniones, donde vuestra confianza y esfuerzo me motivaron a dar siempre lo mejor. Estaré eternamente agradecida a ambas por el apoyo y cariño brindado.

Agradezco a la Comunidad de Madrid por su apoyo financiero para realizar esta investigación

A mis jefes Julio y Jesús por su apoyo incondicional, gracias por confiar en mí y ayudarme en todo lo posible, y gracias por permitirme ser parte de la familia UTW. A Robert, gracias por ser el mejor compañero que haya podido tener. A Iván, por todo el conocimiento que ha compartido conmigo. A María y Jorge, gracias por vuestro apoyo y cariño.

A Mónica García, muchas gracias por todo el esfuerzo y trabajo invertido en mí, tus palabras me confortaron en los momentos más difíciles.

A la empresa Diagneterra, gracias por proporcionarme los datos necesarios para poder desarrollar mi investigación.

A los chicos de prácticas que estuvieron cada verano. Guardo en mi corazón todos los momentos compartidos bajo el sol de la Mancha. Sin ustedes, nada de este trabajo hubiera sido posible. A Gema y Juan, los mejores copilotos.

A las personas de Bodegas y Viñedos Casa del Valle, especialmente a Daniel por brindarme toda la ayuda necesaria y recibirnos siempre con los brazos abiertos. A Rubén y Nani por ayudarme incondicionalmente en nuestras jornadas de campo.

Agradecer a la maravillosa familia del CEIGRAM, al increíble equipo de gestión Esperanza, Katerina, Hamid y Carlos, que han dispuesto todas las herramientas necesarias para realizar mi tesis. A mis amigos Andrés y Ernesto, gracias por ayudarme no solo a nivel técnico sino a nivel emocional. Las penas con vosotros siempre se convirtieron en alegrías. Y a todos mis compañeros del CEIGRAM.

Y agradecer con todo mi corazón a mi familia, a mi madre Carmen y Ángel por nunca dejarme sola. A mi hermano Ismael por ser siempre la voz serena en mi vida. Y a mi padre, seguro que estarías muy orgulloso de mi. Os dedico este trabajo.

## Abstract

Recent years have witnessed adverse climatic conditions that have subjected viticulturists to increasingly frequent and extreme drought periods. In this context, the evaluation of the water status of the vine has become an essential tool to adapt agronomic practices and improve irrigation management. However, an important aspect of managing irrigation is understanding the spatial and temporal variability of vineyards, particularly in determining the water status of vines under such variability.

Variability is an intrinsic characteristic of the field and can be influenced by factors such as soil characteristics, irrigation, nutrition, pruning, inter-annual climate variability, etc. Platforms such as Unmanned Aerial Systems (UAS) are valuable tools for mapping spatial and temporal variability, facilitating vineyard monitoring with minimal operational costs.

Research aimed at developing crop management models that can dynamically simulate and integrate plant characteristics across different time frames is highly relevant at this time. The general objective of this study was to evaluate the variability of the water status of a commercial Merlot vineyard (*Vitis vinifera* L.) using thermal and multispectral images from UAS.

Two main factors that significantly influence the variability of the vineyard's water status are soil and irrigation. Regarding the first factor, this study aims to assess the contribution of UAS to zoning. For the second factor, the goal was to evaluate the ability of UAS to detect the water status of the vines.

Soil significantly influences vine vegetative development and yield. Under conditions of low water availability, soil is a determining factor in vine behavior. Therefore, it is necessary to understand the spatial variability of the soil.

The first specific objective of this work was to evaluate the UASs' ability to detect heterogeneity by assessing soil and vegetation information.

Under deficit irrigation, vine growth and yield variability are mainly determined by soil characteristics. A fundamental property is the water holding capacity (WHC). Various vegetation indices (VIs) and vegetative growth and yield parameters were evaluated in vines on two soils with different hydraulic (i.e. WHC) and physicochemical properties. Multispectral and thermal information from the UASs was obtained from these two soils.

Among the findings of this study, it was observed that under normal climatic conditions, the area with higher WHC had greater vegetative growth and yield. However, under conditions of extreme aridity, neither the vegetative indices nor

the agronomic and physiological parameters evaluated in the field showed differences between the vines in the two study areas. On the other hand, the spectral and thermal bands of the soil showed significant differences between the two soils in both years. This indicated that the spectral and thermal characteristics of the soil could provide more reliable information for zoning than the vine vegetation itself, as they were less influenced by climatic conditions. Consequently, UASs have proven to be valuable for evaluating spatial and temporal heterogeneity in vineyard monitoring. The spectral and thermal soil information they provide is essential for zoning applications, as it demonstrates consistency over different years, contributing to improving vineyard management practices.

The second specific objective of this work was to evaluate the potential of thermal indices calculated from high-resolution thermal images captured by UASs to assess the water status of the vine.

Based on thermal information from leaves/canopy, recognized as a good indicator of plant water status, we evaluated the robustness of thermal indices based on their ability to estimate Stem Water Potential (SWP) as a reference physiological indicator.

Canopy temperature data ( $T_c$ ) were obtained from UAS flights at specific times of the day (9:00, 12:00 solar time) of vines under five different irrigation treatments. The Crop Water Stress Index (CWSI) was calculated using three different methodologies: Jackson's methodology (CWSI\_J), Wet Reference-based Methodology (CWSI\_W), and Bellvert's methodology (CWSI\_B). The difference between canopy temperature and air temperature ( $T_c - T_a$ ) served as the benchmark to overcome as a simple indicator.

SWP, stomatal conductance ( $g_s$ ), and leaf temperature ( $T_L$ ) were acquired at the time of the flights and compared with the thermal indices to calibrate linear models (CWSIs and  $T_c - T_a$ ).

Among the findings of this study, on the one hand, the effect of the time of day in determining plant water status was observed. All indices showed a better relationship with SWP at 12:00 than at 9:00. On the other hand, it is confirmed that the  $T_c - T_a$  index can identify variable crop hydration levels using temperature values ( $T_c$ ) better than indices such as CWSI\_B or CWSI\_W at 12:00 h. However,  $T_c - T_a$  is less robust under conditions of high evaporative demand. Instead, CWSI\_J emerges as a suitable alternative from a climate change perspective in the face of increased heat and aridity, with robust behavior on different days and times of the day. However, several climatic parameters are required to estimate CWSI\_J.

The set of results obtained in this thesis highlights the use of high-resolution images captured by UASs to capture spatial and temporal heterogeneity in the

field in a timely and efficient manner, regardless of the source of plant variability (soil or climate and/or irrigation).

# Resumen

Los últimos años han sido testigos de condiciones climáticas adversas que han sometido a los viticultores a periodos de sequía cada vez más frecuentes y extremos. En este contexto, la evaluación del estado hídrico de la vid se ha vuelto una herramienta esencial para adaptar las prácticas agronómicas y mejorar la gestión del riego. Sin embargo, un aspecto importante a la hora de gestionar el riego es conocer la variabilidad espacial y temporal de los viñedos. Especialmente, poder determinar el estado hídrico de las cepas bajo esa variabilidad.

La variabilidad es una característica intrínseca del campo y puede venir influenciada por características del suelo, riego, nutrición, poda, variabilidad climática entre años, etc.

Plataformas como vehículos aéreos no tripulados (Unmanned Aerial System - UAS) se presentan como una herramienta valiosa para mapear la variabilidad espacial y temporal, facilitando la monitorización de los viñedos con un costo operativo mínimo.

La investigación dirigida a desarrollar modelos de manejo de cultivos que pueden simular e integrar dinámicamente características de las plantas en diferentes marcos temporales, es de gran relevancia en estos momentos.

El objetivo general de este estudio fue evaluar la variabilidad del estado hídrico de un viñedo comercial de Merlot (*Vitis vinifera* L.) mediante imágenes térmicas y multiespectrales utilizando UASs.

Dos factores principales que influyen en gran medida en la variabilidad del estado hídrico del viñedo son el suelo y el riego. Respecto al primer factor, se pretende evaluar la contribución de los UAS a la zonificación, Con el segundo factor, se pretendía evaluar la capacidad de los UAS para detectar el estado hídrico de las cepas.

El suelo influye en gran medida en el desarrollo vegetativo y rendimiento de la vid. Bajo condiciones de baja disponibilidad hídrica, el suelo es un factor determinante en el comportamiento de la vid. Por tanto, es necesario conocer la variabilidad espacial del suelo.

El primer objetivo específico de este trabajo fue evaluar la capacidad de los UASs para detectar la heterogeneidad evaluando información de suelo y vegetación.

Bajo riego deficitario, el crecimiento de la vid y la variabilidad del rendimiento queda determinado principalmente por las características del suelo. Una propiedad fundamental es la capacidad de retención de agua (CRA). Se evaluaron varios índices de vegetación (IVs) y parámetros de crecimiento vegetativo y rendimiento en cepas ubicadas en dos suelos con propiedades hidráulicas (CRA) y fisicoquímicas diferentes. De estos dos suelos se obtuvo información multiespectral y térmica proveniente del UAS.

Entre los hallazgos de este estudio, se observó que en condiciones climáticas normales la zona con mayor CRA tuvo mayor crecimiento vegetativo y rendimiento. Sin embargo, bajo condiciones de aridez extrema, ni los índices vegetativos ni los parámetros agronómicos y fisiológicos evaluados en campo, mostraron diferencias entre las cepas de las dos zonas de estudio. Por otro lado, las bandas espectrales y térmicas del suelo mostraron diferencias significativas entre los dos suelos en ambos años. Esto indicó que las características espectrales y térmicas del suelo podrían proporcionar información más confiable para la zonificación que la vegetación de la vid en sí misma, ya que estaban menos influenciadas por las condiciones climáticas. En consecuencia, los UASs han demostrado ser valiosos para evaluar la heterogeneidad espacial y temporal en el monitoreo de los viñedos. La información espectral y térmica del suelo que proporcionan es esencial para aplicaciones de zonificación, ya que demuestra consistencia a lo largo de diferentes años, lo que contribuye a mejorar las prácticas de gestión del viñedo.

El segundo objetivo específico de este trabajo fue evaluar el potencial de índices térmicos calculados a partir de imágenes térmicas de alta resolución a bordo de UASs para evaluar el estado hídrico de la vid.

Basándonos en la información térmica de hojas/dosel, reconocido como un buen indicador del estado hídrico de las plantas, evaluamos la robustez de índices térmicos en base a su capacidad para estimar el potencial hídrico del tronco (PHT) como indicador fisiológico de referencia.

Se obtuvieron datos de temperatura del dosel ( $T_c$ ) a partir de vuelos de UAS en momentos específicos del día (9:00, 12:00 hora solar) de cepas bajo cinco tratamientos de riego diferenciado. Se calculó el Índice de Estrés Hídrico del Cultivo (Crop Water Stress Index - CWSI) bajo tres métodos diferentes: metodología de Jackson (CWSI\_J), metodología basada en referencia artificial húmeda (CWSI\_W) y metodología de Bellvert (CWSI\_B). La diferencia entre la temperatura del dosel y la temperatura del aire ( $T_c - T_a$ ) fue el punto de referencia a superar como indicador simple.

SWP, conductancia estomática (gs) y la temperatura de la hoja (TL) se adquirieron en el momento de los vuelos y se compararon con los índices térmicos para calibrar modelos lineales (CWSIs y Tc-Ta).

Entre los hallazgos de este estudio encontramos, por un lado, el efecto del momento del día a la hora de determinar el estado hídrico de las plantas. Todos los índices mostraron una mejor relación con el PHT a las 12:00 que a las 9:00. Por otro lado, se confirma que el índice Tc-Ta puede identificar niveles variables de hidratación del cultivo utilizando valores de temperatura (Tc) mejor que índices como CWSI\_B o CWSI\_W a las 12:00 h. Sin embargo, Tc-Ta es menos robusto bajo condiciones de alta demanda evaporativa. En cambio, CWSI\_J se presenta como una alternativa adecuada desde una perspectiva de cambio climático ante el aumento de calor y aridez, con un comportamiento robusto en diferentes días y momentos del día. Sin embargo, se requieren varios parámetros climáticos para estimar el CWSI\_J.

El conjunto de los resultados obtenidos en esta tesis pone de manifiesto el uso de imágenes de alta resolución obtenidas de UASs para capturar la heterogeneidad espacial y temporal en campo de manera oportuna y eficiente, independientemente de la fuente de variabilidad de las plantas (suelo o clima y/o riego).

## Doctorado Industrial

El trabajo realizado en esta tesis se enmarca en la colaboración entre la empresa Unmanned Technical Works (UTW) y la Universidad Politécnica de Madrid, a través de la convocatoria de ayudas para la realización de doctorados industriales de la Comunidad de Madrid (IND2020/AMB-17341).

El objetivo general de este estudio es evaluar el comportamiento de la vid en respuesta a diferentes estrategias de riego deficitario y su relación fisiológica con imágenes térmicas y espectrales obtenidas mediante UAS (sistemas aéreos no tripulados). De esta forma, se pretende obtener una vasta fuente de datos que posteriormente serán analizados y tratados con avanzadas herramientas matemáticas y TIC, permitiendo finalmente desarrollar soluciones para la toma de decisiones de riego de manera rápida y eficaz.

Los resultados de este estudio tienen como finalidad mejorar la gestión de los recursos, permitiendo un incremento en la productividad del cultivo y reduciendo el impacto ambiental de las prácticas agrícolas. El uso de plataformas de teledetección contribuye a la reducción de costes operativos en la agricultura, mejorando la competitividad de las empresas agrícolas que adopten estas tecnologías.

Este tipo de trabajo pone en valor la necesidad de colaborar con empresas del sector tecnológico y agrícola. Conociendo las necesidades de ambos, se puede diseñar soluciones que permitan alcanzar los objetivos del proyecto.

Gracias a estas ayudas se pudo publicar un artículo en Remote Sensing titulado “Multispectral and Thermal Sensors Onboard UAVs for Heterogeneity in Merlot Vineyard Detection: Contribution to Zoning Maps” <https://doi.org/10.3390/rs15164024>

Y Otro que actualmente está en avanzado proceso de revisión en la revista Irrigation Science titulado “Thermal imaging from UAS for estimating crop water status in a Merlot 1 vineyard in semi-arid conditions”

Ambos trabajos conforman el contenido de este estudio.

# Lista de figuras

Figura 1.2.1. Principales bandas espectrales dentro del espectro electromagnético. (Chuvienco, 2016)	3
Figura 1.2.2. Firma espectral para diferentes materiales sobre la tierra (Chuvienco, 2016)	4
Figura 1.2.3. Reflectancia espectral de una hoja verde sana (Chuvienco, 2016)	5
Figura 1.2.4. Espectro electromagnético. Zona de radiación infrarroja reflejada(700-3000nm) y radiación infrarroja emitida (3000-100000nm) (Messina and Modica, 2020).	11
Figura 1.3.1. Nomenclatura de los horizontes genéticos del perfil del suelo (Instituto Geográfico Nacional, 2006)	23
Figura 3.1.2. Estación meteorológica portátil situada dentro del seto, midiendo la temperatura del aire. Incluye un datalogger y un termopar conectado a una referencia artificial húmeda (RAH) compuesta por una bayeta amarilla constantemente húmeda.	44
Figura 3.1.3. Detalle cepa de Merlot	45
Figura 3.2.1. Imagen Superior: Plataforma UAS de ala fija. Imagen inferior izquierda: cámara térmica Duet-T (AgEagle, 2022). Imagen inferior derecha: Sensor multiespectral Parrot Sequoia (Parrot, 2021)	47
Figura 3.3.2. Fotografía aérea del viñedo experimental. Las líneas indican la zonificación preliminar del suelo del viñedo comercial. El recuadro rojo representa la parcela 12 de estudio. El recuadro verde representa la zona experimental dentro de la parcela de estudio. Las cepas de estudio se encuentran en los círculos rojos dentro del recuadro verde.	51
Figura 3.3.3. Ficha de campo (modelo) y resumen de codificación simple (Instituto Geográfico Nacional, 2006)	54
Figura 3.3.4. Captura de pantalla del programa ImageJ utilizado para obtener el valor porcentual de los poros de las cepas transformando las imágenes RGB.	56
Figura 3.3.5. Detalle de imagen multiespectral con la ubicación del dosel experimental de enredadera (a) y suelo (b) en una de las parcelas de suelo de estudio (C1).	59
Figura 3.4.1. Imagen izquierda: Localización de la parcela 11 de estudio. Imagen derecha: Detalle de la localización de los cinco tratamientos de riego.	61
Figura 3.4.2. Ubicación de la estación meteorológica portátil	67
Figura 3.4.3 Representación de los flujos de energía.	71
Figura 4.2.1. Detalle del mapa de suelos correspondiente a la prezonificación en el Ensayo 1. El rectángulo rojo indica la zona experimental, las ubicaciones de las dos calicatas de suelo (C1 y C2) se indican con puntos rojos.	80

Figura 4.2.2. Imagen del perfil de los suelos de estudio con los horizontes (a) Suelo calicata 1 (C1); (b) Suelo calicata 2 (C2).	81
Figura 4.2.3. Detalles del mapa de suelos correspondiente a la zonificación final de la zona experimental.	86
Figura 4.2.4. Estados fenológicos	87
Figura 4.2.5. Seguimiento de maduración. Contenido de sólidos solubles ( $^{\circ}$ Brix); pH; TA, acidez total (g de tartárico $\cdot$ L $^{-1}$ ) y peso de baya (g) de las cepas de las dos calicatas (C1 y C2) en el año 2021 a), c), e) y el año 2022 b), d), f).	95
Figura 4.2.6 Seguimiento de maduración. Peso de baya (g) de las cepas de las dos calicatas (C1 y C2) en el año 2021 a) y el año 2022 b).	96
Figura 4.2.7. Histograma de cada banda multispectral de la superficie del suelo de las cepas experimentales cercanas (C1 y C2) en el viñedo (Toledo, España) basado en 500 píxeles para cada sitio. Las dos primeras filas corresponden a 2021 (-21), y el resto corresponden a 2022 (-22). Las bandas son borde rojo (a, e); rojo (b, f); NIR (c, g); y verde (d, h).	99
Figura 4.2.8. Índices de vegetación correspondiente a los suelos de estudio (C1 y C2) ubicadas cerca de las cepas experimentales (Toledo, España). La primera fila corresponde a 2021, y la segunda fila corresponde a 2022. Los índices son NDVI (a, d); RVI (b, e); y GNDVI (c, f). Niveles de significancia estadística (Sig.): ns, no significativo; * $p < 0.05$ ; ** $p < 0.01$ . Las estadísticas se basan en 500 píxeles por cada tipo de suelo (C1 y C2).	100
Figura 4.3.1. Mapa de zonificación de los suelos de la zona de estudio.	106
Figura 4.3.2 Potencial hídrico del tronco (PHT, MPa) a las 9:00 y 12:00 en ambos años (2021, 2022) según los tratamientos de riego (T100, T50, T25, T0 y T25-S). Niveles de significancia estadística: ns, no significativo; medias con letra distinta son significativamente diferentes, $p < 0.05$	110
Figura 4.3.3 Conductancia estomática $g_s$ (mmol/m $^{-2}$ s $^{-1}$ ) a las 9:00 y 12:00 en ambos años (2021, 2022) según los tratamientos de riego (T100, T50, T25, T0 y T25-S). Niveles de significancia estadística: ns, no significativo; medias con letra distinta son significativamente diferentes, $p < 0.05$	112
Figura 4.3.4 Relación entre PHT y $g_s$ a las 9:00, (a). Relación entre PHT y $g_s$ a las 12:00 (b) (las ecuaciones de regresión se obtuvieron considerando todas las fechas para todos los tratamientos y todas las fechas para los tratamientos por separado)	114
Figura 4.3.5 Clorofila (Chl, micromol/m $^2$ ) a las 9:00 y 12:00 en ambos años (2021, 2022) según los tratamientos de riego (T100, T50, T25, T0 y T25-S). Niveles de significancia estadística: ns, no significativo; medias con letra distinta son significativamente diferentes, $p < 0.05$	116
Figura 4.3.6 Temperatura de la hoja (TL) a las 9:00 y 12:00 en ambos años (2021, 2022) según los tratamientos de riego (T100, T50, T25, T0 y T25-S). Niveles de significancia estadística: ns, no significativo; medias con letra distinta son significativamente diferentes, $p < 0.05$	118

Figura 4.3.7 Temperatura de la copa de las cepas (Tc) a las 9:00 y 12:00 en ambos años (2021, 2022) según los tratamientos de riego (T100, T50, T25, T0 y T25-S). Niveles de significancia estadística: ns, no significativo; medias con letra distinta son significativamente diferentes, $p < 0.05$	120
Figura 4.3.8: Seguimiento de maduración. Contenido de sólidos solubles ( $^{\circ}$ Brix); pH y TA, acidez total (g de tartárico-L-1) de las cepas de los 5 tratamientos de riego (T100, T50, T25, T0 y T25-S) en el año 2021 a), c), e) y en el año 2022 b) y d)	125
Figura 4.3.9: Seguimiento de maduración. Peso de baya (g) de las cepas de los 5 tratamientos de riego (T100, T50, T25, T0 y T25-S) en el año 2021 a) y en el año 2022 b)	126
Figura 4.3.10. Evolución de Tc-Ta por tratamientos de riego (T100, T50, T25, T0 y T25-S) a las 9:00 a) y 12:00 b) en dos años (2021 y 2022)	128
Figura 4.3.11. Evolución de modelos CWSI (CWSI_J, CWSI_W, CWSI_B) por tratamientos de riego (T100, T50, T25, T0 y T25-S) a las 9:00 y 12:00 en dos años (2021 y 2022)	130
Figura 4.3.12. Relación entre los indicadores térmicos y el Potencial Hídrico del Tronco (PHT) a las 9:00 en 2021 (círculos rellenos) y 2022 (círculos) y a las 12:00 en 2021 (rectángulos rellenos) y 2022 (rectángulos). La línea discontinua es la relación media de ambos años y horas.	132
Figura 4.3.13: Matriz de correlación de Pearson para indicadores térmicos y parámetros fisiológicos a las 9:00.	133
Figura 4.3.14: Matriz de correlación de Pearson para indicadores térmicos y parámetros fisiológicos a las 12:00.	134

## Lista de tablas

Tabla 1.2.1. Características de algunos de los principales plataformas y sensores utilizados en teledetección.	7
Tabla 1.2.2. Principales parámetros de algunas de las cámaras térmicas más usadas a bordo de UASs (Starket et al., 2014)	14
Tabla 1.2.3. Principales parámetros de algunas de las cámaras multispectrales más usadas (Deng et al, 2018).	16
Tabla 3.1.1. Datos climatológicos, estación climatológica de Magán-Toledo serie 20 años	43
Tabla 3.2.1. Parámetros de los sensores multispectrales y térmicos instalados en el UASs utilizados en todos los vuelos del estudio.	48
Tabla 3.3.1. Horas y dosis de riego totales del ensayo	49
Tabla 3.3.2. Procedimientos realizados en laboratorio para analizar las propiedades físicas y químicas (PFs y PQs) de los suelos de los dos ensayos.	53
Tabla 3.3.3. Calendario de las imágenes obtenidas sobre las superficies de estudio, vegetación y suelo, realizadas con cámaras térmica y multispectral instaladas en el UAS durante los dos años de estudio (2021 y 2022)	58
Tabla 3.3.4. Índices de vegetación calculadas a partir de las bandas multispectrales del sensor a bordo del UAS.	60
Tabla 3.4.1. Descripción de los cinco tratamientos de riego durante dos años del estudio en el viñedo experimental (Toledo, España).	62
Tabla 3.4.2. Descripción de las horas y dosis de riego de los diferentes tratamientos durante los dos años de estudio (2021 y 2022).	62
Tabla 3.4.2. Ecuaciones y variables utilizadas para estimar $R_{ndiario}$ . $S_i$ (MJ/m <sup>2</sup> /día) radiación de onda corta entrante obtenida de la estación de Magán. $J$ factor de conversión Día-inst utilizado cuando solo una observación durante el día de radiación neta se escala de instantánea a diaria. Duración del día $N$ (h), tiempo $t$ de desfase entre la hora de salida del sol de NOAA (Administración Nacional Oceánica y Atmosférica) y la hora de vuelo del UAS (h). $\epsilon_a$ emisividad del aire, $\epsilon_s$ emisividad de la superficie del cultivo/dosel, $\sigma$ constante de Stefan-Boltzmann ( $5.67 \times 10^{-8} \text{ W} \cdot \text{m}^{-2} \cdot \text{K}^{-4}$ ), $T_c$ temperatura de la superficie del cultivo/dosel (K), $T_a$ temperatura del aire (K).	73
Figura 4.1.1. Evolución de las temperaturas, ETo y precipitaciones de los dos años de estudio en comparación con la serie de 30 años.	77
Tabla 4.1.1. Temperatura ( $T_a$ ), humedad relativa (HR) y déficit de presión de vapor (DPV) dentro del dosel los días de vuelo del UAS a las 9:00 y 12:00. Evapotranspiración de referencia diaria (ETo) para cada fecha.	79

Tabla 4.2.1. Características macromorfológicas de los horizontes de las calicatas (C1 y C2).	82
Tabla 4.2.2. Propiedades físicas de los horizontes de dos calicatas (C1 y C2).	83
Tabla 4.2.3. Propiedades químicas de los horizontes de dos calicatas (C1 y C2).	84
Tabla 4.2.4. Propiedades de los horizontes de las calicatas (C1 y C2): densidad aparente (Da), agua disponible (AD), grava y capacidad de retención de agua (CRA).	85
Tabla 4.2.5. Potencial hídrico del tronco (PHT, MPa) medido a las 9:00 y 12:00 (hora solar) en los días del vuelo de UAS de las cepas de las dos calicatas (C1 y C2). Cada valor representa una media de seis cepas por tipo de suelo. DE, desviación estándar.	89
Tabla 4.2.6. Contenido de clorofila foliar (Chl, micromol/m <sup>2</sup> ), medido a las 9:00 y 12:00 (hora solar) en los días del vuelo de UAS, de las cepas de las dos calicatas (C1 y C2) ubicados en el viñedo experimental (Toledo, España). Cada valor representa la media de seis cepas por tipo de suelo. DE: Desviación Estándar.	91
Tabla 4.2.7. Crecimiento vegetativo de la planta: contorno de la espaldera, ancho, altura, superficie foliar externa (SA), volumen, poros (%), y peso de madera de poda en dos calicatas (C1 y C2) ubicados en el viñedo experimental (Toledo, España). Cada valor representa la media de seis cepas por tipo de suelo o calicata. DE, desviación estándar.	93
Tabla 4.2.8. Parámetros de rendimiento y madurez. Número de racimos por vid. Rendimiento (kg/vid). SC, contenido de sólidos solubles (°Brix); pH; TA, acidez total (g de tartárico·L <sup>-1</sup> ) de las cepas de las dos calicatas (C1 y C2). Cada valor representa una media de seis cepas por tipo de suelo. DE, desviación estándar.	97
Tabla 4.2.9. La temperatura de la superficie del suelo (°C) para cada calicata (C1 y C2). Cada valor representa una media de 300 píxeles para cada tipo de suelo. DE, desviación estándar.	98
Tabla 4.2.10. Índices de vegetación obtenidos a partir de imágenes multiespectral a las 12:00 en la temporada 2021.	103
Tabla 4.2.11. Índices de vegetación obtenidos a partir de imágenes multiespectral a las 12:00 en la temporada 2022.	104
Tabla 4.3.1. Evolución fenológica de los tratamientos de riego durante las dos campañas de riego.	107
Tabla 4.3.2 Crecimiento vegetativo de la planta en el 2021: contorno de la superficie foliar, ancho del dosel, altura del dosel, área de superficie foliar externa (SA), volumen, poros (%), y peso de madera de poda (MP) de las cepas en los 5 tratamientos de riego. Cada valor representa una media de seis cepas por tipo de suelo o calicata. DE, desviación estándar.	122
Tabla 4.3.3 Crecimiento vegetativo de la planta en el 2022: contorno, ancho, altura, área de superficie foliar externa (SA), volumen, poros (%), y peso de madera de poda (MP) de las cepas en los 5 tratamientos de riego. Cada valor representa una media de seis cepas por tipo de suelo o calicata. DE, desviación estándar	123

Tabla 4.3.4. Vendimia: Producción (Prod), peso de la baya (B) y calidad del mosto; contenido de sólidos solubles (SST); pH; acidez total (TA) de las cepas de los 5 tratamientos de riego en el año 2021 y 2022. Cada valor representa una media de seis cepas por tratamiento de riego DE, desviación estándar. 127

S4. Temperatura de la hoja (TL) a las 9:00 y 12:00 en ambos años (2021, 2022) según los tratamientos de riego (T100, T50, T25, T0 y T25-S). 177

## Abreviaturas y acrónimos

$\alpha$ - Albedo  
AD- Agua Disponible  
AEMET- Agencia Estatal de Meteorología  
B- peso de la baya  
CIC- Capacidad de Intercambio Catiónico  
CE- Conductividad Eléctrica  
Chl- Clorofila  
COS- Carbono Orgánico del Suelo  
Cp- Calor específico del aire ( $J\ kg^{-1}\ ^\circ C$ )  
 $\sigma$ - Constante de Stefan-Boltzmann ( $5.67 \times 10^{-8}\ W\ m^{-2}\ K^{-4}$ )  
CRA- Capacidad de Retención de Agua  
CWSI- Crop Water Stress Index  
Da- Densidad aparente  
DPV- Déficit de Presión de Vapor  
 $\epsilon_a$ - Emisividad atmosférica  
 $\epsilon_s$ - Emisividad de la superficie  
ea- Presión de vapor real del aire (Pa)  
ec- Presión de vapor saturado a la temperatura de la cubierta vegetal- (Pa)  
E- Evapotranspiración de referencia  
EC- Conductividad Eléctrica  
Ep- Evapotranspiración potencial  
ET- Evapotranspiración  
FAO- Food and Agriculture Organization  
G- Flujo de calor que se almacena en el suelo por conducción  
GNDVI- Índice de Vegetación de la Diferencia Normalizada Verde  
H- Flujo de calor sensible  
Hc- Flujo de calor sensible proveniente del dosel  
HR- Humedad Relativa  
IPAR- Incident photosynthetically active radiation  
IVs- Indices de Vegetación  
J- Factor de conversión Día-instantáneo  
K- Constante de Von Kerman  
LW -Radiación de onda larga  
LW<sub>atm</sub> -Radiación de onda larga ascendente desde la atmósfera hasta el sensor  
LW<sub>in</sub>- Radiación de onda larga entrante  
LW<sub>out</sub>- Radiación de onda larga emitida  
LW<sub>sensor</sub>- Radiación de onda larga de la imagen térmica  
MO- Materia Orgánica  
MP- Madera poda  
ND- Número Digital  
NDRE- Índice Normalizado Diferencial de Borde Rojo  
NDVI- Normalized Difference Vegetation Index  
NIR- Near Infrared

OSAVI- Índice De Vegetación Ajustado Al Suelo Optimizado  
PHT- Potencial Hídrico del Tronco  
PMP- Punto de Marchitez Permanente  
Prod- Producción  
ra- Resistencia aerodinámica  
rc- Resistencia del cultivo  
rcp- Resistencia potencial del dosel para un cultivo sin estrés hídrico  
RAH- Referencia Artificial Humeda  
Rn- Radiación neta  
RVI- Ratio vegetacion index  
SA- Superficie Foliar Externa  
SH- Altura de referencia del sensor  
Si- Radiación solar entrante (incoming) a la superficie  
So- Radiación solar saliente (reflejada, outgoing) en la superficie  
SR- Índice de Vegetación de Relación Simple  
SST Sólidos solubles  
SW- Radiación de onda corta diaria  
SWIR- Shortwave infrarojo  
Ta Temperatura del aire  
TA- Acidez total  
Ta\_seto- Temperatura del aire dentro del seto  
Tc- Temperatura del cultivo  
TCARI- Índice de Reflectancia de Absorción de Clorofila  
Thumedo- Temperatura de referencia húmeda  
Ts- Temperatura del sensor térmico sin corregir  
Tseco Referencia de temperatura seca  
TIR- Thermal Infrared  
Tkin- Temperatura Cinética  
Trad- Temperatura medida por un sensor o de radiación  
USDA- United States Department of Agriculture  
VIS- Visible  
U- Velocidad del viento  
UAS Unmanned Aerial System  
VSWIR- Visible to Shortwave Infrared

# 1. Introducción

## 1.1 Retos agronómicos para el manejo de la heterogeneidad de las parcelas

La agricultura se encuentra actualmente ante desafíos significativos, ya que debe incrementar la producción de alimentos para satisfacer las necesidades de una población en constante crecimiento, todo ello de manera sostenible y afrontando limitaciones cada vez más restrictivas en cuanto a los recursos disponibles. A su vez, cada año se enfrenta a situaciones imprevisibles derivadas de los impactos del cambio climático.

A consecuencia del cambio climático, es crucial un uso racional de los recursos hídricos, lo que requiere una gestión del agua eficiente y toma de decisiones en condiciones de alta incertidumbre (FAO, 2021). Esta situación es especialmente grave en zonas áridas y semiáridas de España.

En España, la viña (*Vitis vinifera* L.) se encuentran en tercer lugar entre los cultivos leñosos más importantes, después del olivar y los árboles frutales no cítricos (ESYRCE, 2023). La superficie dedicada a viñedos para la producción de vino asciende a casi 1 millón de hectáreas, el 40% de ellas se encuentran bajo regadío.

Factores ambientales, de topografía y de suelos influyen en variaciones en el desarrollo de la vid (Hall et al., 2003). Conocer esta variabilidad es necesaria para gestionar cada unidad homogénea de forma independiente, proporcionando insumos óptimos a cada una, especialmente el riego (Madruga et al., 2015).

En regiones semiáridas, el crecimiento de la vid está frecuentemente expuesto al estrés hídrico (Costa et al., 2016; Van Leeuwen et al., 2018), lo que impacta en el desarrollo vegetativo y reproductivo, la composición de la fruta y la calidad del vino (Van Leeuwen et al., 2018). La cantidad y el momento del riego juegan un papel crucial no solo para lograr altos rendimientos, sino también en la calidad (Intrigliolo et al., 2010). Para poder hacer una planificación de riego eficiente, el conocimiento de la variabilidad es un requisito indispensable. En la vid, las estrategias de riegos influyen en la acumulación de azúcar y compuestos fenólicos en la baya, pudiendo reducir la calidad del vino significativamente bajo estrés

hídrico severo (Van Leeuwen et al., 2018, 2009). Por tanto, la planificación efectiva del riego basada en la gestión adaptativa en el tiempo y el espacio es necesaria para obtener buenos rendimientos en la vid.

## **1.2 Teledetección aplicada a la Agricultura**

Una herramienta adecuada para un manejo acorde a la variabilidad de los cultivos es la teledetección. La teledetección para aplicaciones agrícolas tiene como objetivo proporcionar información espacial y espectral de parámetros de la superficie, permitiendo la clasificación y cartografía de cultivos (Berni et al 2009).

Las tecnologías de teledetección óptica han proporcionado herramientas para aumentar la comprensión de los procesos fisiológicos, principalmente aquellos relacionados con el estrés en las plantas (Berger et al, 2022). Los estudios de teledetección para aplicaciones agrícolas han aumentado en las últimas décadas impulsados por nuevas plataformas y sensores con resoluciones mejorados (Weiss et al., 2020).

La teledetección es considerada un método cuantitativo no destructivo que cuenta con herramientas como la espectroscopía de imágenes, la espectroscopía de fluorescencia, de microondas y la teledetección térmica que, separadas o en combinación, proporcionan información sobre el efecto del estrés (biótico o abiótico) en las plantas.

### **1.2.1 Base teórica**

La teledetección se basa en conceptos físicos sólidos, ya que implica la recopilación de señales electromagnéticas provenientes de objetos con diferentes propiedades físicas y químicas (Chuvieco, 2016).

La base de la teledetección consiste en la radiación reflejada o emitida desde la superficie terrestre por elementos como el suelo, el agua, la vegetación, etc. proporcionando información crucial sobre sus propiedades. Es decir, se trata de comprender como interactúa la energía electromagnética con la superficie.

La teledetección óptica utiliza sensores o cámaras para recopilar dicha información de los objetos. Cubre longitudes de onda desde el visible hasta el infrarrojo de onda corta (VSWIR, 400-2500 nm) y el infrarrojo térmico (TIR, 800-1400 nm), recopilando la radiación reflejada y emitida desde las superficies observadas (Figura 1.2.1). Cuando se trata de la detección de respuestas de las plantas a

diversos tipos de estrés, la reflectancia en el visible (VIS, 400-700 nm), el infrarrojo cercano (NIR, 700-1300 nm) y el infrarrojo de onda corta (SWIR, 1300-2500 nm) y el TIR (800-1400 nm) han sido las señales de detección pasiva más explotadas (Gerhards et al., 2019).




Figura 1.2.1. Principales bandas espectrales dentro del espectro electromagnético. (Chuvieco, 2016)

La proporción de energía incidente que se refleja, absorbe y transmite es una función de las características únicas de la superficie. Esta proporción varía con la longitud de onda, de hecho, la forma en que la radiación solar interactúa con la superficie terrestre produce variaciones en la longitud de onda, lo que puede decirnos mucho sobre las propiedades químicas y físicas de la superficie. En el caso de la vegetación, una hoja parecerá verde si su reflectancia en longitudes de onda verdes es mayor que su reflectancia en las porciones azul o roja del espectro visible. En la parte visible del espectro, la variación en el comportamiento de la reflectancia de un objeto sobre las longitudes de onda visibles da como resultado lo que se denomina 'color' (Chuvieco, 2016)



Figura 1.2.2. Firma espectral para diferentes materiales sobre la tierra (Chuvienco, 2016)

El comportamiento de la reflectancia de un objeto sobre varias longitudes de onda del espectro electromagnético se conoce comúnmente como una firma de reflectancia espectral o simplemente firma espectral (Figura 1.2.2).

La vegetación tiene firmas únicas de reflectancia espectral con una baja reflectancia en el espectro visible (VIS), una alta reflectancia en el infrarrojo cercano (NIR) y una baja reflectancia en la porción de infrarrojo de onda corta (SWIR) del espectro. Las firmas espectrales de la vegetación se ven modificadas por el tipo y la morfología de las hojas, su fisiología, el contenido de clorofila, el estrés de la planta y la senescencia. Por otro lado, los suelos tienen firmas de reflectancia espectral que aumentan gradualmente con longitudes de onda crecientes, de una manera dependiente de su contenido de hierro, materia orgánica, agua, minerales y sales. La firma espectral de un suelo también será modificada por sus propiedades estructurales y morfológicas en la superficie (Chuvienco, 2016).

Las propiedades de reflectancia de una hoja están principalmente relacionadas con los niveles de pigmentos fotosintéticos y agua de la hoja, así como con sus características estructurales. La firma espectral general de una hoja o planta también se ve afectada por la edad de la hoja, el estrés por nutrientes y la salud

(enfermedades, vigor, etc.). Una firma de reflectancia espectral típica de una hoja verde obtenida a partir de mediciones de laboratorio se muestra en la Figura 1.2.3.

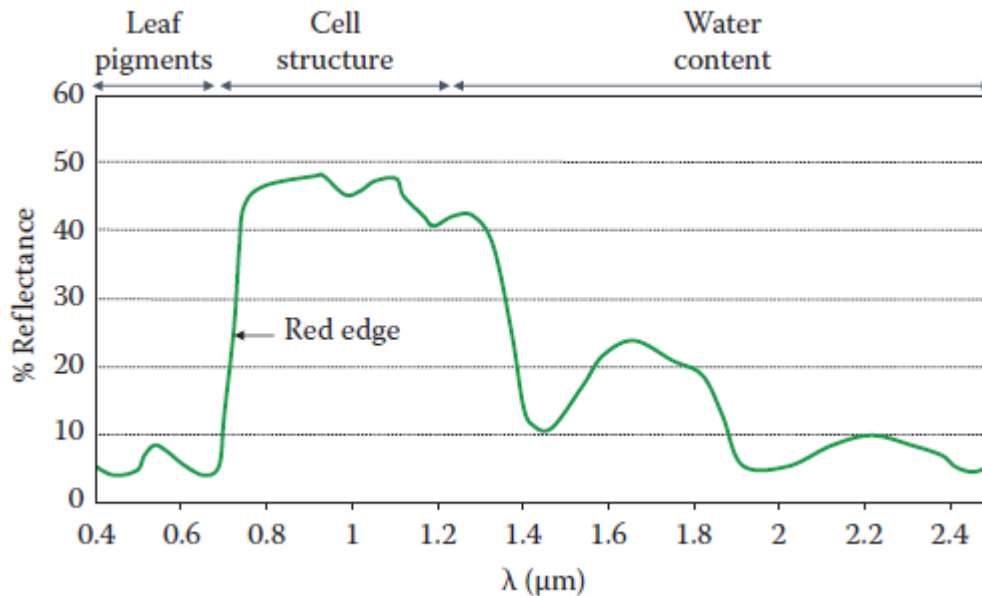


Figura 1.2.3. Reflectancia espectral de una hoja verde sana (Chuvieco, 2016)

La clorofila no absorbe toda la luz del sol uniformemente. La baja reflectancia en la región del VIS (400-700 nm) se debe al efecto absorbente de los pigmentos de la hoja, principalmente clorofila a, clorofila b, carotenoides y xantofilas, siendo los pigmentos de clorofila responsables del 60%–75% de la energía absorbida (Gates et al. 1964). Todos estos pigmentos absorben en la región "azul" del espectro electromagnético centrado en longitudes de onda  $\sim 450\text{nm}$ , mientras que la clorofila también absorbe en la porción "roja" del espectro, centrada en  $\sim 650\text{nm}$ . Entre las regiones espectrales azul y roja, hay una región espectral de radiación menos intensamente absorbida, un "pico de reflectancia verde" en  $550\text{nm}$ , que es responsable del aspecto verde de las hojas saludables. Debido a que la energía en el rango de 400-700 nm es absorbida por los pigmentos para impulsar la fotosíntesis, a menudo se utiliza el término radiación fotosintéticamente activa incidente (IPAR) para describir la radiación en la parte visible del espectro (Chuvieco 2016).

Hay muchas características comunes en la mayoría de los espectros de vegetación, como el alto contraste observado entre la banda roja (645 nm) y la región del NIR (700-1300 nm). En general, se puede decir que cuanto mayor sea el contraste entre estas dos regiones, mayor será la cantidad y el vigor de la vegetación. Este

comportamiento espectral teórico de la vegetación en el espectro "rojo" y NIR forma la base para el diseño y desarrollo de índices de vegetación (IVs). Los IVs se construyen a partir de combinaciones de bandas (relaciones, sumas lineales, etc.) cuando están disponibles imágenes multiespectrales. Están diseñados para aislar y mejorar la señal de la vegetación en imágenes obtenidas por teledetección, facilitando así la discriminación y extracción de información útil sobre la vegetación (Asrar et al. 1992; Gutman 1991; Huete et al. 1994; Huete et al. 1997).

### **1.2.2 Plataformas**

Para llevar a cabo las técnicas de teledetección es necesario el uso de sensores a bordo de equipos o plataformas que permitan capturar la información de forma homogénea. Actualmente existen varias posibilidades para obtener información, unas de acceso libre y otras de forma comercial (Tabla 1.2.1)

Tabla 1.2.1. Características de algunos de los principales plataformas y sensores utilizados en teledetección.

Plataforma	Resolución temporal	Resolución espacial	Bandas espectrales (nm)
Sentinel-2 (acceso abierto)	2-5 días	10, 20m	Aerosol: 430-450, Blue: 450-520 Green: 540-570, Red: 650-680 Red Edge1: 690-710, Red Edge2: 730-740 Red Edge3: 770-790, NIR1: 780-900 NIR2: 850-870, Vapor de agua: 930-950 Cirrus: 1360-1390, SWIR1: 1560-1650 SWIR2: 2100-2280
WorldView3(Comercial)	<1 día	1.24m VNIR y 3.4m SWIR	450 - 800 (Pacromatica) Coastal Blue: 400 – 450 Blue:450 – 510; Green: 510 – 580; Yellow: 585 – 625, Red:630 – 690; Red edge: 705 – 745, Near-IR1: 770 - 895 Near-IR2: 860-1040 SWIR-1: 1195-1225 SWIR-2: 1550 - 1590 SWIR-3: 1640 - 1680 SWIR-4: 1710 - 1750 SWIR-5: 2145 - 2185 SWIR-6: 2185 - 2225 SWIR-7: 2235 - 2285 SWIR-8: 2295 - 2365
Cessna (Micro-Hyperspec Modelo VNIR y SWIR Hyperspect Modelo NIR-100)	<1 día	0.2-0.6m	Hiperspectral (400-850 nm con resolución de 6.5 nm) y SWIR (950-1750 nm con resolución de 6.05 nm)
UASs (Parrot sequoia y DUET-T)	<1 día	11cm multiespectral 16cm térmico	Green: 530–570, Red: 640–680, Red Edge: 730–740, NIR: 770–810 700-1200 (térmico)

Por lo general, para la agricultura, se utilizan plataformas con cámaras multiespectrales y térmicas. Si se quiere hacer una monitorización precisa de los cultivos, especialmente de los leñosos, es necesario una alta resolución espacial. En este contexto, los UASs (Unmanned Aerial System, por sus siglas en inglés) se presentan como plataformas más idóneas que los satélites. Los satélites tienen momentos específicos para la captura de imágenes, no permitiendo la flexibilidad de elegir cualquier día o momento para obtener imágenes de una zona determinada. Por el contrario, los UASs posibilitan una planificación más adaptada a las necesidades, sin embargo, existe una limitación en cuanto a la resolución temporal de los vuelos en comparación con los satélites.

En particular, las imágenes adquiridas por los UASs proporcionan mediciones relacionadas con la radiancia en cada píxel. Para medir la reflectancia, se aplican algoritmos de procesamiento de imágenes para compensar los efectos debidos a la absorción atmosférica y al espectro de la iluminación solar. A partir de los valores de reflectancia, es posible detectar varios materiales y el estado de la vegetación según las respuestas espectrales conocidas (Daponte et al 2019)

Los investigadores han empezado a utilizar cada vez más sensores a bordo de UASs (Awais et al., 2023). Esto puede explicarse en gran parte por la miniaturización de tecnologías de sensores para cámaras VNIR, SWIR y TIR (hiperespectrales) mayoritariamente usados en UASs (Daponte et al 2019). Respecto a los satélites, las imágenes satelitales multiespectrales, como Sentinel-2 A/B (desde junio de 2015) y Landsat (desde octubre de 2008), son fácilmente accesibles en la actualidad.

Las ventajas principales del uso de imágenes UASs es la muy alta resolución que permite detectar diferencias espaciales en el campo (Wang et al 2019). Este tipo de imágenes de muy alta resolución pueden ayudar a identificar la resolución espacial óptima (o la altura de vuelo óptima del UAS) para capturar diferencias significativas en el paisaje (Garrigues et al., 2006).

### **1.2.3 Sensores**

Los sensores son elementos o equipos capaces de medir la radiación proveniente de un objeto y convertirla en una señal que pueda ser registrada y presentada de forma adecuada para extraer información: cámaras, videos, radar, sonar. Los sensores pueden ser activos (radars, lidar, sonar) en el que utilizan energía emitida por el sensor y miden la respuesta obtenida por el objeto, y sensores pasivos (hiper

y multiespectrales, térmicos, ópticos) que miden la radiación electromagnética que emanan los objetos debido al efecto de la luz solar.

La calidad de los sensores se mide en términos de precisión de sus mediciones, es decir, la resolución de estos. La resolución se define como la capacidad para discriminar información (Benediktsson et al., 2012)

La discriminación de información en imágenes obtenidas por sensores remotos no se refiere solo al detalle espacial, sino también al número de bandas espectrales, sus anchos de banda y rango espectral cubierto, la frecuencia temporal de observación, etc. A continuación, definiremos los tipos de resolución que se tienen en cuenta en todo sistema sensor.

**Resolución espacial:** identifica el objeto más pequeño que se puede detectar en una imagen. En un sistema fotográfico, la resolución espacial identifica la separación mínima en la que los objetos aparecen independientes y aislados. Se mide en milímetros en la fotografía o en metros en el suelo, y depende de la longitud focal de la cámara y la altura de la cámara sobre el suelo. Dado que las imágenes se adquieren principalmente en forma digital, la resolución espacial se expresa comúnmente como la longitud (en metros) de las unidades espaciales mínimas en la imagen, llamadas píxeles (de elemento de imagen).

**Resolución espectral:** se refiere al número de bandas proporcionadas por el sensor y sus anchos de banda espectrales. En general, un sensor proporcionará una mejor capacidad de discriminación cuantas más bandas se adquieran. Idealmente, esas bandas espectrales deben ser lo suficientemente estrechas como para identificar características de absorción específicas que de otro modo podrían estar difuminadas. La selección del número de bandas, el ancho y el rango espectral medido por el sensor están relacionados con los objetivos que se espera alcanzar.

**Resolución radiométrica:** Mide la capacidad para discriminar pequeñas variaciones en la radiancia espectral registrada. En el caso de los sistemas fotográficos, la resolución radiométrica del sensor está dada por la cantidad de niveles de grises capturados por la película. En sensores electrónicos ópticos, la imagen se adquiere digitalmente y la resolución radiométrica se expresa comúnmente como el rango de valores utilizados para codificar la radiancia de entrada, es decir, el número de bits utilizados para almacenar la señal de entrada. Un sistema sensor de 8 bits puede discriminar 256 radiancias de entrada diferentes por píxel ( $2^8 = 256$ , por lo tanto, un rango de 0 a 255) (Chuvieco, 2016).

**Resolución temporal:** se refiere a la frecuencia de observación proporcionada por el sensor. Este ciclo es una función de las características orbitales del satélite (altura, velocidad y declinación), así como del campo de visión del sensor. Los sensores con alta resolución temporal tienen baja resolución espacial, ya que podrán observar un área más grande en cada adquisición de imagen. Esta situación difiere de plataformas como los UASs o avionetas ya que la frecuencia de observación es más limitada.

La resolución espacial es quizás la más relevante en cuanto a monitorización de cultivos, especialmente para leñosos, ya que si el píxel es demasiado grande se puede ver influenciado no solo por la planta sino por otros elementos presentes, en el caso de la vid, por ejemplo, el píxel se verá influenciado por el ancho del dosel, el efecto del marco de plantación, llegando a incluir varias líneas en el mismo píxel y el efecto del suelo.

Los sensores a bordo de UASs son una solución para evaluar la heterogeneidad espacial y temporal en el desarrollo de cultivos leñosos. En estos casos, la vegetación no cubre completamente la superficie del suelo y la resolución proporcionada por los satélites actualmente no es inferior a 1m. Se necesita una resolución más alta para cultivos en espaldera como los viñedos (Khaliq et al 2019).

En los últimos años se ha avanzado mucho en el desarrollo de nuevos sensores de alta resolución debido a la gran aplicabilidad que tiene el uso de UASs en diferentes áreas de trabajo.

Los avances en tecnología han permitido adaptar los sensores para poder transportarlos en UASs, versiones miniaturizadas de sensores multiespectrales e hiperespectrales así como cámaras térmicas comerciales que no requieren refrigeración (de otro modo serían más pesados), son accesibles en el mercado para aplicaciones específicas.

#### 1.2.3.1 Sensores térmicos a bordo de UASs.

El principio de funcionamiento de los detectores térmicos se basa en la conversión de la radiación electromagnética absorbida en energía térmica (Messina and Modica, 2020)

En la década de 1960, el uso de datos térmicos para detectar el estrés hídrico a escala de campo con teledetección térmica se volvió prominente (Tanner 1963). El sensor térmico utiliza la radiación térmica para leer la representación térmica pasiva con un rango de longitud de onda de 700 a 1200 nm (Figura 1.2.4). Se utiliza

una matriz de microbolómetros dentro de los sensores para almacenar y recibir la señal de la representación térmica y se almacenan estas señales como valores de número de datos crudos (ND) en el píxel de la imagen (Awais et al 2023).

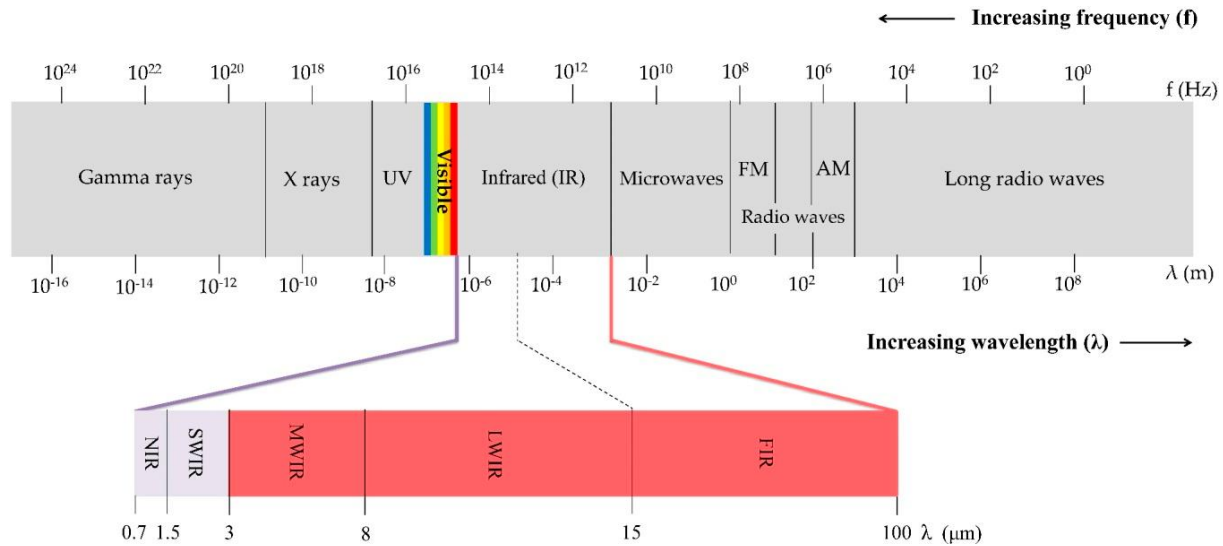


Figura 1.2.4. Espectro electromagnético. Zona de radiación infrarroja reflejada(700-3000nm) y radiación infrarroja emitida (3000-100000nm) (Messina and Modica, 2020).

La teledetección térmica es un mecanismo mediante el cual se mide el calor liberado por un objeto y se transforma en lecturas de temperatura sin contacto con un cuerpo (Khanal et al. 2017).

Las leyes de Wien y Boltzmann describen la relación entre las radiaciones de un cuerpo negro (es decir, un objeto ideal que absorbe y reemite toda la energía incidente) y la longitud de onda de la emisión máxima con la temperatura de un cuerpo negro.

La ley de Stefan–Boltzmann establece que la emisividad de un cuerpo negro es proporcional a la cuarta potencia de su temperatura absoluta:

$$E = \sigma T^4 \quad (1)$$

Donde E representa la potencia radiada por unidad de área expresada en  $W \cdot m^{-2}$ ,  $\sigma$  es la constante de Stefan–Boltzmann, y T es la temperatura absoluta en Kelvin. La fórmula muestra la radiación electromagnética total emitida por un cuerpo negro es una función de su temperatura absoluta. Por lo tanto, la radiación emitida por un cuerpo aumenta a medida que su temperatura aumenta.

La ley de Kirchhoff (1860) (2) establece que, en una longitud de onda dada, la emisividad de un cuerpo es igual a su capacidad de absorción:

$$\epsilon = \alpha \quad (2)$$

donde  $\epsilon$  representa la emitancia y  $\alpha$  la absorbancia. Esto se explica como que aquellos objetos que absorben toda la energía son buenos emisores y aquellos que reflejan la mayor parte de la energía son malos emisores (Jensen, 2014).

Todos los cuerpos con una temperatura superior al cero absoluto se caracterizan por un movimiento aleatorio, es decir, el calor cinético, cuya medida es la temperatura cinética ( $T_{kin}$ ). Además, un objeto emite energía como función de la temperatura, y la energía emitida se utiliza para determinar su temperatura radiante  $T_{rad}$ . Aunque hay una fuerte correlación lineal positiva entre  $T_{kin}$  y  $T_{rad}$ ,  $T_{rad}$  es menor que  $T_{kin}$  debido a la emisividad ( $\epsilon$ ). Por esta razón, la temperatura medida por un sensor ( $T_{rad}$ ) siempre será más baja que la temperatura real ( $T_{kin}$ ). Se deduce de esto, como se explica por la ley de Kirchhoff:

$$T_{rad} = \epsilon T_{kin} \quad (3)$$

La emisividad ( $\epsilon$ ) es la relación entre la radiación emitida por la superficie y la radiación emitida por un cuerpo negro a la misma temperatura (Jacob et al 2004). Debido a que la luminancia de cualquier cuerpo real, a la misma temperatura, siempre es menor que la de un cuerpo negro (que es igual a 1), su emisividad tiene un valor entre 0 y 1. Cualquier cuerpo absorbe y emite radiación de manera menos efectiva a una temperatura dada en comparación con un cuerpo negro, como se explica en la ley de Planck. Muchos factores influyen en la emisividad: color, composición química, rugosidad superficial, contenido de humedad, campo de visión, ángulo de visión, longitud de onda espectral, etc. (Jacob et al, 2004). La emisividad de la vegetación varía de 0.96 a 0.99, mientras que la del suelo es alrededor de 0.89, y la emisividad del agua es 0.99.

Una de las aplicaciones de las imágenes térmicas en teledetección aplicada a la agricultura es medir la temperatura de la cubierta vegetal de los cultivos. Con esta información es posible calcular ciertos índices de estrés hídrico.

Recientemente, la posibilidad de obtener imágenes de muy alta resolución proveniente de UAS, ha aumentado la posibilidad de utilizar esta tecnología para detectar variabilidad en el estado hídrico en parcelas comerciales y así poder tomar decisiones de riego.

Hasta la fecha, las imágenes térmicas de plataformas satelitales se han utilizado ampliamente para medir las temperaturas de los cultivos y la superficie del suelo a escalas regionales y globales (Khanal et al 2017). Sin embargo, los tamaños de

píxel de estas imágenes son mayores que un campo individual en la mayoría de las regiones agrícolas y, por lo tanto, estas imágenes tienen aplicaciones limitadas para aplicaciones agrícolas específicas del sitio (Mahlein, 2016; Gowda et al., 2008). Por ejemplo, algunos sensores térmicos basados en satélites con cobertura diaria, como el espectroradiómetro de imágenes de resolución moderada (MODIS), el satélite ambiental geostacionario (GOES) y el radiómetro avanzado de muy alta resolución (AVHRR), proporcionan imágenes térmicas en un rango de resolución de 1000 a 4400 m, en comparación con imágenes visibles, del infrarrojo cercano (NIR) y del infrarrojo de onda corta (SWIR) que tienen una resolución de 250 a 1000 m (Khanal et al, 2017). Ha habido algunas mejoras en la resolución espacial de los sensores térmicos en algunos satélites (por ejemplo, Landsat 7 ETM proporciona 60 m, Landsat 8 proporciona 100 m y ASTER proporciona un tamaño de píxel de 90 m), pero estos satélites tienen un tiempo de revisión de 16 días. Para los productores o agricultores que desean utilizar imágenes satelitales para el monitoreo de cultivos y suelos en la temporada, la baja resolución espacial y la frecuencia temporal se convierten así en limitaciones importantes (Khanal et al, 2017)

Estudios realizados por Sepulcre-Cantó et al. (2006, 2007) demostraron que las imágenes térmicas de alta resolución adquiridas por vía aérea, como las avionetas, son útiles para detectar el estrés hídrico de los cultivos para la gestión específica del sitio. Sin embargo, los sistemas aéreos tripulados tienen costos operativos elevados, y debido a la presencia limitada de empresas que ofrecen productos rentables, el uso de sistemas aéreos tripulados es limitado en la Agricultura de Precisión (Khanal et al, 2017)

Las imágenes térmicas proporcionadas por UASs ahora están disponibles a alta resolución espacial, espectral y temporal a un precio más bajo en comparación con los últimos años. Sin embargo, en comparación con los sensores ópticos comerciales disponibles para UASs, las cámaras térmicas siguen siendo más caras y tienen una resolución más baja. Las cámaras térmicas disponibles comercialmente tienen resoluciones superiores a 4200 píxeles por 2800 píxeles (Stark et al., 2014). La Tabla 1.2.2 proporciona una lista de cámaras térmicas actualmente disponibles.

Tabla 1.2.2. Principales parámetros de algunas de las cámaras térmicas más usadas a bordo de UASs (Starket et al., 2014)

Cámara	Resolución (píxeles)	Peso (g)	Resolución espectral (nm)
FLIR T050sc	320 x 240	880.0	75–1300
FLIR A325as	320 x 240	700.0	750–1300
Gobi-384 (Scientific)	384 x 288	500.0	800–1400
ICI 7640 P-Series	640 x 480	127.6	700–1400
InfraTec mobileIR M4	160 x 120	265.0	8–1400
Optris PI400	382 x 288	320.0	750–1300
Pearleye LWIR	640 x 480	790.0	800–1400

### 1.2.3.2 Sensores multiespectrales a bordo de UASs

Las cámaras multiespectrales se pueden dividir en dos categorías en términos de ancho de banda: banda estrecha y banda ancha. Banda estrecha significa que el rango del espectro es pequeño (Sampson et al., 2003). Generalmente, con un rango espectral más pequeño, se pueden obtener mediciones espectrales más precisas (Imai, 2000). Las cámaras de banda ancha tienen amplios rangos espectrales, por ejemplo, la Sequoia usada en UASs tiene un ancho de banda de 40 nm, que suelen ser similares a los de los satélites; en consecuencia, es sencillo aplicar algunos algoritmos, por ejemplo, para Índices de Vegetación (IVs) utilizados para sensores satelitales a datos de cámaras de banda ancha (Fernández Guisuraga et al., 2018).

Además del ancho de banda, la calibración radiométrica es otro factor importante que determina la precisión espectral y los derivados basados en la reflectancia (IVs). Antes de utilizar imágenes multiespectrales, la calibración radiométrica es un requisito previo y un paso clave, en el que el valor del número digital (ND) registrado por la cámara se puede convertir en reflectancia espectral, de esta manera se pueden calcular los IVs (Deng et al., 2018). Los métodos de calibración dependen del sensor para UAS que se vaya a usar. El enfoque más común para realizarlo es el método de línea empírica basado en la adquisición durante el vuelo de al menos un panel de referencia con reflectancia conocida y propiedades lambertianas, lo que significa que la reflectancia de la superficie no se ve afectada

por el ángulo de iluminación (Poncet et al, 2019; Wang et al, 2015). Siguiendo este método, la relación entre el ND del panel de referencia extraído de la imagen UAV y el valor de reflectancia conocido de ese panel se utiliza para convertir los ND de todos los píxeles de la imagen en valores de reflectancia (Matese et al, 2019; Deng et al, 2018). En la Tabla 1.2.3 se observa los principales parámetros que se consideran en el uso de las cámaras multiespectrales a bordo de UAS.

Tabla 1.2.3. Principales parámetros de algunas de las cámaras multispectrales más usadas (Deng et al, 2018).

Cámara	Resolución (píxeles)	Peso (g)	Resolución espectral (nm)
Sentera Quad	1248 x 950	170	RGB, Red:655, RedEdge 725 y NIR: 800
ADC Micro	2048 x 1536	200	Green: 520-600 Red: 630-690 NIR: 760-900
Buzzard	1280 x 1024	250	Blue: 500, Green: 550, Red :675 NIR: 1700 NIR2: 750 NIR3: 780
MiniMCA6	1280 x 1024	700	Blue490, Green: 550, Red: 680, Red Edge: 720, NIR1:800, NIR2: 900
XNiteCanon SX230 NDVI	4000 x 3000	223	Blue: 385-470, Green: 500-570, NIR: 670-770
RedEdge	1280 x 960	150	Blue: 475, Green: 560, Red: 668, RedEdge: 717, NIR: 840
Sequoia	1280 x 960	72	Green: 550, red: 660, RedEdge: 735, NIR: 790

Dentro de los sensores más usados encontramos Parrot Sequoia (Parrot Drone SAS, París, Francia), Micasense RedEdge (MicaSense Inc., Seattle, WA, EE. UU.) y DJI P4M (SZ DJI Technology Co., Ltd., Shenzhen, China). Estos sistemas consisten en cámaras capaces de capturar luz reflejada con un ancho de banda de 10 a 40 nm en los canales espectrales visibles, de borde rojo y NIR, que luego se co-registran para crear una imagen compuesta con varias bandas espectrales (Fawcett et al, 2020). Las cámaras multispectrales se consideran herramientas consolidadas para el cálculo de los principales índices vegetativos, sin embargo, el número reducido de bandas espectrales adquiridas (generalmente cinco bandas:

blue, green, red, rededge y NIR) y el ancho de banda discreto (media de 10-40 nm) no permiten análisis detallados, investigando la respuesta espectral del dosel en índices de longitud de onda más específicos (Di Gennaro et al, 2022).

En agricultura de precisión es necesario considerar la precisión, aplicabilidad y potencial de los diferentes sensores, así como los métodos de calibración.

## **1.3 Uso de sensores para caracterización de suelos**

### **1.3.1 Propiedades de los horizontes del suelo**

La calidad del suelo viene determinada por las propiedades fisicoquímicas que la componen. Las características fisicoquímicas de diferentes suelos varían en espacio y tiempo debido a la variación en topografía, clima, procesos de meteorización física, cobertura vegetal, actividades microbianas y varias otras variables bióticas y abióticas.

Diferentes factores crean diferentes tipos de suelo. La interacción entre las propiedades físicas, químicas y biológicas del suelo influyen en la calidad de este, y en última instancia, en la productividad de los ecosistemas agrícolas (Delgado y Gómez, 2016)

Para un suelo dado, sus propiedades dependen de la historia de la formación del suelo. Una comprensión adecuada de las características del suelo y la interpretación adecuada de las magnitudes de sus propiedades, ambas combinadas bajo el término más amplio de calidad del suelo, son necesarias para la gestión adecuada de los suelos agrícolas (Delgado y Gómez, 2016).

#### 1.3.3.1 Propiedades físicas:

Las propiedades físicas son las que pueden evaluarse por inspección visual o por el tacto. Cada suelo presenta un conjunto peculiar de propiedades físicas que depende de la naturaleza de sus componentes, de las cantidades relativas de cada uno de ellos y de la manera que se hayan mutuamente acoplados (Thompson, 1988). Los suelos se componen de sólidos, líquidos y gases mezclados en proporciones variables. Las cantidades relativas de aire y agua presentes dependen mucho de la intensidad de las uniones de las partículas sólidas. La superficie ocupada por las raíces y su relación con el aire y con el agua se hallan determinadas, en gran parte, por la constitución física de los horizontes del suelo (Thompson, 1988). Entre las propiedades físicas más relevantes a nivel agronómico encontramos:

**Profundidad:** Por definición los suelos profundos presentan más superficie para la ocupación de las raíces, este parámetro influye a su vez en una mayor capacidad de retención de agua (CRA). Las plantas, cuando enfrentan situaciones que limitan su desarrollo, como la sequía, podrían soportar el estrés por un periodo de tiempo mayor si se encuentran en suelos con una mayor CRA.

**Textura del suelo:** La textura del suelo se define como el porcentaje en peso de cada una de las tres fracciones minerales: arena, limo y arcilla. Estas fracciones se refieren al diámetro de las partículas expresadas en milímetros (hasta 2 mm). Las partículas con diámetro mayor a 2 mm se excluyen de las determinaciones de textura, pasando a ser piedras y gravas apenas contribuyen a las propiedades básicas del suelo, como la CRA o como almacén o suministro de nutrientes.

**Estructura:** Dos suelos pueden presentar misma textura, pero presentar propiedades físicas distintas debido a la ordenación específica de sus partículas. La ordenación de las partículas individuales para formar unidades mayores es la estructura, resulta de la tendencia que experimentan las partículas más finas, especialmente el humus y la arcilla, al unirse entre sí (Thompson, 1988). El concepto de estructura del suelo implica la distribución, rango de tamaño y conectividad de los espacios porosos entre partículas y agregados en el suelo (Oades 1993), lo que afecta al almacenamiento y suministro de agua, nutrientes y oxígeno (Hamblin 1985).

**Porosidad del suelo y densidad aparente:** La porosidad se considera como los espacios vacíos que contienen aire y agua. Los poros aparecen tras el proceso de transformación de la roca madre a suelo debido al ahuecado y disgregación del material. La porosidad total se calcula a partir de la densidad aparente o global

del suelo y la de las partículas que lo componen. La densidad aparente es el peso de los sólidos del suelo por unidad de volumen total del mismo. El volumen de poros es una parte del volumen de suelo medido para la estimación de la densidad aparente. Como regla general los suelos de textura fina tienen mayor porosidad y menor densidad aparente que los suelos arenosos. La densidad aparente de un suelo varía según su grado de compactación. La compresión del suelo hace descender su volumen de poros y aumenta su peso por unidad de volumen.

**Color:** El color es una de las características más perceptibles del suelo y es importante porque está relacionado con el contenido de MO, el clima el drenaje y la mineralogía del suelo.

**Temperatura:** Varios son los factores que influyen en la temperatura del suelo, el ángulo de incidencia, la cobertura del suelo, el color, contenido de agua, la profundidad y la textura. El color del suelo influye en la temperatura ya que las tonalidades oscuras tienden a absorber y emitir el calor con mayor rapidez que las claras. Por otro lado, la temperatura del suelo afecta a parámetros de producción de la vid como es la madurez de la uva. El momento de la madurez está impulsado principalmente por la temperatura del aire, sin embargo, esta se puede ver influenciada por la temperatura del suelo (Van Leeuwen y Rességuier, 2018)

### 1.3.3.2 Propiedades químicas

La función principal del suelo en relación con su calidad química para la producción de cultivos es proporcionar nutrientes para el crecimiento de las plantas (White 2010). Algunas de las principales propiedades químicas que se han utilizado como indicadores en agricultura es el pH, Carbono orgánico del suelo (COS), capacidad de intercambio catiónico (CIC), salinidad y nitrógeno total.

**CIC:** Indica la carga negativa por unidad de masa del suelo y se mide como el número total de moles de carga que pueden ser desplazados por unidad de masa de suelo por una solución extractora (Heil y Sposito 1997, White 2003). El CIC es un agente de control importante de la estabilidad de la estructura del suelo, la disponibilidad de nutrientes para el crecimiento de las plantas, el pH del suelo y la reacción del suelo a fertilizantes y otros mejoradores (Hazelton y Murphy 2007). Aunque existen rangos óptimos de valores de CIC como pautas generales, no se encontraron valores específicos para la viticultura.

Los cinco cationes más abundantes en los suelos son  $\text{Ca}^{2+}$ ,  $\text{Mg}^{2+}$ ,  $\text{Na}^+$  y  $\text{K}^+$  a los cuales debe agregarse  $\text{Al}^{3+}$  en suelos ácidos con  $\text{pH} < 5.5$ . Los cationes  $\text{Mn}^{2+}$ ,  $\text{Fe}^{2+}$ ,

$\text{Cu}^{2+}$  y  $\text{Zn}^{2+}$  generalmente tienen una concentración lo suficientemente baja como para no contribuir al complemento de cationes, por lo que se puede determinar un CIC efectivo sumando los principales cationes (Hazelton y Murphy 2007).

**Salinidad:** La salinidad limita la producción de cultivos cuando la concentración de sales solubles en la solución del suelo es lo suficientemente alta como para disminuir la absorción de agua por las plantas. Una medición de la conductividad eléctrica (EC) de un extracto de pasta saturada proporciona una estimación de las sales solubles totales (Heil y Sposito 1997). Un aumento en la salinidad afecta el rendimiento de la vid, pero la respuesta varía según el cultivar de uva y el portainjerto utilizado. El efecto de la sal en la supervivencia, el crecimiento y la calidad de la fruta de la vid se ha estudiado extensamente y existen valores umbrales para el crecimiento de la vid (Zhang et al. 2002).

**pH:** Es uno de los determinantes más importantes de la fertilidad del suelo debido a su influencia en la solubilidad de iones metálicos como Al, Mn, Fe, Cu, Zn y Mo, su efecto en el suministro de cationes y aniones nutrientes, y su influencia en los microorganismos presentes en el suelo y su actividad. El rango de pH óptimo para el crecimiento de las cepas es de 5.5 a 8 (White 2003).

**Materia orgánica:** En términos de COS, no es absorbida por las plantas como un nutriente del suelo, pero su ciclo es importante debido a su asociación con nutrientes (N, P y S) y las contribuciones beneficiosas que realiza a las propiedades químicas, físicas y biológicas del suelo (Hoyle et al. 2011). Los nutrientes pueden liberarse al suelo en formas disponibles para las plantas a medida que los materiales orgánicos se descomponen por microorganismos. La materia orgánica también desempeña un papel importante en el mantenimiento de la estructura del suelo y la reducción del contenido de arcilla fácilmente dispersable (Tisdall y Oades 1982, Dexter 2002). el COS realiza una variedad de funciones en los suelos y el grado de importancia del COS para funciones particulares difiere con el tipo de suelo.

El estado de nitrógeno de la vid depende del contenido de materia orgánica del suelo, su tasa de mineralización y la relación C/N (Choné et al., 2001).

Las propiedades antes mencionadas, principalmente las de carácter físico, tienen un papel crucial en cuanto a la disponibilidad de recursos hídricos para la vid.

La capacidad del suelo para almacenar agua depende de su profundidad, textura, estructura, contenido en materia orgánica, así como el espesor y secuencia de los horizontes en el perfil (Thompson, 1988).

Los suelos que presentan texturas finas presentan una elevada capacidad de retención de agua (CRA) disponible debido a sus numerosas partículas pequeñas con una gran superficie total y a su elevado volumen de pequeños poros distribuidos entre las partículas. Esto es válido para los puntos de CC y PMP, donde CC es su límite superior o Capacidad de Campo y el límite inferior es el Punto de Marchitez Permanente. Por otro lado, la profundidad también juega un papel importante, ya que las texturas pueden variar a lo largo del perfil permitiendo en unos casos estar disponible el agua para algunos cultivos cuyas raíces profundicen más que otras.

La estructura influye en la CRA por el modo en el que se ordenan las partículas del suelo.

La secuencia de capas en el perfil del suelo tiene un efecto en la capacidad de retención del agua. Debido al movimiento del agua en el perfil, al atravesar un cambio textural se genera un retraso, en algunos casos, el retraso es lo bastante importante como para aumentar la capacidad de retención hídrica de la capa superior (Thompson, 1988). Por otro lado, la materia orgánica puede llegar a retener un peso de agua superior al suyo propio. Estos materiales presentan densidades aparentes muy bajas y elevada porosidad.

Las propiedades del suelo son uno de los parámetros más críticos que determinan la variabilidad en el desarrollo del viñedo. El suelo proporciona a la vid soporte estructural, nutrientes y agua. Algunos aspectos cruciales del desarrollo de la vid dependen de la capacidad del suelo para proveerlos, lo que afecta la fisiología, la producción y la dinámica de maduración de la uva (Van Leeuwen et al., 2018)

En la región central de España, donde las limitaciones de riego y escasa precipitación pueden ser un problema para la producción de uva de vinificación, las propiedades del suelo son la principal fuente de la cual la vid extrae agua. La textura del suelo influye en CRA y, consecuentemente, en la liberación progresiva de agua para la absorción de las raíces de la vid (Bellvert et al., 2012). Esta influencia es aún más decisiva bajo riego deficitario. Si, por el contrario, los suelos tienen baja CRA, el riego debería ser imprescindible para el correcto desarrollo de los cultivos (Barbagallo et al., 2021).

En parcelas sin riego, las características del suelo tienen un impacto importante en el estado hídrico de la vid y, como consecuencia, en el rendimiento y la composición de la fruta (Morlat y Bodin 2006; Van Leeuwen et al., 2004). En condiciones de riego, el efecto de las propiedades del suelo en el estado hídrico de

la vid no debería ser tan fuerte porque el suministro de agua a la planta está garantizado por el riego y menos por el reservorio de agua en el suelo (Bellvert et al., 2012).

Para conocer las propiedades del suelo definidas anteriormente es necesario hacer un correcto estudio del suelo. Esto se hace a través del estudio de su perfil (sección vertical en el terreno desde la superficie hasta el material originario) que consta de una o varias capas llamadas horizontes. Los horizontes se diferencian por sus propiedades físico-químicas. La variabilidad de suelos tanto horizontal (paisaje, geografía de suelos) como vertical (horizontes, perfil, tipología de suelos) depende de la diferenciación de horizontes. En agronomía el conocimiento de los suelos es de gran importancia ya que permite hacer un correcto manejo de este (estimación de productividad, erosión y degradación, necesidades de nutrientes y fertilizantes, selección de zonas de riego y plan de riego, etc.).

En los horizontes principales se utilizan las letras mayúsculas para designar los procesos más importantes y en la descripción de los procesos secundarios se utilizan letras minúsculas como sufijo (Figura 1.3.1)

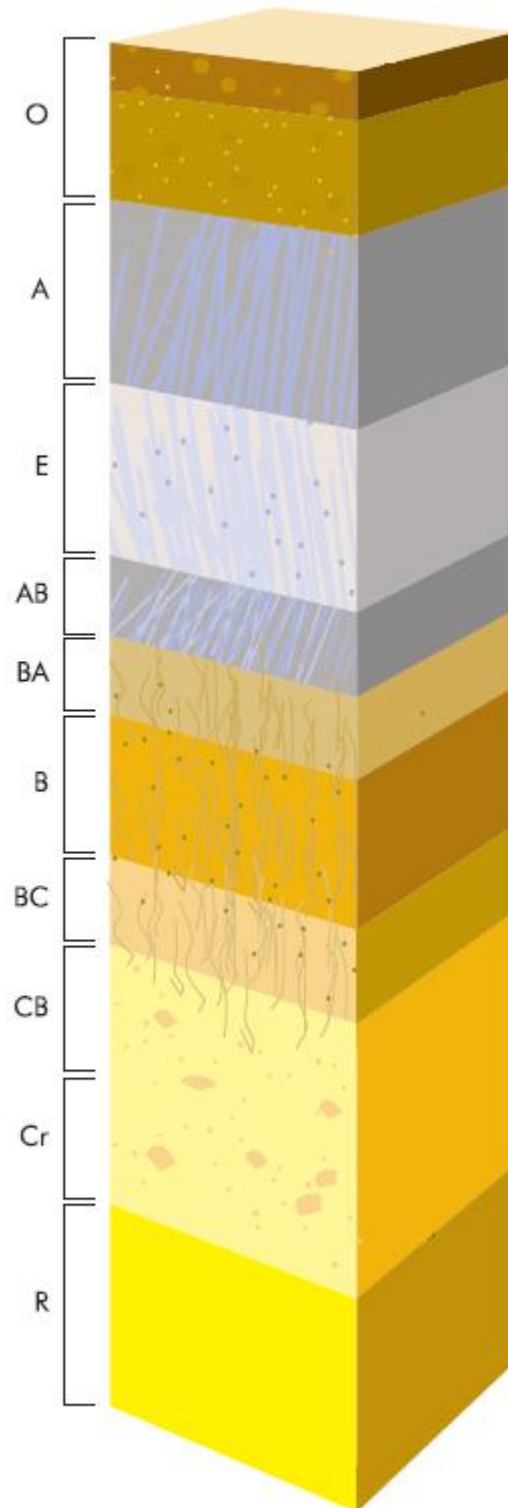


Figura 1.3.1. Nomenclatura de los horizontes genéticos del perfil del suelo (Instituto Geográfico Nacional, 2006)

Los horizontes A y B se denomina solum y constituye la profundidad efectiva en la que se desarrolla la mayor parte del sistema radicular de la planta, de ahí su importancia en la alimentación hídrica y nutricional de la propia planta.

Los horizontes se pueden clasificar a nivel genético, que son aquellos que tienen una relación directa con los factores y procesos de formación del suelo, es decir, con su génesis. Y a nivel de diagnóstico basado en la caracterización de cada una de las propiedades medibles de un suelo.

En los siguientes apartados se profundizará más sobre los sistemas de clasificación del suelo.

### **1.3.2 Clasificación de suelos. USDA y FAO**

A la hora de clasificar los suelos se debe considerar diferentes factores como factores y procesos de formación, propiedades de los suelos, agrupación de las propiedades, horizontes, el perfil o diversas relaciones entre los elementos anteriores. Las clasificaciones pueden ser genéticas donde se da más relevancia a los factores y procesos formadores del suelo o clasificaciones objetivas donde prevalece las características morfométricas.

Debido a la complejidad en la clasificación de suelos el uso de la clasificación objetiva basada en las características morfométricas es una metodología muy usada en campo.

La clasificación de suelos toma gran relevancia a la hora de realizar los mapas de suelo. La variabilidad existente en el desarrollo vegetativo de los cultivos bajo un manejo homogéneo viene influenciada principalmente por el suelo.

Suelos con un carácter más arcilloso o arenoso afecta en mayor o menor medida a la disponibilidad de agua y nutrientes sobre las plantas. Delimitar zonas con suelos diferentes en base a características texturales, por ejemplo, permitiría hacer una programación de riego acorde con la CRA.

La clasificación de suelos se basa en propiedades del suelo las cuales, en la medida de lo posible, deben poder ser medidas y observadas en campo.

La selección de características de diagnóstico tiene en cuenta su relación con los procesos formadores de suelos. La comprensión de estos procesos formadores de suelos contribuye a una mejor caracterización de los suelos, pero estos procesos no deben, como tales, usarse como criterio de diferenciación

Actualmente existen dos grandes metodologías de clasificación y las más usadas por su objetividad: la americana (USDA) y la FAO. La Soil Taxonomy (1975-2010) de USDA es más detallada en cuanto a análisis y descripciones y la más comúnmente usada por expertos. Esta clasificación usa varias categorías (orden, suborden, grupo, subgrupo, familia, serie). Según la Soil Taxonomy (USDA) los suelos se clasifican dentro del sistema de Orden en 12 grandes grupos: *Alfisol*, *Andisol*, *Aridisol*, *Entisol*, *Gelisol*, *Histosol*, *Inceptisol*, *Mollisol*, *Oxisol*, *Spodosol*, *Utilisol* y *Vertisol*.

Es muy importante la clasificación a niveles de detalle ya que las plantas son capaces de discriminar esas pequeñas diferencias, por otro lado, si se quiere trabajar con precisión es importante tener esos niveles de clasificación.

Las dos metodologías les dan mucha importancia a las herramientas de diagnóstico (características o propiedades y horizontes de diagnóstico). Sin embargo, ambas metodologías difieren en varios aspectos; USDA es abierta, y la leyenda de la FAO es cerrada. La importancia y la necesidad de los datos de suelo y de clima es muy significativa en USDA y menor en la FAO. Se diferencian también a nivel tecnológico, ya que la aplicabilidad a la práctica agronómica es superior en la Soil Taxonomy de USDA.

Las 'clases' son categorías de un sistema de clasificación predefinido o reconocidas durante el estudio como elementos naturales del paisaje.

Clasificar los suelos de acuerdo con un sistema estándar de clasificación permite correlacionar los suelos en un área dada con suelos en otros lugares, así como estandarizar el mapeo dentro de una sola área de estudio (Rossiter, 2000)

### **1.3.3 Prezonificación y zonificación**

Realizar un mapa de suelos de forma estandarizada requiere de dos aspectos, geografía de suelo (distribución geográfica) y tipología de suelos (estudia y clasifica los perfiles). Una adecuada fotointerpretación aérea y muestreo de suelos permite realizar este tipo de reconocimiento. La fotointerpretación es un paso clave a la hora de hacer una prezonificación. Determinar de forma más o menos rápida aquellas zonas que, en principio, parecen diferenciarse entre sí. Una vez que se consigue hacer esa separación es posible hacer estudios de suelo que permitan hacer una zonificación adecuada y acorde a las propiedades física y químicas.

Las propiedades del suelo varían en el espacio y con el tiempo. Como consecuencia, rara vez se describen adecuadamente a escalas de campo y paisaje mediante herramientas tradicionales de levantamiento de suelos. Los métodos tradicionales de muestreo y análisis de suelos proporcionan información detallada en ubicaciones específicas. Sin embargo, esta información es limitada en número, volumen y cobertura espacial (Soil Survey, 2017)

Se puede zonificar superficies en base a propiedades homogéneas del suelo de una forma alternativa a los métodos tradicionales, un ejemplo es la creación de mapas de conductividad eléctrica aparente del suelo a escala de campo (ECap) mediante información obtenida de sensores de inducción electromagnética montados sobre plataformas como cuadrimotos o quads (Esteves et al., 2021). Estos mapas se utilizan para medir diversas características del suelo, como salinidad, contenido de agua, contenido de arcilla, materia orgánica y muchas otras características que se sabe que influyen mutuamente en la conductividad eléctrica del suelo (Peralta y Costa., 2013; Corwin y Lesch., 2005). Son una herramienta económica fundamental para elegir estratégicamente ubicaciones de muestreo, reduciendo la cantidad de muestras necesarias para describir la variabilidad espacial de las propiedades físicas y químicas del suelo.

Existen otros sensores que permiten hacer ese tipo de mapeos previos como el radar de penetración terrestre y los de resistividad eléctrica. Estos métodos han sido ampliamente utilizados en Estados Unidos por el National Cooperative Soil Survey (NCSS) para documentar la variabilidad de las propiedades del suelo en entornos de paisaje específicos e identificar las ubicaciones de componentes de suelo contrastantes dentro de unidades de mapa (Soil survey, 2017).

Este tipo de monitorización proximal del suelo se pueden utilizar en levantamientos de suelos. Pueden mostrar cómo una o más propiedades del suelo varían en una porción del paisaje, ayudar a estimar el rango en los valores de propiedad para una serie de suelos o componente de unidad de mapa específico, refinar los límites de las delineaciones de unidades de mapa de suelos e identificar la ubicación y extensión de componentes de suelo contrastantes dentro de las delineaciones de unidades de mapa de suelos (Soil Survey, 2017). Al describir perfiles de suelo, algunos de estos métodos pueden utilizarse para documentar propiedades del suelo en ubicaciones específicas (datos de punto).

Por otro lado, los datos de teledetección, como las imágenes Landsat ETM, pueden ser variables auxiliares útiles para la predicción de la textura superficial del suelo

y por ende para mapas de zonificación (Liao et al., 2013; Zhang et al. 1992; Odeh y McBratney 2000).

A escalas de campo y paisaje, la caracterización de las variaciones espaciales y temporales es demasiado lenta, costosa y poco practica utilizando únicamente métodos tradicionales de muestreo puntual. La teledetección puede proporcionar una excelente cobertura espacial, pero las mediciones son en su mayoría indirectas y típicamente limitadas a los primeros 5-6 cm del suelo (Soil Survey, 2017). Además, la resolución suele ser demasiado gruesa para caracterizar la variabilidad espacial de las propiedades del suelo a escalas intermedias de campo y paisaje. Debido a estas limitaciones, la percepción proximal del suelo se está volviendo cada vez más popular como una forma de llenar la brecha de datos entre datos de puntos de alta resolución y datos de teledetección de menor resolución (Adamchuk et al., 2011).

Todos estos métodos contribuyen a la generación de mapas de suelos o estudios previos de suelo que deberán finalizar en un mapa de zonificación más detallada, principalmente para definir las zonas de desarrollo del cultivo de la vid.

La vid, igual que otras especies vegetales, muestra variaciones de sus caracteres morfológicos y fisiológicos según las condiciones del medio local. En el ámbito de la viticultura no podemos hablar de producción y calidad sin tener en cuenta el terroir. El terroir ha sido reconocido como un factor importante en la calidad y estilo del vino, especialmente en los viñedos europeos (Falcetti 1994). Se puede definir como un ecosistema interactivo en un lugar determinado, que incluye el clima, el suelo y la vid (portainjerto y cultivar) (Seguin 1988). Algunos autores también incluyen factores humanos como técnicas vitícolas y enológicas en su definición de terroir (Seguin 1986).

La zonificación del terroir consiste en la creación de áreas en base a los elementos del medio con similares potencialidades y limitaciones para el desarrollo de la vid y perfectamente caracterizadas, no solo en cuanto a sus propiedades y factores, sino respecto a su distribución geográfica y cartografía.

El objetivo directo de la zonificación es la identificación de las causas de la variabilidad del terroir y la obtención del mapa de variabilidad del viñedo intraparcela para su utilización en la agricultura de precisión.

La vid se cultiva en un creciente número de regiones del mundo y la industria vitivinícola es cada vez más competitiva. Cada productor debe aprovechar sus ventajas comparativas de la mejor manera posible, aumentando así su valor

añadido y así poder diferenciar y posicionar sus vinos en el mercado de forma competitiva.

En la viticultura moderna es importante la tipicidad y el detalle, para caracterizarlo es necesario conocer la variabilidad en el clima, la litología y el suelo a pequeña escala.

La calidad del mapa de variabilidad de suelo radica en la de las fuentes de información y en las técnicas cartográficas utilizadas para su realización, en la precisión y exactitud requerida por una escala adecuadamente elegida de acuerdo con los objetivos, en la densidad de observaciones y en las técnicas de muestreo del suelo y de la planta seleccionados y en la importancia y el número de propiedades, variables o parámetros considerados (Instituto Geográfico Nacional, 2007)

La zonificación, se puede hacer en diferentes escalas en función de un objetivo específico. Si hablamos de gestión técnica basada en la adaptación al entorno o en aplicaciones de técnicas de manejo relacionadas con la agricultura de precisión los factores específicos del lugar requieren un enfoque aún más refinado (escala 1:5000 o incluso 1:1000) si hablamos de un estudio de ordenación del cultivo de la vid en una determinada denominación de origen es necesaria una escala media (por ejemplo, 1:25.000) (Instituto geográfico Nacional, 2007)

El suelo presenta una gran variabilidad espacial, al usar mapas a gran escala parte de esa variabilidad pasaría desapercibida (Van Leeuwen et al., 2012).

Una correcta zonificación del suelo permite manejar un cultivo de acuerdo con la capacidad productiva y las limitaciones de su zona correspondiente (Bonfante et al, 2015). De esta manera, los productores pueden aplicar estrategias de manejo específicas del sitio en lugar de implementar la misma práctica de manejo en todo el cultivo, especialmente para el manejo del riego (Poblete-Echeverría et al 2017).

En el caso de la vid, el conocimiento del suelo y su relación con el crecimiento y vigor de las cepas es crucial para el manejo del cultivo (White et al, 2020; Bramley et al 2007). Sin embargo, para obtener un mapeo convencional del suelo, es necesario que un topógrafo experto realice trabajos de campo utilizando interpretación de fotos aéreas, topografía y mapas de vegetación (Zeraatpisheh et al 2020). La información sobre el suelo y la vegetación obtenida de imágenes de alta resolución permite generar mapas que pueden ser utilizados para la zonificación de cultivos basados en el rendimiento de estos (López-Granados et al, 2005; Sona et al, 2016) y para determinar zonas de manejo homogéneo en los viñedos.

El vigor puede ser fácilmente mapeado mediante sensores remotos y utilizado como una herramienta de zonificación (Hall et al., 2003).

Investigaciones anteriores han explorado la generación de mapas de zonificación de suelo en viñedos utilizando enfoques basados en información multiespectral. La mayoría de los estudios han considerado datos multitemporales de teledetección y fenológicos de la vid (Padua et al 2019). Otros han utilizado mapas NDVI (Oldoni et al, 2020) y algoritmos avanzados para extraer información multiespectral pura de la cobertura vegetal utilizando sensores a bordo de UASs (Pádua et al, 2022) o plataformas aéreas (Hall et al 2001) para generar mapas de vigor. Ciertos estudios también han examinado el uso de propiedades físicas del suelo para identificar zonas con rendimientos de plantas similares basados en índices de vegetación (IVs) y estado hídrico de la vid (Bellvert et al, 2012). Otros estudios han combinado la conductividad eléctrica aparente del suelo a escala de campo y mapas NDVI para seleccionar diferentes zonas de fertilidad dentro de los viñedos (Esteves et al 2022; Ortega-Blu et al 2016). Todos ellos tienen en común desarrollar zonificaciones a la mayor resolución posible, debido principalmente a las necesidades de cultivos en espaldera como la vid.

### **1.3.4 Sensores térmicos sobre UASs para diferenciación de suelos**

Considerando las necesidades de alta resolución para el manejo de zonas homogéneas en la vid, los sensores a bordo de UASs son una solución adaptada al desarrollo de este cultivo.

La temperatura del suelo se ve influenciada en gran medida por la tipología de suelo, por lo que aporta información valiosa a la hora de zonificar las parcelas de forma homogénea.

Algunos parámetros como el color, el albedo (proporción de luz solar reflejada en el suelo), la pendiente y la dirección afectan a la proporción de energía reflejada y por tanto la temperatura del suelo (Chuvieco, 2016).

El comportamiento térmico del suelo depende en gran medida de la humedad, que modula el calentamiento y enfriamiento mediante la partición de la energía radiante en componentes de calor latente y sensible. La diferencia en la amplitud de la variación diurna de la temperatura en las superficies del suelo es resultado de las diferencias en su inercia térmica, que está relacionada principalmente con su contenido de humedad (Reginato et al. 1976) y propiedades de textura (Mulders, 1987).

Cuanto mayor sea el contenido de humedad, mayor será la inercia térmica del suelo, ya que esto aumenta su capacidad térmica y conductividad. Esto hace que los suelos húmedos parezcan más frescos que los secos durante el día y más cálidos durante la noche (Chuvieco, 2016).

La textura del suelo tiene un efecto en cuanto a que un suelo sea cálido o fresco. Se ha observado que los suelos cálidos tienden a tener una textura gruesa y una alta cantidad de elementos gruesos (Van Leeuwen et al., 2018).

Por otro lado, los suelos con un alto contenido de materia orgánica ofrecen los valores más bajos de conductividad eléctrica, lo que explica por qué tienden a mostrar diferencias de temperatura más claras entre el día y la noche (Chuvieco, 2016)

### **1.3.5 Sensores multiespectrales para diferenciación de suelos y desarrollo vegetativo**

Desde el punto de vista de una metodología de clasificación objetiva del suelo (USDA), al igual que la temperatura, es posible determinar zonas diferenciadas en base a propiedades físicas y químicas del suelo observadas mediante sensores multiespectrales.

Las plantas son un elemento integrador de las condiciones ambientales, especialmente de las propiedades del suelo. Conocer su estado mediante IVs nos permite delimitar zonas de forma más homogéneas.

Por ello, una de las formas de discriminar las diferencias existentes en el comportamiento entre plantas situadas dentro de un mismo viñedo (intraparcela) o en viñedos distintos (interparcela) es mediante el uso de diversos IVs.

Los IVs son medidas cuantitativas, basadas en los valores digitales, que tienden a medir la biomasa o vigor vegetal. Usualmente, el índice de vegetación es producto de varios valores espectrales que son sumados, divididos, o multiplicados en una forma diseñada para producir un simple valor que indique la cantidad o vigor de vegetación dentro de un píxel. Altos valores de índices de vegetación identifican píxeles cubiertos por proporciones substanciales de vegetación saludable. Existe una variedad de IVs que han sido desarrollados para ayudar en el monitoreo de la vegetación. La mayoría de estos índices están basados en las interacciones diferentes entre la vegetación y la energía electromagnética de las bandas del espectro rojo e infrarrojo.

Cuando la superficie está fuertemente cubierta de vegetación, las propiedades del suelo deben inferirse a partir de mediciones de la superficie con vegetación. Muchos estudios han demostrado la posibilidad de inferir información valiosa sobre un suelo a partir de los patrones y características espectrales observados sobre la vegetación (Bruce y Hormsby 1987). Esta técnica se conoce como geobotánica y se basa en la detección de anomalías en la cubierta vegetal para obtener información sobre las características del suelo y geológicas. Ejemplos de tales anomalías incluyen patrones únicos de distribución de especies de plantas, crecimiento anormal de plantas y patrones de densidad, así como alteraciones en los pigmentos vegetales o el ciclo fenológico de una planta (Chuvieco 2016)

Muchos estudios (Pádua et al 2019; Oldoni et al, 2020; Pádua et al 2022; Hall et al 2001; Esteves et al, 2022) comúnmente han dependido de datos multiespectrales de las plantas para crear zonas de manejo homogéneas, algunos han incorporado información sobre propiedades del suelo a través de muestras de campo o sensores cercanos.

Por otro lado, ha de tenerse en cuenta que la zonificación en base a información sobre IVs u otros parámetros medidos en planta pueden llevar a conclusiones erróneas cuando aparecen condiciones climáticamente adversas (Atencia-Payares, et al 2023) u otros factores bióticos u abióticos.

El suelo, al igual que la vegetación, tiene su propia firma espectral (Figura 1.2.2). Varios estudios han evaluado la utilidad de la variación espectral de la superficie terrestre para la predicción espacial de atributos del suelo a escala regional (Ge et al 2011; Leeuwen et al 2012). Datos del suelo obtenidos de manera remota utilizando fotografías espectrales y en color han sido útiles para crear diferentes mapas de propiedades del suelo a lo largo del campo utilizando diferentes modelos de predicción (López-Granados et al 2005).

La composición espectral de la energía reflejada y emitida por el suelo depende principalmente de los constituyentes biogeoquímicos (minerales y orgánicos), las propiedades ópticas y geométricas de dispersión (tamaño de partículas, aspecto, rugosidad) y las condiciones de humedad de la superficie inmediata del suelo (Bendor et al., 2008; Mulders 1987).

López Granado (2005) observó que las propiedades del suelo podrían correlacionarse con bandas espectrales en el VIS (rojo, verde, azul) mostrando una correlación entre el porcentaje de arcilla y arena en las bandas azul y verde.

Las regiones VIS y NIR se utilizan más comúnmente para inferir las propiedades del suelo (Ge et al., 2011), aunque ocasionalmente se han utilizado las regiones ultravioletas, infrarrojo medio e infrarrojo térmico.

Sin embargo, la relación entre la firma espectral de los suelos y sus propiedades físicas se limitan a la capa más superficial del suelo, ya que, a diferencia de la vegetación, muy poca energía electromagnética se transmite en profundidad sobre los suelos.

El potencial utilitario de datos térmicos y multiespectrales provenientes del suelo para determinar zonas diferenciadas dentro del viñedo aún no ha sido completamente explorado.

## **1.4 Uso de sensores para caracterización del estado hídrico de las plantas**

La variabilidad observada debido a la influencia del suelo también es observada en cuando al estado hídrico de las plantas, muchas veces influenciado por el propio suelo.

Las medidas del estado hídrico de las plantas suelen estar limitadas al aplicar técnicas tradicionales como el uso de la cámara de presión, sin embargo, herramientas como sensores - indicadores del estado del agua en el suelo, temperatura del dosel, y mediciones dendrométricas pueden facilitar la evaluación del estado hídrico a nivel espacial (Naor, 2000).

### **1.4.1 Indicadores del estado hídrico de las plantas**

El conocimiento del estado hídrico es básico a la hora de tomar decisiones sobre el riego. La gestión del riego se realiza en base a consideraciones fenológicas, de los objetivos productivos y de la composición del mosto resultante. La aplicación de las dosis adecuadas de riego permite establecer el equilibrio entre vigor y capacidad productiva. Para determinar la influencia de las condiciones ambientales y culturales en el estado hídrico de la vid, se requiere un indicador fisiológico sensible que integre tanto las condiciones del suelo como las climáticas.

El estado hídrico de la vid es un factor importante en la calidad de la uva. El contenido elevado de taninos y antocianinas en las bayas de uva roja está relacionado con déficits moderados de agua en la vid (Van Leeuwen et al., 1994).

Existen varias formas de evaluar el estado hídrico de la vid como porómetros o sensores automatizables (flujo de savia, dendrómetros), estos últimos son quizás más aplicados a la investigación que a un viñedo comercial por su complejidad y fragilidad, por lo menos hasta el momento (Baeza, 2007).

#### 1.4.1.1 Potencial hídrico del tronco

El potencial hídrico de la hoja se considera como la metodología más aceptada en cuanto a evaluación en campo. Se han estudiado varias formas de medir el potencial hídrico: según el órgano (hoja, tallo, etc) o según el momento del día (a medio día o antes del amanecer). De manera que encontramos medida del potencial hídrico antes del amanecer, potencial hídrico a mediodía y potencial hídrico del tronco o del tallo, también conocido como potencial xilemático a mediodía.

Las mediciones con la cámara de presión pueden proporcionar valores del potencial hídrico de la hoja al amanecer, del potencial hídrico de la hoja y del potencial hídrico del tallo. Potencial hídrico de la hoja al amanecer mide el estado hídrico de la planta con un flujo de agua cero y proporciona información sobre el potencial hídrico del suelo en la zona de las raíces, ya que se considera que el estado hídrico de la planta al amanecer está en equilibrio con el estado hídrico del suelo. potencial hídrico de la hoja diario medido en una sola hoja refleja una combinación de muchos factores: demanda local de agua de la hoja, déficit de presión de vapor (DPV), radiación interceptada por la hoja, disponibilidad de agua en el suelo; conductividad hidráulica interna de la planta y regulación estomática (Choné, 2006)

El potencial hídrico del tallo se diferencia mejor que de la hoja debido a la pequeña variabilidad entre las hojas cubiertas en diferentes brotes de la misma vid. El potencial hídrico de la hoja es mucho más variable, dependiendo del clima local. La vid es una especie que evita el estrés hídrico (Choné, 2006). La conductividad estomática se regula para controlar el déficit hídrico de la hoja (Naor, 1998).

El potencial hídrico del tallo medido con cámaras de presión (Scholander et al., 1965) se ha utilizado para evaluar el estado hídrico de varios cultivos (Hsiao, 1990; Shackel et al., 1997, Sin embargo, estos métodos son consumidores de tiempo, limitando la caracterización exhaustiva en el campo. Por lo tanto, existe una creciente demanda para el desarrollo de tecnologías rentables para evaluar la variabilidad espacial y temporal del estado hídrico de la vid (Fuentes et al., 2012).

Debido a que el potencial hídrico del tallo es un indicativo del estado hídrico de toda la vid, es una herramienta particularmente útil para el manejo del riego, ya que integra las condiciones medioambientales del entorno. Representa con precisión el estado hídrico de la vid, incluso si el contenido de agua del suelo es heterogéneo (Leeuwen et al., 2009)

El modelo actual del continuum suelo-planta-atmósfera se basa principalmente en la teoría de que el agua debe estar bajo tensión para ser transportada a través del xilema de la planta. El transporte de agua en la planta sigue esquemáticamente cuatro pasos: desde el suelo hasta la raíz; de la raíz al xilema del brote; del brote a la hoja a través del pecíolo; y de la hoja a la atmósfera a través de los estomas (Choné, 2001). El estado hídrico medio de la planta depende del potencial hídrico en las capas de suelo cercanas al sistema de raíces, del tamaño de la copa y de la demanda evaporativa. Las plantas presentan valores de déficit hídrico o rangos bajos de potencial reflejados del ajuste del flujo de savia del xilema a la transpiración foliar en relación con la disponibilidad de agua en el suelo.

El potencial hídrico del tallo se mide en una hoja que no está transpirando (Begg y Turner, 1970). El potencial hídrico del tallo diario es el resultado de la transpiración de toda la planta y de la conductividad hidráulica del suelo y de las raíces. El potencial hídrico del tallo indica la capacidad de la vid para conducir agua desde el suelo hacia la atmósfera. Se ha aplicado con éxito como indicador de déficit hídrico en cultivos de duraznos y ciruelas (Garnier y Berger, 1985). Liu et al. (1978) y Greenspan et al. (1996) midieron el potencial hídrico del tallo y los gradientes de potencial hídrico en las cepas. En los árboles de durazno, se mostró que la diferencia entre el potencial hídrico del tallo y de la hoja (balance de potencial hídrico= potencial del tallo – potencial de la hoja), medidos simultáneamente en la misma planta, es un indicador de la transpiración instantánea del brote. Suponiendo una conductividad hidráulica constante en los pecíolos durante toda la temporada de crecimiento, el balance de potencial hídrico varía con la disponibilidad de agua en el suelo (Garnier y Berger, 1985). Aquí reconsideramos el potencial hídrico del tallo como un indicador notable del déficit hídrico de la planta.

#### 1.4.1.2 Conductancia estomática

La conductancia estomática es la capacidad que tienen los estomas de las hojas para regular y controlar la apertura y cierre de los mismos. Los estomas son estructuras microscópicas presentes en la epidermis de las hojas donde tiene lugar

el intercambio de gases. A la hora de medir la conductancia estomática se utilizan aparatos denominado porómetros cuyo principio básico es medir el flujo de vapor de agua a través de los estomas.

La eficiencia y la tolerancia/resistencia a la sequía y al estrés por calor involucran una combinación de varios rasgos y mecanismos que pueden ser morfo-anatómicos, fisiológicos e hidráulicos de las plantas (Chaves et al., 2010; Carvalho et al., 2015). Comprender la fisiología y la bioquímica relacionadas con la regulación estomática y su respuesta al estrés abiótico (por ejemplo, la sequía) es crucial para entender las respuestas de las plantas al ambiente y mejorar las relaciones hídricas de la planta y la eficiencia en el uso del agua (Roelfsema y Kollist, 2013; Tsegay et al., 2014).

Una mejor comprensión de cómo las plantas regulan la temperatura de sus hojas/copa en relación con el comportamiento estomático es igualmente relevante para mejorar la adaptación/resistencia a períodos más largos de estrés por calor y sequía (Costa et al 2015). La vid se considera una especie resistente a la sequía debido a un control eficiente de la apertura estomática en respuesta a los déficits de agua en el suelo y el aire (Chaves et al., 2010; Costa et al., 2012). Este comportamiento puede ser una estrategia de protección contra la pérdida excesiva de agua y la cavitación del xilema (Chaves et al., 2010; Lovisolo et al., 2010), pero dicho comportamiento estomático también puede resultar en una reducción de la refrigeración por evaporación y un consiguiente aumento anormal de la temperatura de las hojas en condiciones extremas (temperaturas del aire altas y déficits de agua en el suelo). En condiciones típicas del Mediterráneo del sur de Europa, las temperaturas de la copa pueden alcanzar fácilmente valores muy por encima del rango considerado óptimo para la fotosíntesis de la vid (25-30°C) (Venios et al., 2020).

Se conoce que el cierre estomático viene determinado por un control hormonal mediado principalmente por el ácido abscísico (Correia et al. 1995; Lovisolo et al. 2002; Pou et al. 2008). Por otro lado, hay evidencia sólida de control hidráulico, que parece dominante bajo el cierre estomático persistente, como ocurre en el estrés hídrico prolongado y la recuperación después de la rehidratación (Lovisolo et al. 2008a; Pou et al. 2008). La hidráulica de la planta puede regularse, entre otros mecanismos, mediante eventos de cavitación, que dependen del gradiente de  $\Psi$  del suelo a la hoja, que a su vez está parcialmente regulado por los movimientos estomáticos (Pou et al 2012). Por lo tanto, existe una fuerte interdependencia entre la hidráulica de la planta y las respuestas estomáticas (Salleo et al. 2000). Diversos

estudios respaldan el hecho de que una señal hidráulica puede ser un regulador dominante del comportamiento estomático (Fuchs y Livingston 1996, Yao et al. 2001).

La regulación estomática en la vid varía con el genotipo (Costa et al., 2012; Tomás et al., 2014), pueden describirse como isohídricas o anisohídricas según sus respuestas de  $\Psi$  al estrés hídrico del suelo (Tardieu y Simonneau 1998). Influye por otro lado la sensibilidad a las variaciones de DPV. Una marcada respuesta estomática al DPV es característica de especies isohídricas, mientras que las especies anisohídricas muestran una respuesta menos pronunciada y, por lo tanto, tasas de transpiración más altas (Tardieu and Simonneau 1998). De esta manera, las plantas isohídricas mantienen un  $\Psi$  relativamente alto bajo estrés hídrico, ya que la conductancia estomática se regula finamente para evitar una disminución del  $\Psi$  tallo a niveles que provocarían una pérdida excesiva de conductividad (Vogt 2001). En consecuencia, las plantas isohídricas tienen un potencial hídrico mínimo al mediodía que permanece más o menos constante a medida que el suelo se seca. Por el contrario, las plantas anisohídricas muestran una depresión sustancial de  $\Psi$  durante la sequía sin mostrar más deterioros, es decir, muestran cierto grado de tolerancia. En estas plantas, la transpiración no está tan regulada por el cierre estomático.

En comparación con los genotipos anisohídricos, se ha demostrado que los genotipos isohídricos tienen varias características diferenciales, como un aumento más pronunciado de la eficiencia intrínseca del agua disponible en el suelo como respuesta al estrés hídrico (Poni et al. 2007), una mayor sensibilidad estomática al aumento del déficit de presión de vapor (Soar et al. 2006) y una conductancia hidráulica más baja y una menor susceptibilidad a la cavitación (Schultz 2003; Vandeleur et al. 2009), manteniendo una velocidad similar de recuperación de las tasas de intercambio gaseoso de las hojas después del estrés hídrico como las plantas anisohídricas (Schultz 2003).

Consecuentemente, estas características han llevado a considerar que las variedades isohídricas están mejor adaptadas a los entornos de sequía que las variedades anisohídricas (Schultz 2003; Soar et al. 2004, 2006; Vandeleur et al. 2009). Sin embargo, aunque las variedades de vid de origen mediterráneo, como la Garnacha, muestran un comportamiento casi isohídrico, las variedades típicamente anisohídricas, como Syrah y Chardonnay, son comúnmente cultivadas y utilizadas para la elaboración de vino en regiones mediterráneas semiáridas (Jones 2006). Por otro lado, aparecieron informes contradictorios en la literatura

que mostraban que la misma variedad podía comportarse como iso- o anisohídrica dependiendo de las condiciones experimentales (Chaves et al. 2010; Lovisolo et al. 2010).

### **1.4.2 Sensores térmicos para caracterización del estado hídrico de las plantas**

La termografía se basa en que cuando tiene lugar un factor de estrés (por ejemplo, falta de disponibilidad hídrica), la transpiración disminuye debido al cierre estomático, la temperatura de la hoja aumenta a medida que la refrigeración evaporativa en la hoja disminuye. Por lo tanto, las imágenes térmicas son particularmente adecuadas para monitorear la relación de evapotranspiración real a potencial ( $E/E_p$ ) como indicador del estrés hídrico del cultivo (Jackson et al., 1981; González-Dugo et al., 2014). Un paso posterior es relacionar la relación de evapotranspiración con cambios en el potencial hídrico de la hoja o del tallo (Berni et al., 2009; Möller et al., 2007; Bellvert et al., 2016, Awais, 2023) o la conductancia del dosel (Gutierrez et al., 2021).

Las propiedades térmicas de la vegetación son bastante complejas, ya que las plantas absorben una gran cantidad de energía solar incidente para impulsar la fotosíntesis. Esta energía se reemite durante la noche para mantener el equilibrio energético. Además de esto, la vegetación tiene un alto contenido de agua y, por lo tanto, tendrá una alta inercia térmica. Otro factor importante que controla los patrones térmicos de la vegetación es la evapotranspiración (ET), que regula el agua y la temperatura de la planta. Cuando las plantas transpiran, el exceso de energía involucrado en la liberación de vapor de agua implica una reducción en el calor sensible y una disminución paralela en la temperatura superficial de la planta. Por esta razón, las plantas tienden a estar más frescas durante el día que sus alrededores (Chuvieco, 2016)

Aunque exista una complejidad en las dinámicas de energía y radiación de las plantas, es posible, mediante la termografía infrarroja, monitorizar el estado hídrico de las plantas (Gates, 1964; Jackson et al., 1977; Jones, 1999; Jones et al., 2002; Jones et al., 2009) y desarrollar los programas de riego (Cohen et al., 2005, 2017; Jones, 2004; Meron et al., 2010).

Algunos estudios han demostrado en cultivos leñosos como el olivo, la posibilidad de detectar y mapear la variabilidad del estado hídrico a partir de la diferencia de temperatura de la hoja y el aire ( $T_c - T_a$ ) (Sepulcre-Cantó et al. 2006) o mediante el

Crop Water Stress Index (CWSI) (Berni et al. 2009). El uso de mapas de CWSI en viñedos puede ser un método simple, coste-efectivo para un manejo eficiente del riego en función de su estado hídrico (Bellvert et al 2015).

El CWSI es uno de los indicadores más populares para cuantificar el estrés hídrico utilizando sensores térmicos remotos (Jackson et al., 1981; Berni et al., 2009). El CWSI es un modelo evaporativo de una fuente basado en el balance de energía de la superficie (Jackson et al., 1981). Puede calcularse con una operación de escalamiento simple, donde la temperatura de la copa observada,  $T_c$ , se normaliza por la  $T_c$  de un cultivo totalmente transpirante (Thumedo) y la  $T_c$  de un cultivo que no está transpirando en absoluto ( $T_{seco}$ ). Sin embargo, estimar correctamente el Thumedo y el  $T_{seco}$  es bastante desafiante, para ello se han desarrollado enfoques tanto teóricos (Jackson et al., 1981) como empíricos (Idso et al., 1982). En el enfoque teórico, el Thumedo y el  $T_{seco}$  se evalúan a partir de un modelo basado en la física, como las ecuaciones de Penman-Monteith y transferencia de masa para los flujos turbulentos. Esto requiere información micrometeorológica, no siempre fácil de obtener localmente, como la velocidad del viento, la radiación global o las resistencias aerodinámicas y estomáticas (Jackson et al., 1981). Existen enfoques empíricos más simples, con la desventaja de ser específicos para el cultivo y el lugar. Idso et al., (1982) relacionaron la diferencia de temperatura entre la copa y el aire ( $T_c - T_a$ ) de una copa transpira constantemente a una tasa potencial con el DPV.

Otras alternativas para estimar líneas de base se basan en el uso de superficies de referencia húmedas y secas naturales (Clawson et al. 1989; Leinonen y Jones 2004) o artificiales (Meron et al., 2003). En el caso de la vid, se han reportado ejemplos de Merlot (Möller et al. 2007) y Cabernet Sauvignon (Wheaton et al. 2011). Un ejemplo es estimar el Thumedo, rociando hojas con agua jabonosa en ambos lados para mantener su humedad (Thumedo) o con espuma de poliestireno (Meron et al., 2003). Para el  $T_{seco}$  se ha utilizado la cobertura de las hojas con vaselina en ambos lados para evitar la transpiración (Jones et al., 2002). Un enfoque más general estima  $T_{seco}$  simplemente sumando 5°C a la temperatura del bulbo seco (Irmak et al., 2000).

Otro desafío es que los indicadores térmicos se relacionan con la transpiración y no con el  $\Psi_{hoja}$  o el  $\Psi_{tallo}$ , que son el punto de referencia para el estado del agua y la gestión del riego en las cepas. El CWSI se ha relacionado empíricamente con estos (Bellvert et al., 2014; Moller et al., 2007; Weathon et al., 2011).

Para poder desarrollar sistemas de información operativos sobre el estado del agua en los cultivos, es crítico encontrar enfoques robustos y parsimoniosos para estimar  $T_{humedo}$  y  $T_{seco}$  a lo largo del tiempo y bajo diversas condiciones de agua en el suelo, evitando mediciones de campo in situ tanto como sea posible.

## 2. Objetivos de investigación

El objetivo general es evaluar el potencial de sensores térmicos y multiespectrales para la monitorización temporal y espacial del estado hídrico de la vid bajo diferentes escenarios agronómicos.

Para ello se realizaron dos ensayos, cada uno de ellos con un objetivo específico:

- Ensayo 1: Capacidad de los sensores del UASs para distinguir tipos de suelo. Este estudio tuvo como objetivo específico evaluar el potencial de los sensores de UASs para detectar la heterogeneidad espacial. Se evaluó el desarrollo de la vid en suelos con características hidráulicas distintas, bajo las mismas prácticas de manejo, comparando datos recopilados del UASs y de técnicas convencionales de campo durante diferentes años climáticos.
- Ensayo 2: Capacidad de los sensores térmicos del UASs para distinguir el estado hídrico de la vid. El objetivo específico de este estudio es evaluar el potencial del CWSI, calculado a partir de información obtenida de cámaras térmicas a bordo de un UAS, para estimar el potencial hídrico de la vid. Además, determinar el momento adecuado del día para obtener esta información.

## 3. Material y métodos

### 3.1 Zona de estudio

#### 3.1.1 Ubicación

El viñedo comercial donde tuvo lugar el estudio se encuentra en Yepes, Toledo (España), situado a  $39^{\circ}56'25.8''$  N  $3^{\circ}43'22.4''$  W (ETRS89, UTM zona 30 N), a una altitud de 570 msnm, con una extensión de alrededor de 82 ha de viñedo repartido en 15 parcelas (Figura 3.1.1). Los viñedos pertenecen a las *Bodegas y Viñedos Casa del Valle* perteneciente al grupo de Bodegas Olarra.




Figura 3.1.1. Mapa ubicación de la bodega y las diferentes parcelas de viña. Localización de los dos ensayos.

### 3.1.2 Clima

Una estación meteorológica en Magán proporcionó datos de temperatura, precipitaciones y ETo (546 msnm, latitud 40°2'5.81" N y longitud 3°20'3.49" W, Huso UTM30 Coord) (Tabla 3.1.2).

El clima de la zona de estudio está caracterizado por tener inviernos fríos y veranos calurosos con fuertes oscilaciones térmicas y un régimen de lluvia irregular más abundante en otoño y en primavera.

En invierno es frecuente que las temperaturas bajen de los 0 °C en la mayor parte de la región. La temperatura media del mes de enero se sitúa por debajo de los 6 °C, produciéndose numerosas heladas en las noches despejadas de nubes, también son frecuentes las heladas a principios de primavera y finales de otoño.

La temperatura media en verano es alrededor de los 27 °C. Con máximas que llegan a superar los 35°C (AEMET, 2023)

Las precipitaciones son escasas, siendo 338 mm la media anual. La Comunidad Autónoma donde se encuentra el ensayo es de las zonas más secas de España (AEMET, 2023) incluyéndose dentro de la denominada "España seca".

Tabla 3.1.1. Datos climatológicos, estación climatológica de Magán-Toledo serie 20 años (2000-2020)

Estación Magán			
Mes	Precipitación (mm)	ETo (mm)	Tmm (°C)
Enero	28	30	5.2
Febrero	22	49	7.3
Marzo	37	84	10.3
Abril	51	110	13.2
Mayo	31	158	18.0
Junio	16	203	23.5
Julio	5	234	26.9
Agosto	11	204	26.2
Septiembre	20	134	21.2
Octubre	47	78	15.8
Noviembre	37	40	9.5
Diciembre	33	25	6.1
Anual	338	1350	15.3

Por otro lado, se tomaron datos climáticos de un medidor portátil de temperatura y humedad con Datalogger OMEGAETTE modelo HH314A. Esta estación está compuesta por una sonda de temperatura/humedad que utiliza un semiconductor y un sensor capacitivo de polímero. Cuenta con una pantalla triple para mostrar la temperatura y la humedad de la sonda y puede mostrar los datos de un termopar de tipo K separado conectado a la entrada T2 mediante un conector en miniatura de tipo SMP estándar.

La conexión termopar se utiliza para tomar valores de temperatura de una referencia artificial húmeda (RAH). Esta referencia se situó cerca de la estación meteorológica portátil, a la sombra de las cepas. RAH consiste en una tela no tejida húmeda que cubre un flotador de poliestireno. El flotador se coloca en una caja de plástico llena de agua de  $0,28 \times 0,30$  m. De esta manera, la tela se mantiene constantemente mojada.

Los valores se registraron cada minuto y se tomaron medias por hora.



Figura 3.1.2. Estación meteorológica portátil situada dentro del seto, midiendo la temperatura del aire. Incluye un datalogger y un termopar conectado a una referencia artificial húmeda (RAH) compuesta por una bayeta amarilla constantemente húmeda.

### 3.1.3 Material vegetal

En la zona seleccionada se cultivan cepas de Merlot (*Vitis vinifera* L.) de veinte años, injertadas sobre portainjertos SO4 (Selección Oppenheim 4). Las hileras de vid están orientadas al noreste y dispuestas en espaldera, con un marco de plantación de  $2,60 \times 1,10$  m. El estudio se realizó durante las temporadas de riego de 2021 y 2022.



Figura 3.1.3. Detalle cepa de Merlot

**Ficha ampelográfica:**

Pámpano Joven: Brotación algodonosa, con pigmentación rojiza en el ribete de las hojas

Porte de la cepa: Erguido

Características de la hoja: Tamaño medio, forma cuneiforme, senos laterales marcados, haz verde oscuro y envés arañoso.

Características del racimo: Tamaño medio, sueltos y forma cónica y larga

Características de la baya: Tamaño pequeño, forma esférica y color azul-negra.

Periodo vegetativo: brotación entre temprana y media, y maduración media-temprana.

Rendimiento: 3.1 a 3.6 kg/cepa

Vulnerabilidad: Sensible al mildiu y la botrytis.

**Aptitudes agronómicas:** Es una variedad sensible a las heladas de primavera, sensible al mildiu y resistente al oidio. Presenta un vigor medio-alto (con fuerte tendencia a emitir chupones) y una maduración temprana de la uva.

Prefiere suelos argílicos calcáreos. Da vinos más ligeros sobre aluviones, arenas o gravas filtrantes, y vinos fuertes, coloreados y más tánicos sobre los suelos arcillosos, arcillo-calcáreos o gravas arcillosas.

**Patrón:** Selección Oppenheim del Teleki nº4 (SO4)(Variedades de vid, Registro de variedades comerciales, Ministerio de Agricultura, Pesca y alimentación, 2003)

Es bastante resistente a contenidos elevados de caliza en el suelo y resistente a la sequía. Soporta bien los subsuelos húmedos. Es sensible a la carencia de magnesio y tiende a agravar los problemas de desecación del raspón.

Durante mucho tiempo fue el patrón de moda principalmente en Francia y en zonas frescas, sin embargo, su excesivo vigor, la producción de vino de calidad mediocre y los problemas de desecación del raspón han propiciado poco a poco su abandono.

## 3.2 Equipos empleados

Para ambos ensayos se utilizó la plataforma de UAS de ala fija eBee SenseFly (AgEagle Aerial Systems Inc., Wichita, Kansas), equipada con un sensor multiespectral Parrot Sequoia (Parrot© SA, 2017, París, Francia) y un sensor térmico Duet-T (AgEagle Aerial Systems Inc., Wichita, Kansas). Los vuelos del UAS se llevaron a cabo a 120 metros sobre el nivel del suelo. Se obtuvo una resolución media de imagen en tierra de 0.148 m para el sensor multiespectral y 0.16 m para el sensor térmico por píxel. La elección de este tipo de dron se basa en la capacidad de cubrir grandes áreas en una sola misión, gracias a la eficiencia aerodinámica y mayor autonomía de vuelo (Rakech et al., 2021)

Los parámetros de vuelo del UAS fueron los siguientes: velocidad de 50 km/h; solapamiento del sensor Duet-T, solapamiento lateral del 80% y solapamiento longitudinal del 80%; solapamiento del sensor multiespectral, solapamiento lateral del 70% y solapamiento longitudinal del 70%.



Figura 3.2.1. Imagen Superior: Plataforma UAS de ala fija. Imagen inferior izquierda: cámara térmica Duet-T (AgEagle, 2022). Imagen inferior derecha: Sensor multiespectral Parrot Sequoia (Parrot, 2021)

El sensor multiespectral Parrot Sequoia cuenta con cuatro bandas espectrales: Green (530-570 nm), Red (640-680 nm), Rededge (730-740 nm) e Near Infrared (NIR) (770-810 nm). Antes del vuelo, se tomaron imágenes de una placa de

calibración con la cámara Parrot Sequoia para normalizar la iluminación local. El sensor térmico Duet-T incluye una cámara infrarroja térmica de alta resolución y una cámara RGB senseFly SODA. Las imágenes se registraron durante condiciones de cielo despejado. Las principales características se describen en la Tabla 3.2.1

Tabla 3.2.1. Parámetros de los sensores multispectrales y térmicos instalados en el UASs utilizados en todos los vuelos del estudio.

Sensor	Resolución espectral (nm)	Resolución espacial (m/pixel)	Solape
Parrot Sequoia Multispectral	Green (530-570) Red (640-680) Rededge (730-740) NIR (770-810)	0.14	70%
Duet-T	Infrarojo térmico (FLIR) 700-1200	0.16	80%

### 3.3 Ensayo 1: Caracterización de suelo

#### 3.3.1 Localización y descripción de las viñas del Ensayo 1

Para este estudio se seleccionó la parcela 12 (Figura 3.1.1) con coordenadas 39°56'24.4"N 3°43'19.7"W y superficie de 4.5 ha. Dicha parcela se regaba de forma uniforme, los volúmenes de agua utilizados se aplicaron con un gotero por cada metro y caudal de 2 l h<sup>-1</sup>. El riego se programó siguiendo las prácticas estándar seguidas por la Bodega, es decir, con intervalos de tiempo limitados.

El periodo de riego fue de 17/05/2021 a 27/08/2021 en 2021 y de 23/06/2022 a 01/09/2022 en 2022. Las cantidades de agua aplicadas durante la temporada de riego fueron de 131 y 79 mm en 2021 y 2022, respectivamente. El año 2022 tuvo lugar reducciones del 40 y 49 % en riego y lluvia + riego, respectivamente, en comparación con 2021, debido a la baja disponibilidad de agua durante este año. En ambos años, el agua proporcionada por el riego fue insuficiente para cubrir las altas demandas evaporativas, y se utilizó riego deficitario. Considerándose un 14% de la ETo para 2021 y 8% de la ETo para 2022.

Tabla 3.3.1. Horas y dosis de riego totales del ensayo

	2021		2022	
	Horas de riego	Dosis de riego (mm)	Horas de riego	Dosis de riego (mm)
Mayo	8	5.59	sin riego	sin riego
Junio	34	23.78	12	8.39
Julio	60	41.96	36	25.17
Agosto	54	37.76	47	32.87
Total	156	109.09	95	66.43

### 3.3.2 Parámetros evaluados

#### 3.3.2.1 Prezonificación y zonificación del suelo

En las parcelas del viñedo, se identificaron diferentes zonas homogéneas a través de la metodología de fotointerpretación realizada por la empresa DIAGNOTERRA S.A, basada en mapas históricos del Plan Nacional de Ortofotografía Aérea, PNOA, a lo largo de 30 años de evolución. Los datos de teledetección y modelos digitales del terreno obtenidos del PNOA contaban con una resolución espacial de 2 m/píxel.

La prezonificación se realizó utilizando el programa ArcGIS (Esri, Redlands, CA, EE. UU) considerando dos criterios: (i) la diferencia de color del suelo utilizando criterios geomorfológicos, principalmente relieve y litología, según patrones fotográficos asociados a texturas y tonalidades definidas y (ii) las zonas con diferentes colores que tienen un área representativa (superior a 100 m<sup>2</sup>). Ambos criterios aseguraron una simplicidad y representatividad adecuadas del área (Figura 3.2.2).

Una vez delimitadas las zonas, se selecciona en una zona experimental de 13.900 m<sup>2</sup> (limitada por el recuadro verde) (Figura 3.3.2), se localizaron en el mapa de prezonificación dos suelos diferentes dentro de la zona experimental, se hizo una calicata en cada suelo (C1 y C2) y se establecieron cerca de las calicatas las cepas de estudio. Complementando a las calicatas se hicieron unos sondeos, usando una barrena manual, a lo largo de la zona experimental para ajustar las líneas del mapa de prezonificación.



Figura 3.3.2. Fotografía aérea del viñedo experimental. Las líneas indican la zonificación preliminar del suelo del viñedo comercial. El recuadro rojo representa la parcela 12 de estudio. El recuadro verde representa la zona experimental dentro de la parcela de estudio. Las cepas de estudio se encuentran en los círculos rojos dentro del recuadro verde.

La zonificación final de las parcelas de viñedo se obtuvo siguiendo el manual Soil Survey de USDA (Ditzler et al., 2017), realizando observaciones de suelo entre calicatas y sondas de barrena manual.

#### 3.3.2.2 Propiedades físicas y químicas y clasificación del suelo

Se realizaron dos calicatas y varios sondeos en la parcela de estudio. La elección de estas dos calicatas vino determinada tras la fotointerpretación del mapa de prezonificación (Figura 3.3.2), donde se localizaron dos zonas diferentes.

Una vez se decide las dos zonas de estudio, se procede a hacer la evaluación en campo. Para llevarlo a cabo el 19/05/2021 se abrieron las dos calicatas (C1 y C2) correspondiente a cada zona, con una retroexcavadora. Y se hicieron los sondeos

con una barrena. La profundidad de la calicata la delimita la aparición de la roca madre más o menos alterada.

La calicata es una apertura en el suelo, con al menos una de las paredes verticales y orientada al sol. El sondeo es una apertura de suelo de menor entidad de la que se extrae un cilindro de suelo de unos 10 cm de diámetro a una determinada profundidad. La calicata permite observar el suelo como un continuo y tiene por objetivo caracterizar la unidad taxonómica al cumplimentar la ficha de campo (Figura 3.3.3) usando el Manual de estudio de suelos del USDA (Ortega-Blu, et al 2016). Se tomaron muestras de los diferentes horizontes y se enviaron al laboratorio EUROFINS AGROAMBIENTAL S.A con las normas de procedimientos definidos en la Tabla 3.3.2.

Tabla 3.3.2. Procedimientos realizados en laboratorio para analizar las propiedades físicas y químicas (PFs y PQs) de los suelos de los dos ensayos.

PFs y PQs	Procedimiento
Humedad	Humedad 105 °C Gravimetría
pH	pH (extracto 1:2.5 H <sub>2</sub> O) Potenciometria
Conductividad eléctrica 25 °C	Conduct. Eléctrica 25°C (extr. 1:5 H <sub>2</sub> O) Conductimetria
Materia orgánica oxidable	Materia orgánica (Walkey&Black) Titulación potenciométrica
Caliza activa	Método interno Valoración potenciométrica
Nitrógeno-Kjeldahl	Nitrógeno Kjeldahl (N) Títulación volumetrica
Fósforo sms	Fósforo (P) (Olsen) Espectrofotometria UV-VIS
Potasio sms	Potasio (K) (extracto acetato amónico) Espectrometría ICP-OES
Calcio sms	Calcio (Ca) (extracto acetato amónico) Espectrometría ICP-OES
Magnesio (Mg)	Magnesio (Mg) (extracto acetato amónico) Espectrometría ICP-OES
Sodio (Na)	Sodio (Na) (extracto acetato amónico) Espectrometría ICP-OES
Elementos gruesos D> 2 mm	Elementos gruesos D>2 mm Método interno gravimetría
Texturas	Textura USDA sedimentación discontinua (5 fracciones) Método interno gravimetría
Cap. Reten. Del agua disponible	Método interno gravimetría

Se analizaron varias propiedades del suelo para cada horizonte: textura, profundidad, materia orgánica (MO), conductividad eléctrica de los extractos de pasta saturada (relación 1:2,5) (CEe), pH, caliza activa y nitrógeno total. Se tomaron tres repeticiones de cada horizonte para poder analizar los diferentes parámetros.

Para complementar la clasificación de una zona se utiliza el sondeo; el uso del sondeo pretende la cuantificación de tales unidades (STU) dentro de las unidades cartográficas (SMU) a partir de la identificación de las unidades taxonómica *in situ*

Paraje o finca		M.T.N.	Altitud (m)		Foto N°	Localización		Número											
Municipio Provincia		Lat. N UTM	Long.		(figs. 6.1-6.2) Pasada Vuelo	OPERADOR: V. Gómez-Miguel (UPM)													
Reg. Humedad (fig. 4.2) Reg. Temperatura		ESQUEMA DEL RELIEVE				GEOFORMA (fig. 4.4)													
VEGETACIÓN Uso del suelo						Pendiente (%) Desagüe Drenaje (l)		Orientación Drenaje Int. Prof. frástica (m)											
LITOLOGÍA (Fig. 4.3) Mat. Originaria		OBSERVACIONES				Soil Tax.		CLASIFICACIÓN (figs. 12 y 13)											
Racibilidad Pedregosidad (H)						FAO C.P.C.S.													
						CAPACIDAD													
PROFUN- DIDAD (cm)	HORIZONTES		(A) Límite	COLOR (Fig. 10.2) Seco Húmedo	MOTEAJOS (Fig. 10.3) Color		(B) TEXTURA (Fig. 10.3)	(C) ELEMENTOS GRUESOS (Fig. 10.3) (% Naturales (Fig. 4.3))	(D) ESTRUCTURA (Fig. 10.4)	COMPACTAD., POROSIDAD, GRUEBAS (Fig. 10.5)	Consist.	(E) CONSISTENCIA			(F) RAÍCES		CONCRE- CIONES COSTRAS	OTROS RASGOS (G) Infiltración, pisofitos, etc.	MUESTRA N° (Fig. 11.1)
	Genéticos (usado 7)	Diagnósticos (usado 19)	Tipo Topografía		HUMEDAD (Fig. 10.2)	Calor						Car.	H	S	M	Cantidad Características			

(A) LÍMITE	(B) TEXTURA	(C) ELEMENTOS GRUESOS	(D) ESTRUCTURA Forma (Tipo)	(E) CONSISTENCIA	(F) RAÍCES	(G) INFILTRACIÓN mm/24 h.	(H) PEDREGOSIDAD SUPERFICIAL
<b>A</b> BRUSCO < 2 mm <b>N</b> NETO 2-5 mm <b>G</b> GRADUAL 5-17 cm <b>D</b> DIFUSO > 17 mm	<b>A</b> ARENOSA <b>C</b> ARCILLOSA <b>F</b> FRANCA <b>L</b> LIMOSA	<b>1</b> < 2% <b>2</b> 2-20% <b>3</b> 20-40% <b>4</b> 40-80% <b>5</b> > 80%	<b>GS</b> GRANULAR SIMPLE <b>G</b> GRANULAR ANGULOSA AGLOMERADO <b>L</b> LAMINAR <b>P</b> PRISMÁTICA <b>R</b> RAÍCES <b>F</b> FAUNA	<b>SECO (S)</b> DUREZA { -Alta -Media -Baja } <b>HÚMEDO (H)</b> FRIABILIDAD { -Alta -Media -Baja } <b>MOJADO (M)</b> FLASTICIDAD Y ADHESIÓN { -Alta -Media -Baja }	<b>A</b> ABUNDANTES <b>F</b> FRECUENTES COMUNES <b>P</b> POCAS <b>MP</b> MUY POCAS <b>N</b> NINGUNA	<b>MA</b> MUY ALTA > 200 <b>A</b> ALTA 100-200 <b>M</b> MEDIA 40-100 <b>L</b> LENTA 5-40 <b>ML</b> MUY LENTA = 5	<b>0</b> NO HAY PIEDRAS <b>1</b> INTERFEREN CON EL LABOREO <b>2</b> NO PERMITEN ADITIVOS DE ESCARDA (0,1-3%) <b>3</b> INTERFEREN EN EL USO DE LA MAQUINARIA (3-15%) <b>4</b> IMPIDEN EL USO DE MAQUINARIA (15-90%) <b>5</b> > 90% DE SUPERFICIE
<b>S</b> SUAVE <b>P</b> PLANO <b>O</b> ONDULADO <b>IR</b> IRREGULAR <b>IN</b> INCLINADO		<b>B</b> BLOQUES < 20 cm <b>P</b> PIEDRAS 20-6 cm <b>PP</b> PIEDRAS PEQUEÑAS 6-1 cm <b>D</b> DIFUSO > 17 mm	<b>B</b> BLOQUES CÚBICA SUBANGULAR O POLIÉDRICA <b>C</b> COLUMNAR <b>M</b> MACIZA <b>N</b> SIN DESARROLLAR (MASIVA)		<b>MUY FINAS</b> (< 1mm) <b>FINAS</b> (1-2 mm) <b>MEDIANAS</b> (2-5 mm) <b>GRUESAS</b> (5-10 mm) <b>MUY GRUESAS</b> (> 10 mm)	<b>(I) DRENAJE</b> <b>0</b> MUY ESCASAMENTE DRENADO - NO DRENADO <b>1</b> ESCASAMENTE DRENADO <b>2</b> IMPERFECTAMENTE DRENADO <b>3</b> MODERADAMENTE BIEN DRENADO <b>4</b> BIEN DRENADO <b>5</b> ALGO EXCESIVAMENTE DRENADO <b>6</b> EXCESIVAMENTE DRENADO	

Figura 3.3.3. Ficha de campo (modelo) y resumen de codificación simple (Instituto Geográfico Nacional, 2006)

Tras el análisis de laboratorio se procede a calcular la capacidad de retención de agua (CRA) calculándose de la siguiente manera:

$$AD = P \times (Ad/100) \times Da \times 1000 \quad (1)$$

$$CRA = AD \times ((100 - GV) / 100) \quad (2)$$

Donde  $A_d$  es el agua disponible (% peso) obtenida como diferencias entre el contenido de agua a  $-0,33$  bares (capacidad de campo) y  $-15$  bares (punto de marchitez),  $D_a$  es la densidad aparente ( $t/m^3$ ),  $P$  es la profundidad de los horizontes (m) y  $GV$  es la grava (tamaño de partícula mayor a 2 mm) (% vol).

### 3.3.2.3 Parámetros fisiológicos y agronómicos de las cepas

Los parámetros fisiológicos y agronómicos se midieron en 12 cepas experimentales establecidas en los suelos de estudio, es decir, 6 plantas por calicata o tipo de suelo (C1 y C2). Las 6 plantas de C1 estaban dispuestas en la misma línea, una a continuación de la otra, cerca de donde se realizó la calicata C1. Las 6 plantas de C2 estaban dispuestas de la misma forma, pero no en la misma línea que las cepas de C1.

#### Fenología

Las principales etapas fenológicas (brotación, floración, envero y maduración-cosecha) se definieron utilizando la escala fenológica de Eichhorn y Lorenz (1977), modificada por Coombe (1995).

#### PHT y Chl

Parámetros fisiológicos como el potencial hídrico del tronco (PHT) y el contenido de clorofila (Chl) se midieron en las 12 cepas experimentales a las 9:00 y 12:00 horas solares en 9 días específicos a lo largo de las dos temporadas de estudio (25/06/2021, 05/07/2021, 20/07/2021, 30/07/2021, 18/08/2021, 30/06/2022, 15/07/2022, 05/08/2022 y 12/08/2022). El PHT se evaluó en hojas maduras, sanas y sombreadas, encerradas durante 1 hora en bolsas de papel de aluminio para alcanzar el equilibrio del estado hídrico entre la hoja y el tallo. El PHT se midió utilizando una cámara de presión Scholander (Soil Moisture Equipment Corp., Santa Bárbara, CA, EE. UU.).

La Chl se midió simultáneamente en tres hojas por cada cepa experimental utilizando un Apogee MC-100 (Apogee Instruments, Inc., Logan, UT, EE. UU.) en los mismos días y horas que la evaluación del PHT.

#### Geometría

La copa o dosel de la espaldera se describió para las 12 cepas experimentales el 28/06/2021 y 20/06/2022, momento en el que las cepas se encuentran completamente desarrolladas. Una cinta flexible midió el contorno total de la

cubierta en tres puntos diferentes de cada cepa: en mitad del tronco y a 40 cm de distancia desde el tronco a la izquierda y luego a la derecha. Se anotaron las alturas de las hojas más altas y bajas en los mismos puntos. El ancho de la cubierta se midió en cada punto a tres alturas diferentes (80, 110 y 120 cm). Estos datos se utilizaron para calcular el volumen de la cubierta y la superficie foliar externa (SA) en m<sup>2</sup> (ecuación 3)

$$SA = \frac{(2 \times H \times D) + (A \times D)}{MP} \quad (3)$$

Siendo A la anchura media, H la altura media, D la distancia entre cepas y MP el marco de plantación (IFAPA, 2007).

La densidad de hojas se estimó como un espacio en la cubierta. Se tomó una foto de la cubierta de cada cepa experimental con una manta roja en el fondo para delimitarla (Figura 3.3.4). Utilizando el software ImageJ (Wayne Rasband., Bethesda, MD, EE. UU.). Mediante este programa podemos separar una imagen RGB en tres bandas, verde, azul y rojo.

Para facilitar el cálculo de los espacios vacíos trabajamos con la banda roja, de esta manera la imagen es más sensible al contraste entre el verde de la planta y el fondo rojo. Se transforma la imagen de la banda roja mediante binarización, y a través de la barra que se puede observar en la parte superior de la Figura 3.3.4. se calcula el porcentaje de espacios vacíos, buscando el equilibrio de saturación entre la vegetación y el fondo rojo.

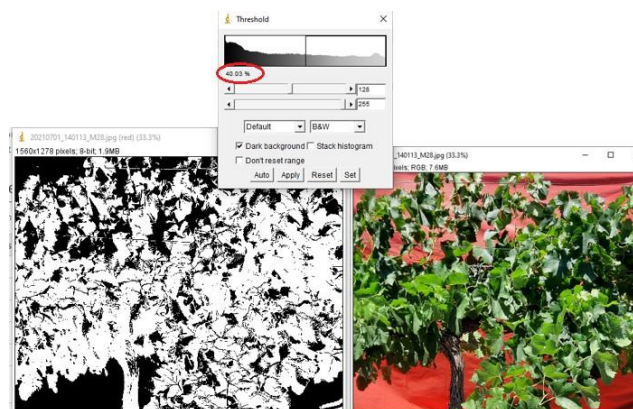


Figura 3.3.4. Captura de pantalla del programa ImageJ utilizado para obtener el valor porcentual de los poros de las cepas transformando las imágenes RGB.

### Seguimiento de maduración

Durante las dos campañas de riego se tomaron muestras de bayas para hacer un seguimiento de maduración, se hicieron 3 muestreos por año (20/07/2021, 30/07/2021, 19/08/2021, 28/07/2022, 08/08/2022, 12/08/2022). En las cepas a los lados de cada tratamiento se tomaron 2 muestras representativas de 100 bayas cada una. Al igual que con las bayas de vendimia, se pesaron y procesaron para determinar los azúcares (°Brix), pH y acidez.

### Vendimia

Las cepas experimentales se vendimiaron el 20/08/2021 y 16/08/2022, se pesó la producción y se contaron los racimos. Se tomaron muestras de 100 bayas por cepa experimental en el momento de la vendimia. Las muestras se colocaron en bolsas de plástico etiquetadas, se colocaron en una hielera portátil con hielo y se llevaron al laboratorio. Inmediatamente se pesaron y procesaron para determinar los sólidos solubles totales (°Brix) usando un refractómetro Atago Brix digital (ATAGO CO., LTD., Tokio, Japón) y la acidez total usando un neutralizador automático 702 SM Titrino (Metrohm AG, Herisau, Suiza) y un medidor de pH Hach sensION (empresa Hach, Loveland, CO, EE. UU.), según el método de Glories (2001).

### Peso de madera de poda

La poda se realizó contando y pesando los distintos sarmientos para cada una de las cepas de estudio.

#### 3.3.2.4. Sensores térmicos y multiespectrales

La campaña de vuelos del UAS se realizó a las 12:00, para evitar el efecto de sombra. En la Tabla 3.3.3 se resumen los diferentes días de vuelo y sobre que superficie se tomó información, suelo o vegetación.

Tabla 3.3.3. Calendario de las imágenes obtenidas sobre las superficies de estudio, vegetación y suelo, realizadas con cámaras térmica y multiespectral instaladas en el UAS durante los dos años de estudio (2021 y 2022)

<b>Superficie</b>	<b>año</b>	<b>sensor multiespectral</b>	<b>sensor térmico</b>
<b>Vegetación</b>	<b>2021</b>	25/06/2021	
		05/07/2021	
		20/07/2021	
		30/07/2021	
		18/08/2021	
	<b>2022</b>	30/06/2022	
<b>Suelo</b>	<b>2021</b>		15/05/2021
		17/05/2021	20/07/2021
	<b>2022</b>		17/05/2022
		19/05/2022	15/07/2022

A la vez que se tomaban imágenes multiespectrales de la vegetación, se tomaban datos de fisiología (PHT y Chl)

Las cepas experimentales fueron identificadas utilizando el software QGIS 3.4 (QGIS, Free Software Foundation, Boston, MA, EE. UU.). El dosel de cada cepa fue delimitado mediante polígonos de  $0.30 \times 0.30$  m (Figura 3.3.5a), 12 polígonos en total (uno por planta). Estos polígonos se ubicaban en el centro de la cepa para evitar los efectos de sombras y componentes del suelo. El número de píxeles que se extrajeron a través de los polígonos fue de 6 píxeles por cepa.

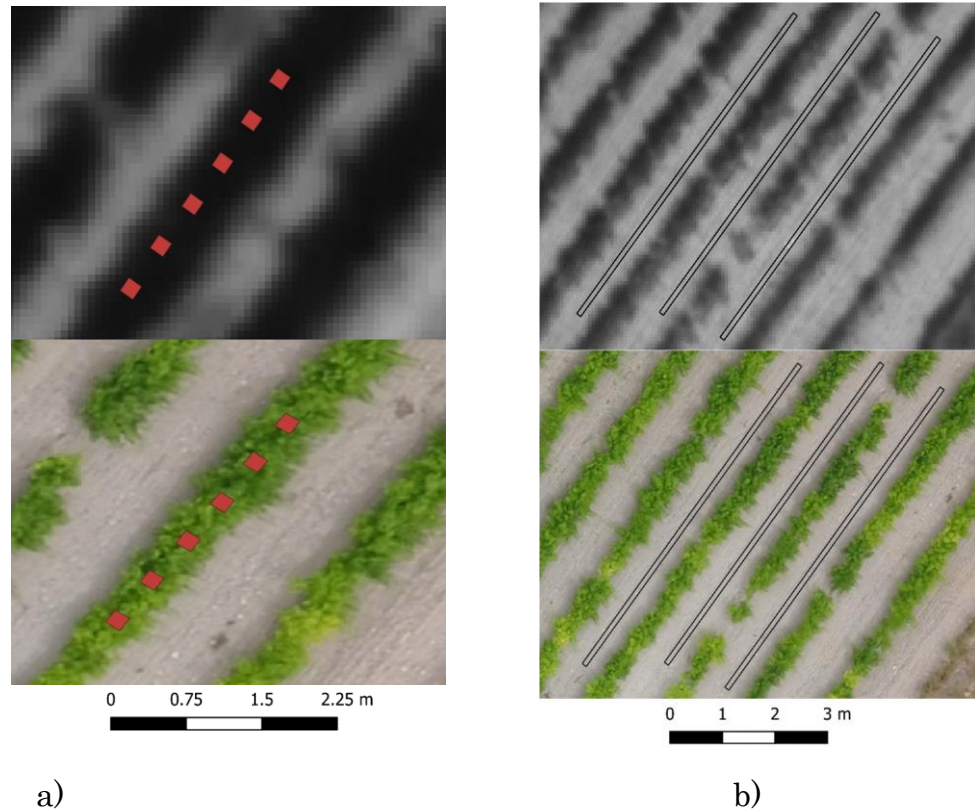


Figura 3.3.5. Detalle de imagen multispectral con la ubicación del dosel experimental de enredadera (a) y suelo (b) en una de las parcelas de suelo de estudio (C1).

Cerca de las viñas experimentales de ambos suelos (C1 y C2) se delimitaron tres rectángulos de  $0.19 \times 15$  m de suelo (Figura 3.3.5b) para C1 y otros tres rectángulos para C2. Con la información de los píxeles de suelo se pretende observar información diferenciada de ambos tipos de suelo que permitan describir mejor las características de ambos. El número total de píxeles por suelo fue de 530 píxeles por tipo de suelo para el sensor multispectral y 350 píxeles por tipo de suelo para el sensor térmico.

### Índices de Vegetación

En este estudio se emplearon diversos índices vegetativos (IVs) como herramienta para evaluar el desarrollo de la vid. Para calcular estos índices, se emplearán fórmulas específicas que consideran la reflectancia de la vegetación en diferentes bandas espectrales. La Tabla 3.3.4 resumen los IVs seleccionados.

Tabla 3.3.4. Índices de vegetación calculadas a partir de las bandas multiespectrales del sensor a bordo del UAS.

Índice	Ecuación	Referencia
NDVI	$(\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red})$	Rouse et al, 1974
GNDVI	$(\text{NIR} \times \text{Green}) / (\text{NIR} + \text{Green})$	Gitelson et a 1996
RVI	$\text{NIR} / \text{Red}$	Jordan, 1969
NDRE	$(\text{NIR} - \text{RedEdge}) / (\text{NIR} + \text{RedEdge})$	Tucker, 1979
OSAVI	$(\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red} + 0.16)$	Rondeaux et al, 1996

Los índices descritos anteriormente se utilizaron en las cepas, para el suelo se seleccionaron tres índices: NDVI, GNDVI y RVI

## 3.4 Ensayo 2: Caracterización del estado hídrico de las plantas

### 3.4.1 Localización y descripción de las viñas del Ensayo 2

Para este estudio se seleccionó la parcela 11 (Figura 3.1.1) con una superficie de 6ha. 5 tratamientos de riego se establecieron a lo largo de un línea. Cada tratamiento estaba formado por 6 cepas con un marco de plantación de 2.60x1.10m (Figura 3.4.1). En total se estudiaron 30 cepas.

Se dejaron un par de cepas al principio y final de cada tratamiento para que hiciera efecto borde.




Figura 3.4.1. Imagen izquierda: Localización de la parcela 11 de estudio. Imagen derecha: Detalle de la localización de los cinco tratamientos de riego.

#### Descripción de los tratamientos de riego

La parcela se regaba de forma uniforme. El riego se programó siguiendo las prácticas estándar seguidas por las Bodegas Casa del Valle, es decir, con intervalos de tiempo limitados.

El ensayo de riego se diseñó en base a cinco tratamientos de riego. La Tabla 3.4.1 describe los diferentes tratamientos de riego. El riego se aplicó desde el 17/05/2021 hasta el 27/08/2021 y desde el 23/06/2022 hasta el 01/09/2022. El año 2022 tuvo lugar reducciones del 40 y 49% en riego y lluvia + riego, respectivamente, en comparación con 2021, debido a la baja disponibilidad de agua durante este año. En ambos años, el agua proporcionada por el riego fue insuficiente para cubrir las altas demandas evaporativas, y se utilizó riego deficitario.

La Tabla 3.4.2 describe las horas y las dosis de riego que recibieron los diferentes tratamientos para cada mes y cada año de estudio. El número de goteros se ajustó para cada tratamiento con el fin de lograr diferentes dosis de riego. Los goteros son de 2 l h<sup>-1</sup>. Los tratamientos de riego se describen en la Tabla 3.4.1.

Tabla 3.4.1. Descripción de los cinco tratamientos de riego durante dos años del estudio en el viñedo experimental (Toledo, España).

Tratamiento	Nº goteros/planta	Sistema	Dosis 2021 (mm/año)	Dosis 2022 (mm/año)
T100	4	Superficie	428.0	258.7
T50	2	Superficie	214.0	129.4
T25	1	Superficie	107.0	64.7
T0	Ninguno	Superficie	secano	secano
T25-S	1	Subterráneo	107.0	64.7

Tabla 3.4.2. Descripción de las horas y dosis de riego de los diferentes tratamientos durante los dos años de estudio (2021 y 2022).

Parcela 11	2021						2022					
	Horas de riego	Dosis de riego (mm)					Horas de riego	Dosis de riego (mm)				
		T100	T50	T25	T0	T25-S		T100	T50	T25	T0	T25-S
Mayo	8	22.38	11.19	5.59	-	5.59					-	
Junio	34	95.1	47.55	23.78		23.78	8.5	23.78	11.89	5.94		5.94
Julio	60	167.83	83.92	41.96		41.96	26	72.73	36.36	18.18		18.18
Agosto	51	142.66	71.33	35.66		35.66	58	162.24	81.12	40.56		40.56
Total	153	427.97	213.99	106.99			92.5	258.74	129.37	64.69		64.69

### 3.4.2 Parámetros evaluados

#### 3.4.2.1 Propiedades físicas y químicas del suelo

El procedimiento para analizar las propiedades físicas y químicas del suelo del ensayo 2 se han descrito en el Ensayo 1, apartado 3.3.2.2.

#### 3.4.2.2 Propiedades fisiológicas y agronómicas de las cepas

Comenzando la temporada de riego, se tomaron medidas de espaldera y SA. El procedimiento se describe en el ensayo 1 apartado 3.3.2.3.

Parámetros fisiológicos como el potencial hídrico del tronco (PHT), el contenido de clorofila (Chl) y la conductancia estomática (gs), se midieron a las 9:00 y 12:00 horas solares en 9 días específicos a lo largo de las dos temporadas de estudio (25/06/2021, 05/07/2021, 20/07/2021, 30/07/2021, 18/08/2021, 30/06/2022, 15/07/2022, 05/08/2022 y 12/08/2022). El PHT se evaluó en hojas maduras, sanas y sombreadas, encerradas durante 1 hora en bolsas de papel de aluminio para alcanzar el equilibrio del estado hídrico entre la hoja y el tallo. El PHT se midió utilizando una cámara de presión Scholander (Soil Moisture Equipment Corp., Santa Bárbara, CA, EE. UU.).

La Chl se midió simultáneamente en tres hojas por cada cepa experimental utilizando un instrumento Apogee MC-100 (Apogee Instruments, Inc., Logan, UT, EE. UU.) en los mismos días y horas que la evaluación del PHT.

La conductancia estomática de las hojas ( $\text{mmol m}^{-2}\text{s}^{-1}$ ) se midió con un sistema portátil de intercambio de gases CIRAS2 (PP Systems, Hitchin, Hertfordshire, Reino Unido). La conductancia estomática de la hoja medida de esta manera se denominará gs.

El PHT, gs y la clorofila se midieron en seis cepas por cada tratamiento de riego. Todas las mediciones se realizaron simultáneamente con la adquisición de imágenes. El procedimiento se describe en el Ensayo 1 apartado 3.3.2.3.

Durante las dos campañas de riego se tomaron muestras de bayas para hacer un seguimiento de maduración, se hicieron 3 muestreos cada año (20/07/2021, 30/07/2021, 19/08/2021, 28/07/2022, 08/08/2022, 12/08/2022). En las cepas a los lados de cada tratamiento se tomaron 2 muestras representativas de 100 bayas cada una (no de las cepas de estudio). Al igual que con las bayas de vendimia, se pesaron y procesaron para determinar los azúcares ( $^{\circ}\text{Brix}$ ), pH y acidez. El procedimiento se describe en el ensayo 1 apartado 3.3.2.3.

### 3.4.2.3. Sensores térmicos

Se realizaron un total de ocho campañas de vuelo de UAS en la zona de estudio del viñedo durante diferentes condiciones climáticas en 2021 y 2022 a las 9:00 y 12:00 horas solares.

El déficit de presión de vapor, DPV (kPa), se calcula a partir de la temperatura del aire dentro del dosel ( $T_a$  seto) y la humedad relativa, HR (%). Estos parámetros fueron obtenidos mediante la estación meteorológica portátil ubicado dentro de las parcelas experimentales (Figura 3.1.2)

Las cepas experimentales fueron identificadas en la imagen utilizando el software QGIS 3.4 (QGIS, Free Software Foundation, Boston, MA, EE. UU). Cada viña del dosel fue delimitada, y se extrajeron 30 regiones de interés o polígonos (una por cepa) de 0.30 x 0.30 m, evitando sombras y píxeles de suelo. El número de píxeles obtenidos con la cámara térmica fue de 5 píxeles por viña. La altísima resolución espacial permitió discriminar entre hojas y suelo y seleccionar píxeles que contenían hojas iluminadas por el sol.

La adquisición de imágenes térmicas y las correcciones geométricas, radiométricas y atmosféricas se procesaron siguiendo la metodología de Wang et al. (2019) para obtener la temperatura de la superficie terrestre eliminando los efectos atmosféricos mediante una corrección atmosférica de un solo canal. A continuación, se describen de forma esquemática los pasos para su corrección:

### 3.4.2.4. Corrección imágenes térmicas

Para obtener la temperatura real del dosel ( $T_c$ ), que se utilizará posteriormente para el cálculo de los índices térmicos, es necesario realizar la corrección atmosférica para eliminar la radiación de onda larga reflejada por la superficie terrestre y la radiación de onda larga ascendente hacia el sensor procedente de la atmósfera.

Tras el vuelo del dron y una vez procesada las fotos del sensor a bordo del UAS, se obtiene una ortofoto denominada  $T_{S^*}$  (representa la imagen con valores de temperatura de brillo del sensor en °C antes de corregir). Para su corrección primero transformamos los valores de la cámara térmica en radiación aplicando la ley de Stefan-Boltzmann.

$$LW_{sensor} = \sigma * (T_{S^*} + 273)^4 \quad (4)$$

$LW_{sensor}$  corresponde a la radiación de onda larga de la imagen térmica en ( $W \cdot m^{-2}$ ). Para usar esta fórmula es necesario transformar la temperatura de °C de la imagen térmica a Kelvin (K).

Una vez que tenemos  $LW_{sensor}$  debemos despejar  $T_s$ , que correspondería a la temperatura del sensor corregida, de la siguiente ecuación:

$$LW_{sensor} = \varepsilon_s \sigma T_s^4 + (1 - \varepsilon_s) LW_{in} + LW_{atm} \quad (5)$$

Donde

$\sigma$  es la constante de Stefan-Boltzmann ( $5,67 \times 10^{-8} W \cdot m^{-2} \cdot K^{-4}$ ).

La emisividad de la superficie ( $\varepsilon_s$ ) se calcula en función de la relación con el NDVI (Van de Griend y M. Owe, 1993). Esta emisividad se calcula a través de la siguiente ecuación:

$$\varepsilon_s = 1.0094 + 0.047 \ln * (NDVI) \quad (6)$$

$LW_{in}$  es la radiación de onda larga entrante o *Longwave Incoming* ( $W \cdot m^{-2}$ ), dicho de otra forma, es la radiación que llega desde la atmosfera hacia la superficie. Para calcular este parámetro consideramos la siguiente ecuación:

$$LW_{in} = \varepsilon_a \sigma T_{a_{seto}}^4 \quad (7)$$

$T_{a_{seto}}$  es la temperatura del aire dentro del seto (°K). En este estudio se tiene en cuenta la temperatura del aire medida con la estación meteorológica portátil que se instala dentro del seto (Figura 3.1.2).

$\varepsilon_a$  es la emisividad atmosférica, depende de la radiación de gases, especialmente vapor de agua (el más variable). Para estimar la emisividad del aire ( $\varepsilon_a$ ) que alcanza la superficie desde la atmósfera (aerosoles, gases, etc.) que emiten, existen varias ecuaciones. En este estudio se decide usar la fórmula propuesta por Prata et al., 1998 (ecuación 9) que es una función de la temperatura del aire y el contenido de vapor de agua de la atmósfera:

$$\varepsilon_a = 1 - (1 + w) \exp^{-\sqrt{(1.2 + 3.0 w)}} \quad (8)$$

Donde  $w$  se describe como:

$$w = \left( \frac{46.5}{T_{a_{seto}} + 273.15} \right) * ea \quad (9)$$

$ea$  es presión de vapor de agua actual (calculada utilizando la estación meteorológica portátil en hPa).

Las condiciones atmosféricas locales, como la temperatura del aire, la humedad relativa y la presión barométrica, se midieron en el momento del vuelo con una estación meteorológica portátil.

El último parámetro por describir de la Ecuación 5 es  $LW_{atm}$ , la radiación de onda larga ascendente desde la atmósfera hacia el sensor ( $W \cdot m^{-2}$ ). Debido a la baja altitud de vuelo y a la simplicidad, este estudio desestimó la influencia de  $LW_{atm}$ , como otros estudios de UAS (por ejemplo, Hoffmann et al., 2016; Ortega-Farías et al., 2016; Brenner et al., 2017).

Quedaría por tanto despejar  $T_s$  a la que denominamos temperatura corregida del sensor en K. Resolviendo la ecuación 5 tendríamos:

$$T_s = \frac{LW_{sensor} - (1 - \epsilon_s) * LW_{in}}{\epsilon_s \sigma^{0.25}} \quad (10)$$

$T_s$  estaría en °K por lo que le sumamos 273.15 para transformarlo en grados centígrados (°C)

Una vez que tenemos la imagen corregida podemos extraer los valores de los píxeles correspondientes a cada cepa de estudio y calcular los correspondientes índices térmicos. A esa temperatura del cultivo/dosel corregido y en grados centígrados le denominaremos  $T_C$

#### 3.4.2.5 Índice de estrés hídrico de los cultivos.

En este ensayo se toma como punto de referencia la forma simplificada  $T_C - T_a$  como indicador del estado hídrico de las plantas. A partir de esta referencia se proponen tres métodos para calcular el Índice de Estrés Hídrico del Cultivo (CWSI, por sus siglas en inglés).

La expresión más común de este indicador es:

$$CWSI = \frac{T_C - T_{humedo}}{T_{seco} - T_{humedo}} \quad (11)$$

Donde  $T_C$  es temperatura del cultivo,  $T_{humedo}$  temperatura de referencia de un cultivo bien hidratado y  $T_{seco}$  temperatura de referencia de un cultivo donde los estomas están completamente cerrados.

Como resultado de esta normalización, el índice varía de 0 (cultivos bien hidratados) a 1 (cultivos completamente estresados).

A continuación, se definirán las metodologías para el cálculo del *CWSI*. Los índices se han calculado para todos los días de vuelo y las dos horas (9:00 y 12:00) definidas para los dos años de estudio (2021 y 2022).

1. Método de referencias artificiales húmedas (RAH):

Este método es el más sencillo para calcular el *CWSI*, pero requiere mediciones *in situ*.

En nuestro estudio utilizamos la referencia húmeda ( $T_{humedo}$ ) descrita en el apartado 3.1.2, como detallan Cohen et al. (2005). Esta superficie es una superficie permanentemente húmeda con propiedades físicas reproducibles que simulan una planta constantemente transpirando. La estación se situaba en el lineo del ensayo de riego (Figura 3.4.2) dentro del seto.

$T_{seco}$  se estimó añadiendo 5°C a la temperatura de bulbo seco (Irmak et al. 2000).




Figura 3.4.2. Ubicación de la estación meteorológica portátil

El índice de estrés hídrico del cultivo *CWSI* se calculó:

$$CWSI = \frac{T_C - T_{humedo}}{T_{seco+5} - T_{humedo}} \quad (12)$$

donde  $T_c$  es la temperatura real del dosel obtenida de la imagen térmica corregida.  $T_{humedo}$  se obtuvo de las lecturas del termopar cada minuto, usando la temperatura media para cada hora.

## 2. Método Bellvert:

La forma empírica de estimar el CWSI propuesta por Bellvert et al (2014) se basa en estimar las temperaturas de referencia o líneas base  $T_{humedo}$  y  $T_{seco}$  en función del DPV. Este estudio tiene en cuenta la influencia de la variedad y el estado fenológico. Bellvert et al. (2014) considera 4 variedades de vid y diferentes etapas fenológicas dentro de cada variedad para calcular las líneas base de referencia  $T_{humedo}$  y  $T_{seco}$ . Para nuestro estudio tomaremos como referencia las del cultivar Tempranillo, que tiene un comportamiento anisohídrico similar al cultivar Merlot (Williams y Baeza 2007). En cuanto al estado fenológico se seleccionaron las ecuaciones en la etapa II-III (Etapa II: del cuajado al envero; Etapa III: del envero a la cosecha) que es el periodo en el que se desarrolló el ensayo.

$$T_{humedo} = -1.780DPV + 1.253 \quad (13)$$

$$T_{seco} = 0.446DPV + 5.317 \quad (14)$$

$T_c$  y  $T_a$  (C°) y DPV (kPa).

Una vez obtenemos las temperaturas de referencia de las líneas base calculamos el CWSI usando la Ecuación 12.

## 3. Método de balance de energía de Jackson:

En esta metodología, para estimar  $T_{humedo}$  y  $T_{seco}$  se utiliza el balance de energía y las ecuaciones de Penman-Monteith. Es una actualización de la metodología presentada por Jackson et al. (1981a, 1982), considera el DPV, velocidad del viento, diferencias en la radiación neta y resistencias de los cultivos. Este enfoque no requiere superficies de referencia y se basa en modelos físicos para estimar todas las variables de entrada del balance de energía y las ecuaciones de transferencia de masa.

La forma más común de representar el balance de energía superficie es:

$$R_n = H + \lambda E + G \quad (15)$$

donde  $R_n$  es la radiación neta ( $Wm^{-2}$ ),  $H$  el flujo de calor sensible al aire ( $Wm^{-2}$ ) y  $\lambda E$  es el flujo de calor latente ( $Wm^{-2}$ ).

$G$  o flujo de calor que se almacena en el suelo por conducción, se puede considerar insignificante a escala diaria (Fisher et al. 2008; Purdy et al. 2016).

El modelo parte del supuesto de que la temperatura de vegetación pura del cultivo ( $T_c$ ) se obtiene de imágenes térmicas de alta resolución.

Suponiendo que la energía almacenada en la cubierta vegetal y la energía utilizada en los procesos fotosintéticos son insignificantes, es decir, no hay  $G$  cuando consideramos solo la vegetación, el balance de energía en la vegetación del dosel se escribe como:

$$R_n = H_c + \lambda E_c \quad (16)$$

Estos parámetros son los mismos descritos en la Ecuación 15, incorporando el subíndice  $c$  que indica que sólo se consideran los flujos de energía de la parte vegetativa del dosel.

Los términos  $H_c$  y  $\lambda E_c$  se pueden expresar como:

$$H_c = \rho C_p + \frac{(T_c - T_{a\_seto})}{r_a} \quad (17)$$

$$\lambda E_c = \frac{\rho C_p (e_c^* - e_a)}{\gamma r_a} \quad (18)$$

donde  $\rho$  es la densidad del aire ( $\text{kg m}^{-3}$ );  $C_p$  el calor específico del aire ( $\text{J kg}^{-1} \text{ }^\circ\text{C}$ );  $T_c$  y  $T_{a\_seto}$  son respectivamente la temperatura del cultivo/dosel ( $^\circ\text{C}$ ) y del aire dentro del seto ( $^\circ\text{C}$ ); y  $r_a$  es la resistencia aerodinámica ( $\text{s m}^{-1}$ );  $e_c^*$  es la presión de vapor saturado a la temperatura de la cubierta vegetal ( $\text{Pa}$ );  $e_a$  es la presión de vapor real del aire ( $\text{Pa}$ );  $\gamma$  la constante psicrométrica ( $\text{Pa }^\circ\text{C}^{-1}$ );

Combinando las ecuaciones (16)(17) y (18) se puede calcular la resistencia del cultivo/dosel ( $r_c$ ) ( $\text{s m}^{-1}$ ) al transporte de vapor como:

$$r_c = \frac{r_a (e_c^* - e_a)}{\gamma \left( \frac{r_a R_n \text{ diario}}{\rho C_p} - (T_c - T_{a\_seto}) \right)} - r_a \quad (19)$$

Para resolver esta ecuación,  $T_{a\_seto}$ ,  $e_a$ ,  $e_c^*$  se obtienen de la estación meteorológica portátil, mientras que  $\rho C_p$  y  $\gamma$  se calcula siguiendo la metodología propuesta por Wang et al (2019). La  $T_c$  se obtiene de los sensores infrarrojos térmicos obtenidos a partir de imágenes térmicas corregidas del UAS. La  $R_n$  de la ecuación 15 es la

misma  $R_n$  de la ecuación 18 ( $Rn_{diario}$ ), la diferencia radica en la disponibilidad de datos de radiación que se disponga. En el próximo epígrafe se describirá con detalle cómo se obtiene  $Rn_{diario}$ .

La resistencia aerodinámica ( $r_a$ ) se calculó a partir de la siguiente ecuación:

$$r_a = \frac{LN\left(\frac{SH-Z*0.67}{Z*0.123}\right)*Ln\frac{SH-Z*0.67}{Z*0.0123}}{K^2*U} \quad (20)$$

A diferencia de los parámetros anteriores en los que usábamos los valores obtenidos de la estación meteorológica portátil, para calcular  $r_a$  tomamos valores de la estación meteorológica de Magán.

Donde  $U$  es la velocidad del viento ( $ms^{-1}$ ) (Allen et al., 1994), y  $SH$  y  $K$  son, respectivamente, la altura de referencia del sensor (a 2 metros es la media de altura en la que se encuentra el sensor de velocidad de viento de las estaciones meteorológicas) y la constante de Von Karman (0,4) respectivamente.  $Z * 0.67$ ,  $Z * 0.123$  y  $Z * 0.0123$  son la altura de desplazamiento cero (m), el momento de longitud de rugosidad (m) y la longitud de rugosidad para el intercambio de calor sensible (m), respectivamente (Maes y Steppe 2012).

Una vez hayamos calculado  $r_a$  solos nos quedaría determinar  $Rn_{diario}$  para poder calcular la resistencia del cultivo  $r_c$  de la ecuación 18.

Sin embargo, el cálculo de este parámetro requiere una serie de estimaciones necesarias ya que la radiación fluctúa a lo largo del día. Los datos de radiación de la estación de Magán son acumulados del día. Para poder determinar la radiación en el momento del vuelo del dron habrá que hacer una serie de cálculos previos.

### Estimación de la $R_n$

Para obtener el valor de  $Rn_{diario}$  es necesario utilizar el balance de radiación sobre el dosel estimada usando el modelo definido por Moyano et al (2018).

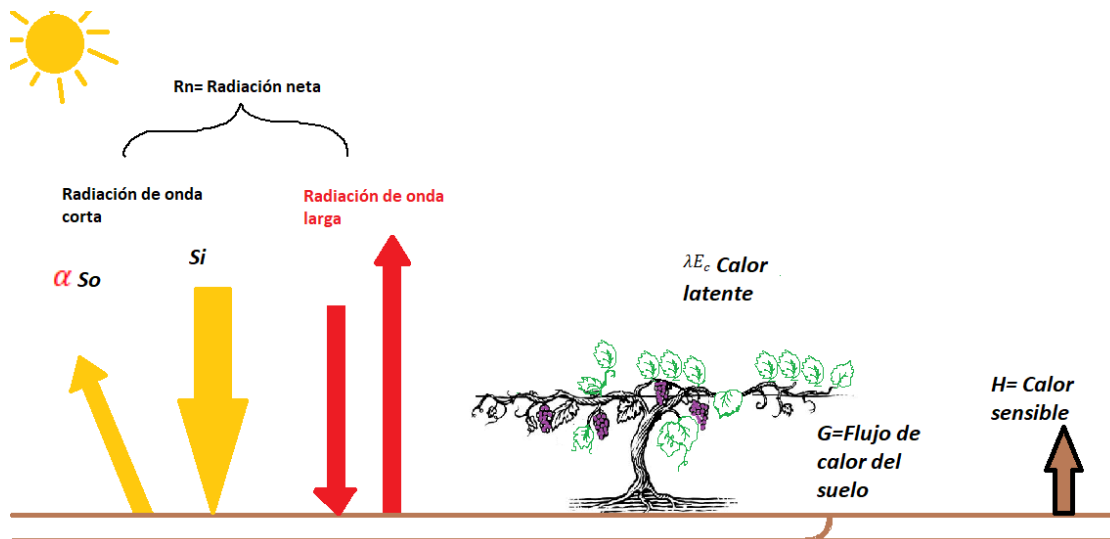


Figura 3.4.3 Representación de los flujos de energía.

En la Figura 3.4.3 se observan los parámetros que componen a la radiación neta  $R_n$ . Estos parámetros son la radiación de onda corta *shortwave* (SW) y radiación de onda larga o *longwave* (LW).

$$R_n = SW + LW \quad (21)$$

Shorwave o radiación de onda corta a su vez se compone de dos flujos de radiación:

$$SW = S_i + S_o \quad (22)$$

$$S_o = -\alpha * S_i \quad (23)$$

$$SW = S_i (1 - \alpha) \quad (24)$$

Donde  $SW$  es la radiación neta de onda corta en la superficie ( $\text{W}/\text{m}^2$ ),

$S_i$  es la radiación solar entrante (incoming) a la superficie ( $\text{W}/\text{m}^2$ ),

$S_o$  es la radiación solar saliente (reflejada, outgoing) en la superficie ( $\text{W}/\text{m}^2$ ).

Longwave o radiación de onda larga también tiene dos componentes

$$LW = LW_{in} + LW_{out} \quad (25)$$

$$LW_{in} = \varepsilon_a \sigma T_a^4 \quad (26)$$

$$LW_{out} = -\varepsilon_s \sigma T_s^4 + (1 - \varepsilon_s) LW_{in} \quad (27)$$

$LW_{in}$  es radiación entrante de onda larga (emitida desde la atmósfera y llegar a la superficie) ( $\text{W}/\text{m}^2$ ).

$LW_{out}$  es la radiación de onda larga emitida (desde la superficie a la atmósfera) ( $W/m^2$ ).

$LW_{out}$  es la fórmula que aplicamos para hacer las correcciones de las imágenes térmicas, (ver Ecuación 5). En ese caso  $LW_{out}$  es  $LW_{sensor}$ , ya que es la radiación emitida por la superficie y capturada por el sensor.

Sin embargo, necesitamos calcular  $Rn_{diario}$  y para ello necesitamos obtener los valores instantáneos de los dos componentes de la radiación ( $SW + LW$ ), es decir  $LW_{inst} + SW_{inst}$

Para entender mejor los inputs con los que cuenta el modelo, todas las ecuaciones y variables utilizadas para obtener la  $Rn_{diario}$  se detallan en la Tabla 3.4.2

Tabla 3.4.2. Ecuaciones y variables utilizadas para estimar  $Rn_{diario}$ .  $Si$  (MJ/m<sup>2</sup>/día) radiación de onda corta entrante obtenida de la estación de Magán.  $J$  factor de conversión Día-inst utilizado cuando solo una observación durante el día de radiación neta se escala de instantánea a diaria. Duración del día  $N$  (h), tiempo  $t$  de desfase entre la hora de salida del sol de NOAA (Administración Nacional Oceánica y Atmosférica) y la hora de vuelo del UAS (h).  $\epsilon_a$  emisividad del aire,  $\epsilon_s$  emisividad de la superficie del cultivo/dosel,  $\sigma$  constante de Stefan-Boltzmann ( $5.67 \times 10^{-8} \text{ W m}^{-2} \cdot \text{K}^{-4}$ ),  $T_c$  temperatura de la superficie del cultivo/dosel (K),  $T_a$  temperatura del aire (K).

Variable Description	Ecuaciones
Radiación de onda larga entrante ( $LW_{in}$ )	$LW_{in} = \epsilon_a \sigma T_a^4$
Radiación de onda larga emitida ( $LW_{out}$ )	$LW_{out} = \epsilon_s \sigma T_c^4$
Radiación de onda larga instantánea $LW_{inst}$	$LW_{ins} = LW_{in} - LW_{out}$
<b>Radiación de onda corta diaria: <math>SW</math></b>	$SW = Si (1 - \alpha)$
Albedo: $\alpha$	$\alpha = 0.28 - 0.14e^{-6.08/SR^2}$
Índice de Vegetación de Relación Simple: SR	$SR = (1+NDVI)/(1-NDVI)$
<b>Radiación de onda corta instantánea: <math>SW_{ins}</math></b>	$SW_{ins} = \frac{RS}{J} \cdot 24/N$
Factor de conversión Día-instantáneo: $J$	$J = \frac{Rn,d}{Rn,i} = \frac{2N}{\pi \sin(\frac{\pi t}{N}) * 24}$
Radiación neta instantánea: $Rn_{inst}$	$Rn_{inst} = LW_{ins} + SW_{ins}$
<b>Radiación Neta Diaria</b>	$Rn_{diario} = Rn_{inst} * J * \frac{N}{24}$

La  $LW_{ins}$  es la diferencia entre la radiación de onda larga entrante ( $LW_{in}$ ) y la saliente ( $LW_{out}$ ). Se requiere una conversión instantánea-diarria para obtener la  $Rn_{diario}$

$SW$  se calculó basándose en los datos de radiación solar local  $S_i$  de la estación Magán y el albedo superficial  $\alpha$ , calculado en función del índice de vegetación de relación simple (SR), que muestra que el albedo disminuye a medida que aumenta el verdor de la vegetación (GAO, 1995).

$SW_{ins}$  se calculó utilizando un factor de conversión,  $J$ , entre variables de radiación instantánea y diaria basado en el curso sinusoidal diurno de la radiación de onda corta y neta.

Finalmente obtenemos  $Rn_{diario}$  para poder calcular la  $r_c$ , uno de los parámetros necesarios para calcular el CWSI.

Se puede obtener una solución analítica para el CWSI una vez que se conocen  $r_c$  y la resistencia potencial del dosel para un cultivo sin estrés hídrico ( $r_{cp}$ ) (Jackson 1982a).

$$CWSI = 1 - \frac{E}{E_p} = \frac{\gamma \left(1 + \frac{r_c}{r_a}\right) - \gamma^*}{\Delta + \gamma \left(1 + \frac{r_c}{r_a}\right)} \quad (28)$$

donde  $\Delta$  es la pendiente de la relación temperatura presión de vapor de saturación y:

$$\gamma^* = \gamma \left(1 + r_{cp}/r_a\right) \quad (29)$$

Se han publicado estimaciones de  $r_{cp}$  para muchos cultivos; en nuestro estudio, obtuvimos un valor empírico de un sistema portátil de intercambio de gases CIRAS2.

### 3.5 Análisis de datos

Diferentes análisis estadísticos se llevaron a cabo para tratar la variedad de datos obtenidos en los dos ensayos.

De forma común se trataron los datos térmicos y multiespectrales mediante análisis de varianza (ANOVA) utilizando Infostat versión 1.5 (Universidad Nacional, Córdoba, Argentina). Las medias se separaron utilizando la prueba de LSD ( $<0.05$ ) para diferencias estadísticas.

Para el ensayo 1, se utilizó una prueba no paramétrica de Wilcoxon para evaluar las diferencias entre los datos fisiológicos y agronómicos medios, utilizando el software estadístico RStudio (RStudio Inc., Boston, MA, EE. UU.).

Para el Ensayo 2, se utilizaron coeficientes de determinación ( $R^2$ ) y matriz de correlación de Pearson para evaluar la relación entre los índices medios de teledetección fisiológica y térmica utilizando el software estadístico gratuito R Studio (RStudio Inc. Boston, Massachusetts, Estados Unidos). Los parámetros agronómicos se analizaron mediante análisis ANOVA utilizando el software Infostat.

## 4 Resultados

### 4.1 Clima

En la Figura 4.1.1 se observa la evolución de la temperatura media y las precipitaciones que ha tenido lugar los dos años de estudio, comparados con la media de la serie histórica de 20 años. Como se puede observar, la media de temperaturas es más alta en el año 2022 en comparación con el 2021. Se observa un aumento progresivo de la temperatura desde el mes de mayo hasta el mes de agosto de 2 °C, alcanzado su pico en el mes de julio con 3 °C con respecto a la media histórica. Por el contrario, la temperatura media del 2021 tuvo una tendencia similar a la media histórica.

La ETo el año 2022 fue 16 mm de media superior en los meses de mayo, junio y julio, en comparación con la serie histórica para estos meses. La ETo en 2022 ha sido un 9 % superior con respecto al 2021. El mes de julio ha sido el mes más caluroso, con una temperatura media de 27 °C y 30 °C en 2021 y 2022 respectivamente y una ETo de 226 y 250 mm en 2021 y 2022, respectivamente; lo que indica que el 2022 fue un año con alta demanda evaporativa.

En cuanto a las precipitaciones, ambos años tuvieron precipitaciones similares, siendo un 2 % más lluviosos en comparación con la serie histórica. En concreto, la primavera del año 2022 tuvo lugar unas precipitaciones de 155 mm, en comparación con el año 2021 que fueron de 85 mm. Considerando la serie histórica, las primaveras en esta zona son de alrededor de 119 mm, lo que hace de la primavera del 2022 especialmente lluviosa.

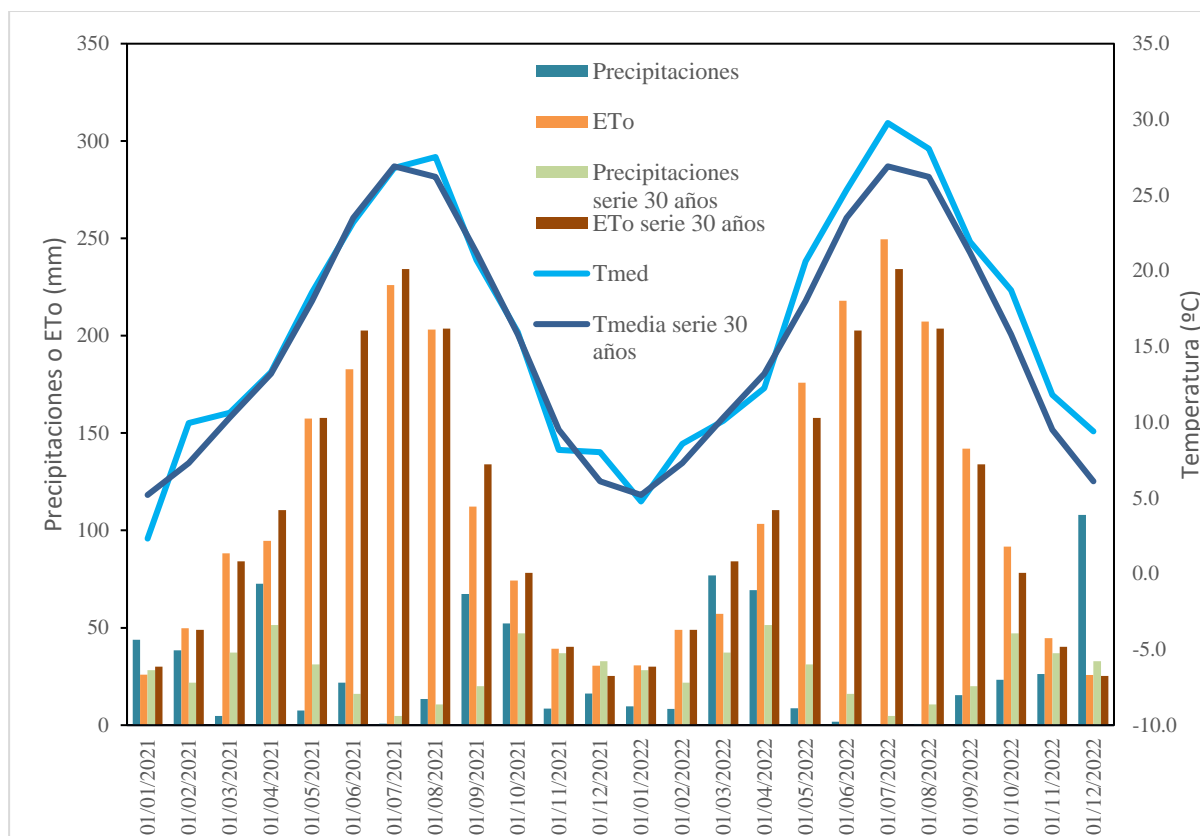


Figura 4.1.1. Evolución de las temperaturas, ETo y precipitaciones de los dos años de estudio en comparación con la serie de 30 años.

La Tabla 4.1.1 muestra la información climática de temperatura del aire ( $T_a$ ), humedad relativa y el déficit de presión de vapor (DPV) de la estación portátil dentro del dosel (Figura 3.1.2) los días en el que se obtuvieron las mediciones en campo y la adquisición de imágenes con el UAS.

Como era de esperar,  $T_a$  es menor a las 9:00 que a las 12:00, la humedad relativa disminuyó a medida que avanzaba el día, y el DPV es mayor a las 12:00 que a las 9:00. Al mismo tiempo, la humedad relativa en 2021 fue mayor que en 2022, presentando una diferencia en ambos momentos del día de alrededor del 4 %. En cuanto al DPV, se encontraron mayores diferencias entre los años a las 12:00 que a las 9:00. En ambos años, el DPV estaba alrededor de 3 kPa a las 9:00.

Sin embargo, se obtiene más información si cuantificamos las diferencias por fecha en cada año. Las tres primeras fechas en 2021 muestran una tendencia positiva en el aumento de  $T_a$  de +4.5 °C a +6.7 °C, disminuyendo en la última fecha a +2.1 °C. Por el contrario, en 2022, la primera fecha muestra un aumento de  $T_a$  de solo +2.1

°C, y el resto muestra alrededor de un aumento de +6.5 °C en Ta. Estas diferencias indican que las primeras y últimas fechas de cada año tuvieron condiciones diferentes.

Las diferencias en HR siguen el mismo patrón que las diferencias en Ta en 2021. Las tres primeras fechas muestran una tendencia positiva en la disminución de HR de -9.6 % a -15.4 %, disminuyendo en la última fecha a -5.1 %. Esto se repite en 2022. Las tres primeras fechas muestran una tendencia positiva en la disminución de HR de -4.5 % a -16.2 %, disminuyendo en la última fecha a -7.3 %.

Las diferencias en DPV en 2021 muestran el mismo patrón previamente descrito para las diferencias en Ta y HR. En el caso de 2022, las fechas intermedias muestran una diferencia de DPV de +2.4 KPa, siendo la primera y última fecha de +0.6 y +1.9 KPa, respectivamente

Tabla 4.1.1. Temperatura ( $T_a$ ), humedad relativa (HR) y déficit de presión de vapor (DPV) dentro del dosel los días de vuelo del UAS a las 9:00 y 12:00. Evapotranspiración de referencia diaria ( $E_{To}$ ) para cada fecha.

Dates	9:00			12:00			$E_{To}$ (mm/día)
	$T_a$ (°C)	HR (%)	DPV (kPa)	$T_a$ (°C)	HR (%)	DPV (kPa)	
25/06/2021	29.0	39.3	2.4	33.5	29.7	3.6	6.6
05/07/2021	29.8	39.7	2.5	35.0	29.0	4.0	8.2
20/07/2021	30.8	33.9	2.9	37.5	18.5	5.3	7.9
30/07/2021	32.0	15.9	4.0	34.1	10.8	4.8	9.1
<b>MEDIA 2021</b>	<b>30.4</b>	<b>32.2</b>	<b>3.0</b>	<b>35.0</b>	<b>22.0</b>	<b>4.4</b>	<b>7.9</b>
30/06/2022	27.6	27.6	2.7	30	23.1	3.3	7.0
15/07/2022	35.1	22.5	4.4	41.3	14.2	6.8	8.1
05/08/2022	31.2	34.4	3.0	37.9	18.2	5.4	7.3
12/08/2022	30.6	28.5	3.1	37.4	21.2	5.0	6.3
<b>MEDIA 2022</b>	<b>31.1</b>	<b>28.3</b>	<b>3.3</b>	<b>36.7</b>	<b>19.2</b>	<b>5.1</b>	<b>7.2</b>

## 4.2 Parámetros evaluados Ensayo 1: Caracterización del suelo

### 4.2.1 Prezonificación

En la zonificación preliminar se observaron siete tipos de suelo diferentes delimitados por el recuadro rojo (Figura 4.2.1) en la parcela de estudio. Las calicatas, junto con los sondeos realizados, dieron información sobre las características de suelo (Figura 4.2.2) a lo largo de la zona experimental, esta información permitió ajustar las líneas de zonificación. Desaparecen, por tanto, las líneas de prezonificación que indicaban 7 tipos de suelo. La información obtenida de dos calicatas de suelo a través de la observación y análisis de muestras de las diferentes capas de los perfiles se describen en los próximos apartados.



Figura 4.2.1. Detalle del mapa de suelos correspondiente a la prezonificación en el Ensayo 1. El rectángulo rojo indica la zona experimental, las ubicaciones de las dos calicatas de suelo (C1 y C2) se indican con puntos rojos.

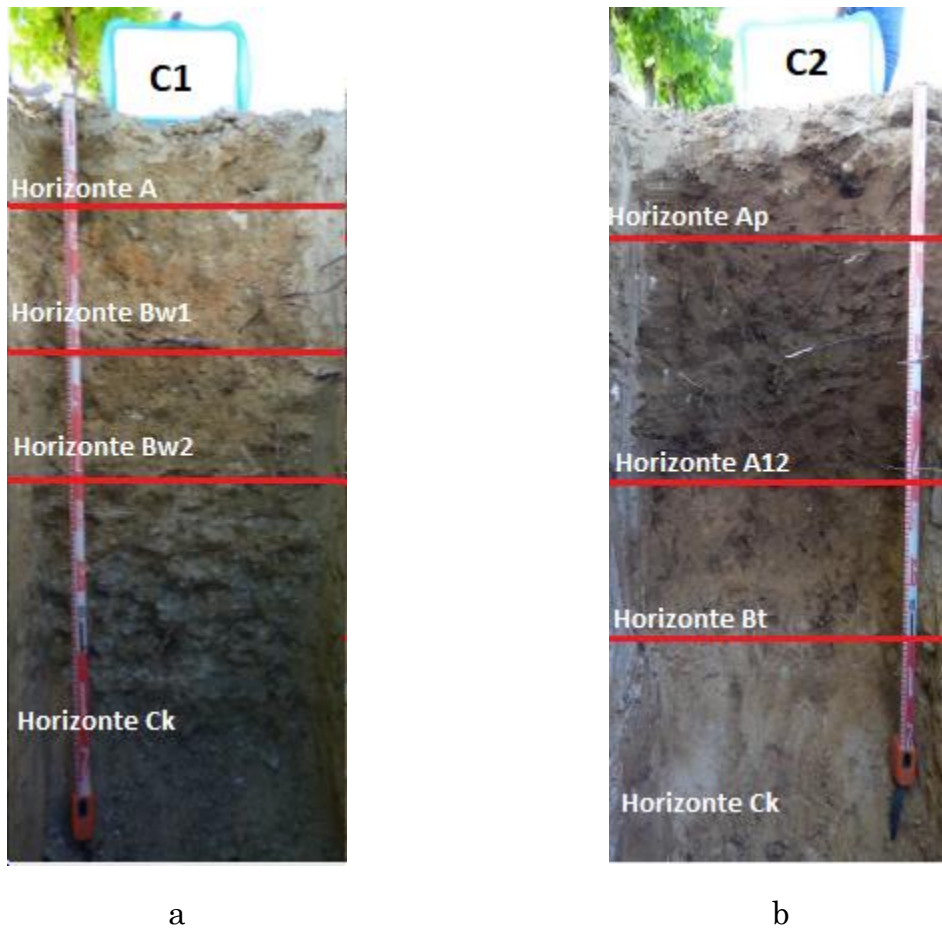


Figura 4.2.2. Imagen del perfil de los suelos de estudio con los horizontes (a) Suelo calicata 1 (C1); (b) Suelo calicata 2 (C2).

#### 4.2.2 Descripción de propiedades físicas y químicas de los horizontes. Clasificación

Las calicatas C1 y C2 mostraron diferencias en parámetros esenciales como la litología, geomorfología, orientación y pendiente (Tabla 4.2.1). La pendiente de ambos suelos era similar (5.6 %) y considerada empinada y ligeramente empinada por la FAO (2009). Desde un punto de vista topográfico, C2 se encontraba en una posición cóncava y C1 en una posición convexa. La cantidad de piedras en C1 fue mayor que en C2. El material parental en C1 era yesos detríticos y carbonatados. En C2, arenas y limos.

Tabla 4.2.1. Características macromorfológicas de los horizontes de las calicatas (C1 y C2).

Calicata	Altitud	Material parental	Geoforma	Posición	Orientación	Pendiente (%)	Pedregosidad
C1	569.3 m.s.n. m	Yesos detríticos y carbonatos	Relieve alomado	Ladera media (Convexidad- $\cap$ )	E (79, 8°)	5.6	10 %, calizas irreg., 2-12 cm Ø
C2	571.8 m.s.n. m	Arenas y limos	Glacis	Ladera baja (Concavidad - $\cup$ )	NE (41, 9°)	5.6	8 %, calizas irreg., 2-8 cm Ø

La observación visual de ambos perfiles de suelo (Figura 4.2.2) mostró diferencias en color, profundidad del horizonte y textura (Tabla 4.2.2). Los primeros horizontes en C1 eran marrón amarillento claro. El primer horizonte en C2 (Ap) mostró una matriz rojiza propia de suelos con propiedades férricas. El horizonte A12 fue más oscuro que Ap (entre marrón y negro).

El primer horizonte de C1 era un horizonte de diagnóstico óchrico (Ap). Los dos horizontes siguientes (Bw1 y Bw2) eran cámbico. En el suelo C2 se observó que los dos primeros horizontes eran óchricos (Ap y A12), y el tercer horizonte era cámbico. Ambos suelos presentaron un horizonte Ck considerado horizonte de diagnóstico calcáreo.

La textura observada en el perfil de ambos suelos difería sobre todo en el primer horizonte. El contenido de arcilla en C1 fue un 18% mayor y el de limo un 31% más alto en comparación con C2 (Tabla 4.2.2). La arena en C2 fue un 21% más alta que en C1. Los otros horizontes en ambos suelos tenían una textura franco-arenosa.

Tabla 4.2.2. Propiedades físicas de los horizontes de dos calicatas (C1 y C2).

Calicatas	Textura (%)			Clases Texturales	Horizonte de diagnóstico	Color	
	Arcilla	Limo	Arena				
C1	Ap (0-25cm)	20.7	30.9	48.4	Franco	óchrnico	2.5Y6/3 en húmedo y 2.5Y8/2 en seco
	Bw1 (25-50cm)	13.8	24.4	61.8	Franco arenosa	cámbico	7.5YR6/4 en húmedo y 7.5YR7/3 en seco
	Bw2 (50-70cm)	-	-	-	-	cámbico	5Y6/4 en húmedo y 5Y7/3 en seco
	Ck (70-130cm)	11.4	28.3	60.3	Franco arenosa	cálcico	5Y5/4 en húmedo y 5Y6/3 en seco
C2	Ap (0-25cm)	14.0	21.9	64.1	Franco arenosa	óchrnico	10YR4/4 en húmedo y 10YR5.5/4 en seco
	A12 (25-70cm)	14.2	16.3	69.5	Franco arenosa	óchrnico	10YR3.5/3 en húmedo y en 10YR5/4 seco
	Bt (70-95cm)	17.8	8.8	73.4	Franco arenosa	argílico	10YR6/6 en húmedo y 10YR7/3 en seco
	Ck (95-125cm)	-	-	-	Franco arenosa	cálcico	7.5YR6/8 en húmedo y 7.5YR7/4 en seco

El pH es básico en ambos suelos (>8.5) (Tabla 4.2.3). La conductividad eléctrica (CEe) del extracto saturado del suelo en C1 fue un 63% más alta que en C2. El horizonte Ck en C1 fue de 1.10 dS/m, clasificándolo como un horizonte salino. Los otros horizontes tenían valores de CE por debajo de 0.35 dS/m, calificándolos como no salinos. La presencia de un horizonte salino en C1 no afectó a la producción de la vid. El valor medio de materia orgánica (MO) en los horizontes fue de 0.95 y 0.79

(g/100 g) en C1 y C2, respectivamente. La media de caliza activa y capacidad de intercambio catiónico (CIC) en los horizontes de C1 fue un 42 y un 63% más alto que en C2. Los valores de CIC más altos en el primer horizonte de C1 estaban relacionados con un mayor porcentaje de arcilla, materia orgánica y nitrógeno.

Las concentraciones medias de nitrógeno fueron de 0.08 y 0.07 (g/100 g) para C1 y C2, respectivamente. El horizonte Ap en C1 tuvo un valor de N más alto (0.120 g/100 g).

Tabla 4.2.3. Propiedades químicas de los horizontes de dos calicatas (C1 y C2).

Calicatas	Caliza activa (g/100g)	CE. (ext. 1:5 dS/m)	CIC (cmol(+)/kg)	pH (ext. 1:2.5 H <sub>2</sub> O)	MO (g/100g)	N total (g/100g)	
C1	Ap (0-25cm)	11	0.21	13.4	8.6	2.15	0.120
	Bw1 (25-50cm)	13	0.19	5.3	8.8	0.54	0.044
	Bw2(50-70cm)	-	-	-	-	-	-
	Ck(70-130cm)	7	1.10	20.7	8.1	0.15	0.058
C2	Ap (0-25cm)	5	0.15	10.3	8.5	1.45	0.087
	A12 (25-70cm)	5	0.18	10.4	8.6	0.72	0.058
	Bt(70-95cm)	8	0.22	4.8	8.6	0.20	0.037
	Ck(95-125cm)	-	-	-	-	-	-

Las diferencias en textura y profundidad de los horizontes determinaron la CRA (Tabla 4.2.4). Los valores de CRA fueron de 175 y 122 mm en C1 y C2, respectivamente. La CRA de C1 fue un 43% mayor que la de C2. Además, la media de agua disponible (AD) de los horizontes fue del 12.3 y 7.3%, respectivamente. C1

mostró un 74% más de grava que C2. La densidad media y la profundidad del suelo en ambos horizontes fueron similares.

Las diferencias observadas debido a las propiedades físicas y químicas entre suelos influyeron en la CRA. Debido principalmente a la textura fina (arcilla y limo) y al mayor contenido en MO.

Tabla 4.2.4. Propiedades de los horizontes de las calicatas (C1 y C2): densidad aparente (Da), agua disponible (AD), grava y capacidad de retención de agua (CRA).

Hori zontes	Profundidad (m)	Da (t/m <sup>3</sup> )	AD		Grava (%vol)	CRA (mm)
			(% w/w)	(mm)		
C1						
Ap	0.25	1.42	8	28.4	27.8	20.5
Bw1	0.25	1.45	11	39.9	38.1	24.7
Bw2	0.15	1.45	13	37.7	19.5	30.4
Ck	0.50	1.45	17	123.3	19.5	99.2
Total	1.15					174.8
C2						
Ap	0.25	1.45	9	31.3	11.1	27.8
A12	0.45	1.45	8	52.2	9.9	47.0
Bt	0.26	1.45	6	22.6	3.2	21.9
Ck	0.30	1.45	6	26.1	3.2	25.3
Total	1.25					122.0

En general, son varias las propiedades que difieren entre las dos calicatas de estudio y que influyen en el desarrollo distintivo de las cepas evaluadas, sobre todo en lo referente a CRA.

La textura es una de las propiedades más relevantes para el desarrollo óptimo de las plantas. El porcentaje de arcilla era considerablemente mayor en C1 que en C2. La arena, sin embargo, era mayor en porcentaje en C2 comparado con C1. El

contenido en MO y el CIC eran mayores en C1. Esto permite que haya disponibilidad hídrica y nutricional para las plantas de este suelo C1 superiores a las que recibirían las cepas de C2.

### 4.2.3 Zonificación

Tras el análisis de las diferentes propiedades de suelo se pudo reducir la prezonificación inicial (Fig 4.2.1) a dos unidades cartográficas de suelo monotáficas. La Figura 4.2.3 muestra la parcela de la zona experimental con las líneas finales de zonificación. Los suelos en la "zona A", por tanto, C1, corresponden a Typic Calcixerepts familia franco-gruesa, gypsicas, méxicos, y superactivos y los suelos en la "B", en la que se encuentra C2, corresponden a Calcic Haploxeralfs familia franco-gruesa, mezclada, activa y méxica. área de la zona "A" fue de 7315 m<sup>2</sup> y el área de la zona "B" fue de 6535 m<sup>2</sup>.




Figura 4.2.3. Detalles del mapa de suelos correspondiente a la zonificación final de la zona experimental.

## 4.2.4 Características de las cepas

### 4.2.4.1. Características fisiológicas de las cepas

#### a) Fenología

La evolución fenológica fue diferente entre los años. La brotación ocurrió el 25/03/2021 y el 10/04/2022, la floración el 06/05/2021 y el 15/05/2022, envero el 30/07/2021 y el 21/07/2022, y maduración-cosecha el 20/08/2021 y el 16/08/2022

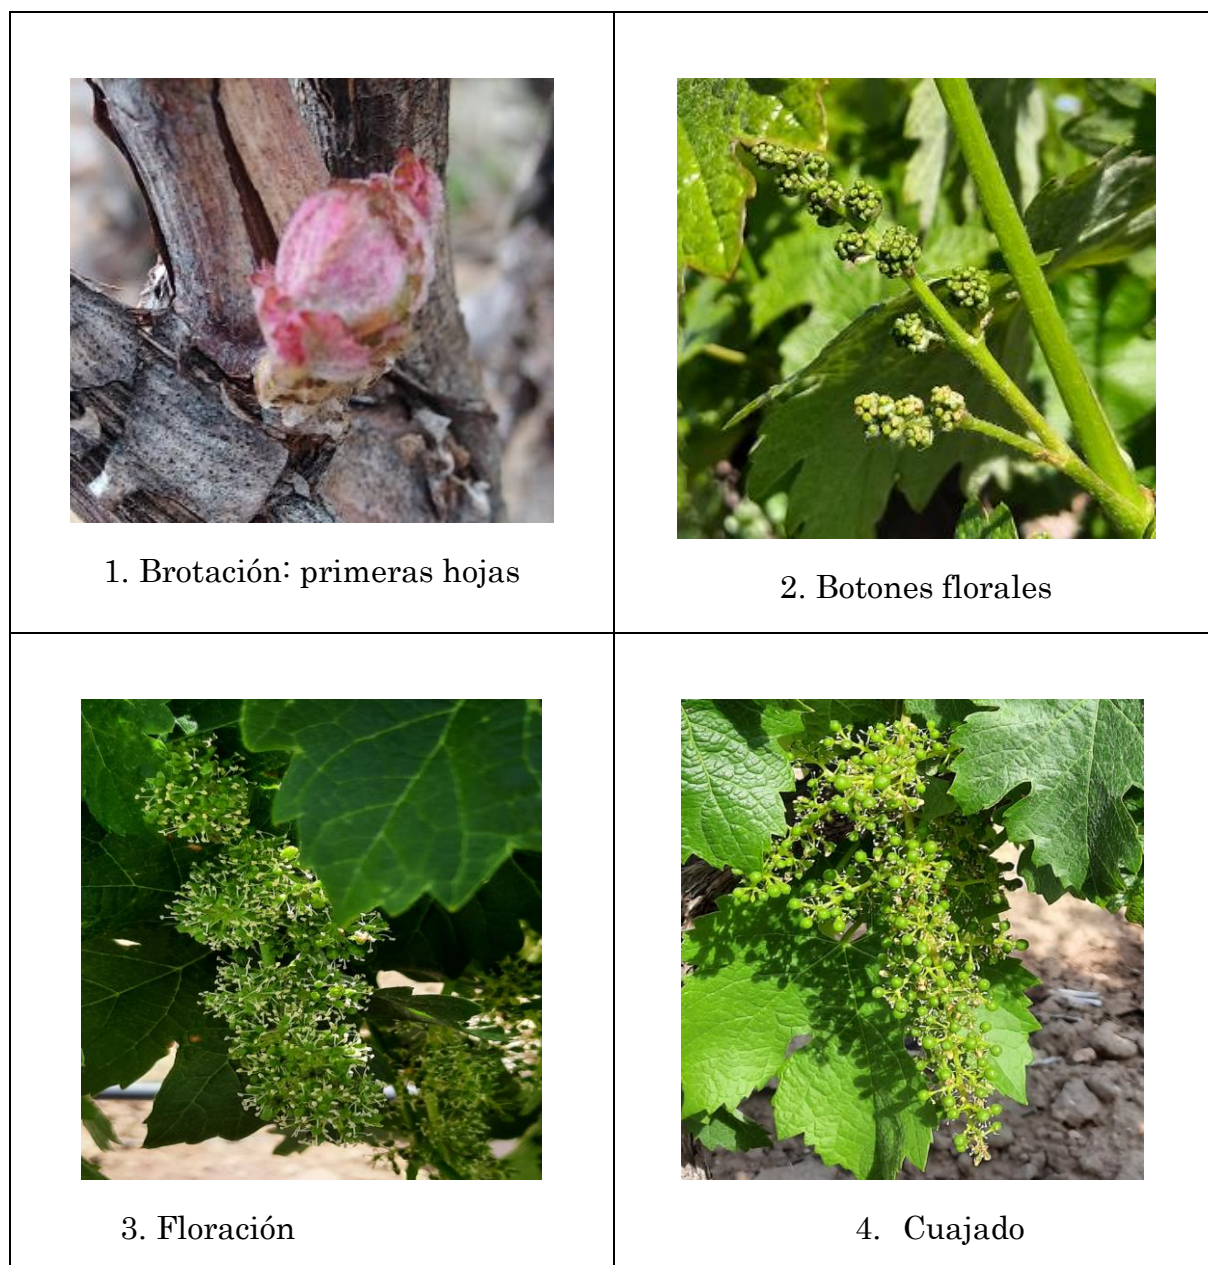


Figura 4.2.4. Estados fenológicos

b) Potencial hídrico del tronco (PHT)

Los valores de PHT a las 9:00 para las cepas de C1 y C2 fueron significativamente diferentes el 30/07/2021 y el 19/08/2021. En 2022, solo difirieron el 15/07/2022 (Tabla 4.2.5). El 30/07/2021, las cepas de C1 tenían valores un 34% más altos que las cepas de C2. Mientras tanto, el 15/07/2022, las cepas de C1 fueron un 23% más bajas que las cepas de C2. La media anual de las cepas de C1 mostró un valor más alto en 2021 (-0.67 MPa) en comparación con las cepas de C2 (-0.77 MPa). Así, en 2022, la media anual de las cepas de C1 fue más bajo que el de las cepas de C2 (-1.31 MPa y -1.25 MPa, respectivamente), pero no fue significativamente diferente. No se observaron diferencias significativas en las lecturas de PHT obtenidas a las 12:00 en 2021. Las medias anuales de las cepas de C1 y C2 fueron -0.99 y -1.04 MPa, respectivamente. En 2022, hubo diferencias significativas el primer día de la temporada de riego (30/06/2022), pero no en las otras mediciones o la media. En 2022, el PHT medio fue menor que en 2021 para ambas horas de medición.

Tabla 4.2.5. Potencial hídrico del tronco (PHT, MPa) medido a las 9:00 y 12:00 (hora solar) en los días del vuelo de UAS de las cepas de las dos calicatas (C1 y C2). Cada valor representa una media de seis cepas por tipo de suelo. DE, desviación estándar.

Fechas	(9:00)		(12:00)	
	C1	C2	C1	C2
25/06/2021	-0.53	-0.57 ns	-0.88	-0.84 ns
DE	0.07	0.13	0.07	0.08
05/07/2021	-0.86	-0.88 ns	-0.84	-0.94 ns
DE	0.23	0.22	0.10	0.14
20/07/2021	-0.59	-0.64 ns	-0.99	-0.98 ns
DE	0.03	0.03	0.03	0.02
30/07/2021	-0.65	-0.87 *	-1.01	-1.01 ns
DE	0.04	0.03	0.09	0.04
19/08/2021	-0.73	-0.90 *	-1.3	-1.5 ns
DE	0.03	0.04	0.19	0.03
<b>MEDIA 2021</b>	<b>-0.67</b>	<b>-0.77 *</b>	<b>-0.99</b>	<b>-1.04 ns</b>
30/06/2022	-1.07	-0.9 ns	-1.0	-1.2 *
DE	0.103	0.16	0.11	0.14
15/07/2022	-1.17	-0.92 *	-1.14	-1.10 ns
DE	0.16	0.09	0.14	0.14
05/08/2022	-1.42	-1.41 ns	-1.53	-1.47 ns
DE	0.13	0.12	0.10	0.23
12/08/2022	-1.47	-1.59 ns	-1.58	-1.68 ns
DE	0.09	0.11	0.18	0.21
<b>MEDIA 2022</b>	<b>-1.31</b>	<b>-1.25 ns</b>	<b>-1.43</b>	<b>-1.47 ns</b>

Niveles de significancia estadística: ns, no significativo; \*,  $p < 0.05$

c) Clorofila

En 2021, no se observaron diferencias significativas entre C1 y C2, sin embargo, en 2022 sí. Los valores de clorofila a las 12:00 aumentaron en todas las cepas en comparación con las mediciones a las 9:00. En ambas horas de medición, la clorofila fue menor en 2022 en comparación con 2021. A las 9:00 horas en 2021, se observaron diferencias en la clorofila entre las cepas el 18/08/2021, pero no en el valor medio (Tabla 4.2.6). Sin embargo, en 2022, los valores de las cepas de C2 fueron significativamente más altos que los valores de las cepas de C1 el 15/07/2022 y el 12/08/2022.

Tabla 4.2.6. Contenido de clorofila foliar (Chl, micromol/m<sup>2</sup>), medido a las 9:00 y 12:00 (hora solar) en los días del vuelo de UAS, de las cepas de las dos calicatas (C1 y C2) ubicados en el viñedo experimental (Toledo, España). Cada valor representa la media de seis cepas por tipo de suelo. DE: Desviación Estándar.

Fechas	(9:00)		(12:00)	
	C1	C2	C1	C2
25/06/2021	17.1	17.6 ns	14.90 ns	15.40 ns
DE	3.43	2.56	2.64	4.07
05/07/2021	16.1	19.9 ns	17.53	17.25 ns
DE	4.29	1.87	2.15	6.62
20/07/2021	17.6	20.0 ns	19.73	21.38 ns
DE	1.52	2.11	2.80	2.69
30/07/2021	17.9	19.3 ns	19.88	20.43 ns
DE	0.67	4.37	2.68	3.99
19/08/2021	16.2	20.5 *	21.00	20.80 ns
DE	1.96	2.75	2.89	3.02
<b>MEDIA 2021</b>	<b>18.63</b>	<b>19.08 ns</b>	<b>16.98</b>	<b>19.45 ns</b>
30/06/2022	13.29	15.64 ns	13.50	16.53 *
DE	1.71	2.75	1.12	1.39
15/07/2022	14.71	17.63 *	14.20	17.75 *
DE	1.02	1.32	1.26	1.20
05/08/2022	15.96	18.02 ns	16.47	18.46 ns
DE	1.78	1.95	1.56	1.12
12/08/2022	13.87	17.18 *	14.95	17.11ns
DE	1.16	3.05	1.51	2.65
<b>MEDIA 2022</b>	<b>14.76</b>	<b>17.30 *</b>	<b>15.03</b>	<b>17.83 *</b>

Niveles de significancia estadística: ns, no significativo,  $p < 0.05$

#### 4.2.4.2 Características agronómicas de las cepas:

##### a) Crecimiento vegetativo

El desarrollo del dosel fue diferente en ambos años (Tabla 4.2.7). En 2021, el contorno de las cepas ubicadas en C1 fue un 22% mayor que el de las cepas de C2. En 2022, no se observaron diferencias.

En 2021 el porcentaje de poros en las cepas C2 fue un 160% más alta que las cepas de C1. En 2022, estas diferencias no fueron significativas debido a que los poros en

las cepas de C1 aumentaron un 98% respecto al año anterior. Los poros de las cepas de C2 fueron similares en ambos años (39 y 36.5% para 2021 y 2022, respectivamente). La evolución del desarrollo del dosel se evaluó en 2022 (20/06/2022). No se observaron diferencias significativas entre C1 y C2 en ancho del dosel, altura, SA y volumen. Sin embargo, para estos parámetros, las cepas de C1 tuvieron valores ligeramente más altos que las de C2.

No se observaron diferencias significativas entre C1 y C2 en peso de madera de poda en ningún año. Sin embargo, en 2022, el peso de madera de poda se redujo un 22 y un 11% en comparación con 2021 en C1 y C2, respectivamente.

Tabla 4.2.7. Crecimiento vegetativo de la planta: contorno de la espaldera, ancho, altura, superficie foliar externa (SA), volumen, poros (%), y peso de madera de poda en dos calicatas (C1 y C2) ubicados en el viñedo experimental (Toledo, España). Cada valor representa la media de seis cepas por tipo de suelo o calicata. DE, desviación estándar.

	C1	C2	C1	C2
	2021		2022	
Contorno (m)	2.3	1.8 *	1.72	1.82 ns
DE	0.21	0.11	0.24	0.09
Anchura (cm)	61.1	66.1 ns	95	79 ns
DE	9.47	8.51	15.47	3.12
Altura (cm)	93	92 ns	94	86 ns
DE	14.8	9.24	2.89	12.81
SA (m <sup>2</sup> )	2.5	2.4 ns	3.1	2.7 ns
DE	0.18	0.24	0.35	0.13
Volumen (m <sup>3</sup> )	0.69	0.67 ns	0.99	0.75 ns
DE	0.10	0.12	0.17	0.10
Poros (%)	15	39 *	29.7	36.5 ns
DE	3.11	5.22	5.11	5.05
Peso de madera de poda (kg/cepa)	0.18	0.18 ns	0.14	0.19 ns
DE	0.03	0.10	0.04	0.10

Niveles de significancia estadística: ns, no significativo;  $p < 0.05$ ;

b) Seguimiento de maduración

En la Figura 4.2.5 se observan la evolución de los parámetros de calidad (°Brix, acidez y pH) y la Figura 4.2.6 de rendimiento (peso de baya) en los dos años de estudio.

Aunque no se observan diferencias significativas en ningún año para los parámetros medidos, sí que se ve una clara diferencia entre años. Estas diferencias son más marcadas en cuanto °Brix (Fig 4.2.5 a,b) y peso de baya (Fig 4.2.6 a,b).

La evolución de los °Brix a lo largo de la campaña 2021 presentaba un incremento homogéneo, acumulando azúcares progresivamente. Sin embargo, en 2022 los °Brix ya presentaban valores elevados en la primera fecha de muestreo.

Los valores de pH se mantuvieron estables, en torno a 3-3.5 en ambos años. La muestra de C1 para el 2022 de la primera fecha de seguimiento de maduración no pudo llevarse a cabo debido a que no se obtuvo suficiente mosto para su análisis.

La acidez no pudo ser evaluada en las fechas de seguimiento para el año 2022 (Fig 4.2.5 f) por problemas con el equipo de medición. Sin embargo, si se pudo en vendimia de este año, donde no se observaron diferencias significativas. En 2021, la tendencia de la acidez fue decreciendo para ambos tratamientos a medida que avanzaba la campaña, sin mostrar diferencias significativas en las fechas de seguimiento de maduración. Para vendimia, sin embargo, se observa una separación entre los tratamientos.

El peso de baya fue uno de los parámetros que más cambios presentó de un año a otro (Fig 4.2.6). La media de peso de baya para los tres seguimientos de maduración en 2021 estuvo en torno a 0.7 y 0.9 g para C1 y C2 respectivamente (Fig 4.2.6a). Sin embargo, en 2022 la media de peso de baya para los tres seguimientos de maduración estuvo en torno a 0.3 y 0.4 g para C1 y C2 respectivamente (Fig 4.2.6b). Disminuyendo en más de un 50% en ambos tratamientos en 2022 comparado con 2021.

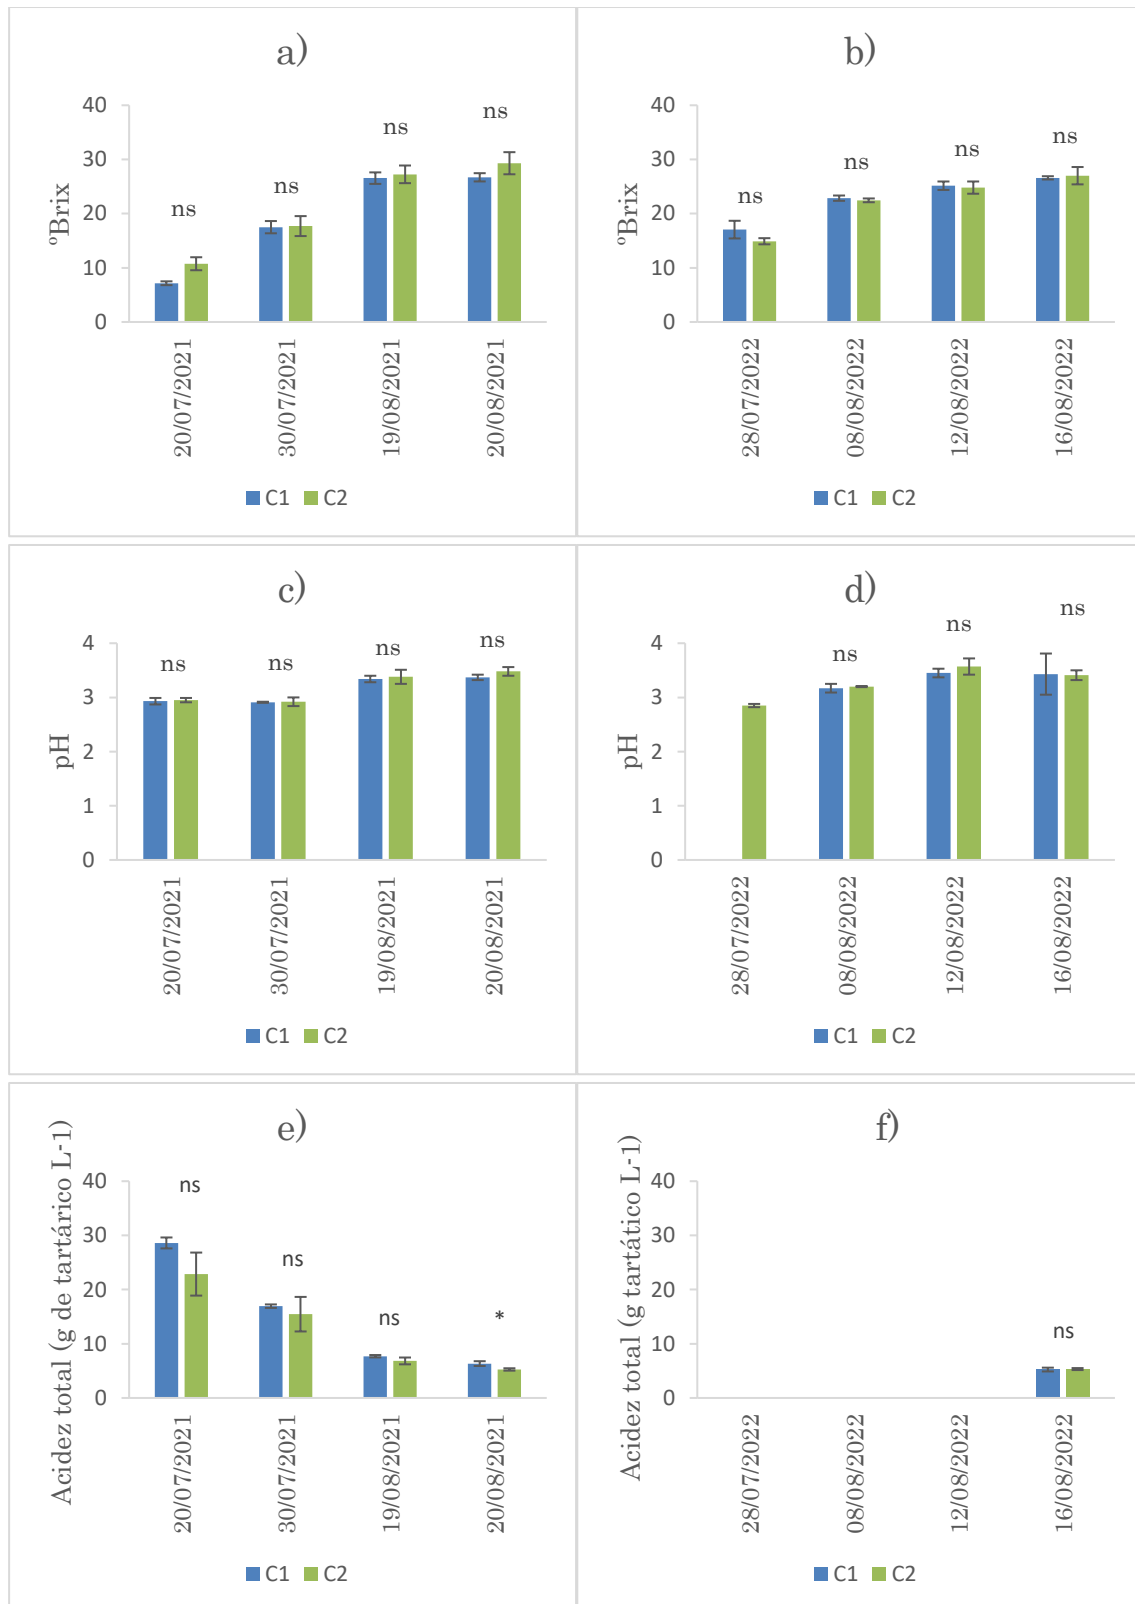


Figura 4.2.5. Seguimiento de maduración. Contenido de sólidos solubles (°Brix); pH; TA, acidez total (g de tartárico L<sup>-1</sup>) y peso de baya (g) de las cepas de las dos calicatas (C1 y C2) en el año 2021 a), c), e) y el año 2022 b), d), f).




Figura 4.2.6 Seguimiento de maduración. Peso de baya (g) de las cepas de las dos calicatas (C1 y C2) en el año 2021 a) y el año 2022 b).

## c) Producción y calidad en la vendimia

En la Tabla 4.2.8 se recogen los datos de la vendimia para ambos tratamientos los dos años de estudio.

En 2021, las cepas de C1 produjeron un número de racimos significativamente mayor (72%), y el rendimiento fue tres veces mayor que en C2. En el 2022, el rendimiento fue mayor en las cepas C2. En cuanto a la calidad, los valores de acidez en vendimia en 2021 mostraron diferencias significativas entre ambos tratamientos, a diferencia del 2022. La acidez de las cepas en C1 disminuyeron un 17% en 2022 comparado con 2021.

Tabla 4.2.8. Parámetros de rendimiento y madurez. Número de racimos por vid. Rendimiento (kg/vid). SC, contenido de sólidos solubles (°Brix); pH; TA, acidez total (g de tartárico L<sup>-1</sup>) de las cepas de las dos calicatas (C1 y C2). Cada valor representa una media de seis cepas por tipo de suelo. DE, desviación estándar.

	C1	C2	C1	C2
	2021		2022	
Número de racimos	71	20 *	63	56 ns
DE	12.3	19.6	18.7	19.7
Rendimiento (kg/vines)	3.56	1.22 *	1.54	2.10 ns
DE	0.75	1.04	0.68	0.79
SST (°Brix)	26.7	29.3 ns	26.6	27.0 ns
DE	0.76	2.04	0.3	1.6
pH	3.37	3.48 ns	3.43	3.41 ns
DE	0.05	0.08	0.38	0.09
Acidez (g de tartárico L <sup>-1</sup> )	6.34	5.26 *	5.24	5.33 ns
DE	0.44	0.22	0.35	0.18

Niveles de significancia estadística: ns, no significativo;  $p < 0.05$

#### 4.2.5 Caracterización del suelo con sensores térmico y multiespectral a bordo de UAS

La temperatura del suelo medida con la cámara térmica difirió significativamente entre los suelos (Tabla 4.2.9). La diferencia de temperatura media entre la superficie de cada suelo para ambos años fue de 1.8 °C. C1 presentó temperaturas más bajas que C2 en ambas estaciones. Las diferencias más significativas se observaron el 20/07/2021 entre los suelos (C1 = 53 °C y C2 = 56 °C). El valor máximo se observó el 20/07/2021 de 2021, con una diferencia de 3 °C. La temperatura media de C2 fue 2.5 °C más alta que la de C1.

Tabla 4.2.9. La temperatura de la superficie del suelo (°C) para cada calicata (C1 y C2). Cada valor representa una media de 300 píxeles para cada tipo de suelo. DE, desviación estándar.

Suelo	17/05/2021	20/07/2021	19/05/2022	15/07/2022
C1	43.4	52.9	51.1	59.3
DE	0.76	2.04	1.04	1.27
C2	45.2	55.9	51.4	61.6
DE	0.75	1.43	1.17	1.43
Sig	*	*	*	*

Niveles de significancia estadística: ns, no significativo;  $p < 0.05$

La respuesta multiespectral difirió entre los suelos (Figura 4.2.7). La distribución del histograma de píxeles en las bandas de borde rojo, NIR y verde mostró una clara separación entre los suelos en ambos años. En 2021, no se observaron diferencias significativas en la banda roja, mientras que, en 2022, sí aparecieron.

Los valores de reflectancia de banda para el suelo C1 fueron significativamente más altos en comparación con C2. La reflectancia NIR, verde y de borde rojo de C1 fue un 18, 16 y 16% más alta que la de las cepas C2, respectivamente. La banda de borde rojo presentó las mayores diferencias observadas entre suelos (C1 = 0.42 y C2 = 0.35) en 2021.

En 2022, las bandas de rojo, NIR, verde y borde rojo de C1 fueron un 20, 20, 29 y 22% más altas que las de las cepas C2. Las diferencias más significativas entre las cepas se observaron en la banda verde (C1 = 0.20 y C2 = 0.14). Las bandas verdes y de borde rojo mostraron las mayores diferencias entre los suelos en ambos años.

La banda verde mostró estas diferencias con cierta superposición entre píxeles de suelo, pero los suelos aún eran significativamente diferentes en 2021.

En resumen, las diferencias en las imágenes espectrales del suelo no dependieron del año. Las bandas verdes, borde rojo y NIR diferenciaron los dos tipos de suelo. Las mayores diferencias en IV entre los suelos se observaron en el GNDVI.




Figura 4.2.7. Histograma de cada banda multispectral de la superficie del suelo de las cepas experimentales cercanas (C1 y C2) en el viñedo (Toledo, España) basado en 500 píxeles para cada sitio. Las dos primeras filas corresponden a 2021 (-21), y el resto corresponden a 2022 (-22). Las bandas son borde rojo (a, e); rojo (b, f); NIR (c, g); y verde (d, h).

Los valores de NDVI, RVI y GNDVI mostraron diferencias significativas entre los suelos en 2021 (Figura 4.2.8). En C1, fueron un 34, 18 y 59% más altos que en C2. En 2022, solo el valor de GNDVI mostró diferencias significativas. C1 fue un 85% más alto que C2. No se observaron diferencias significativas en los valores de NDVI y RVI.

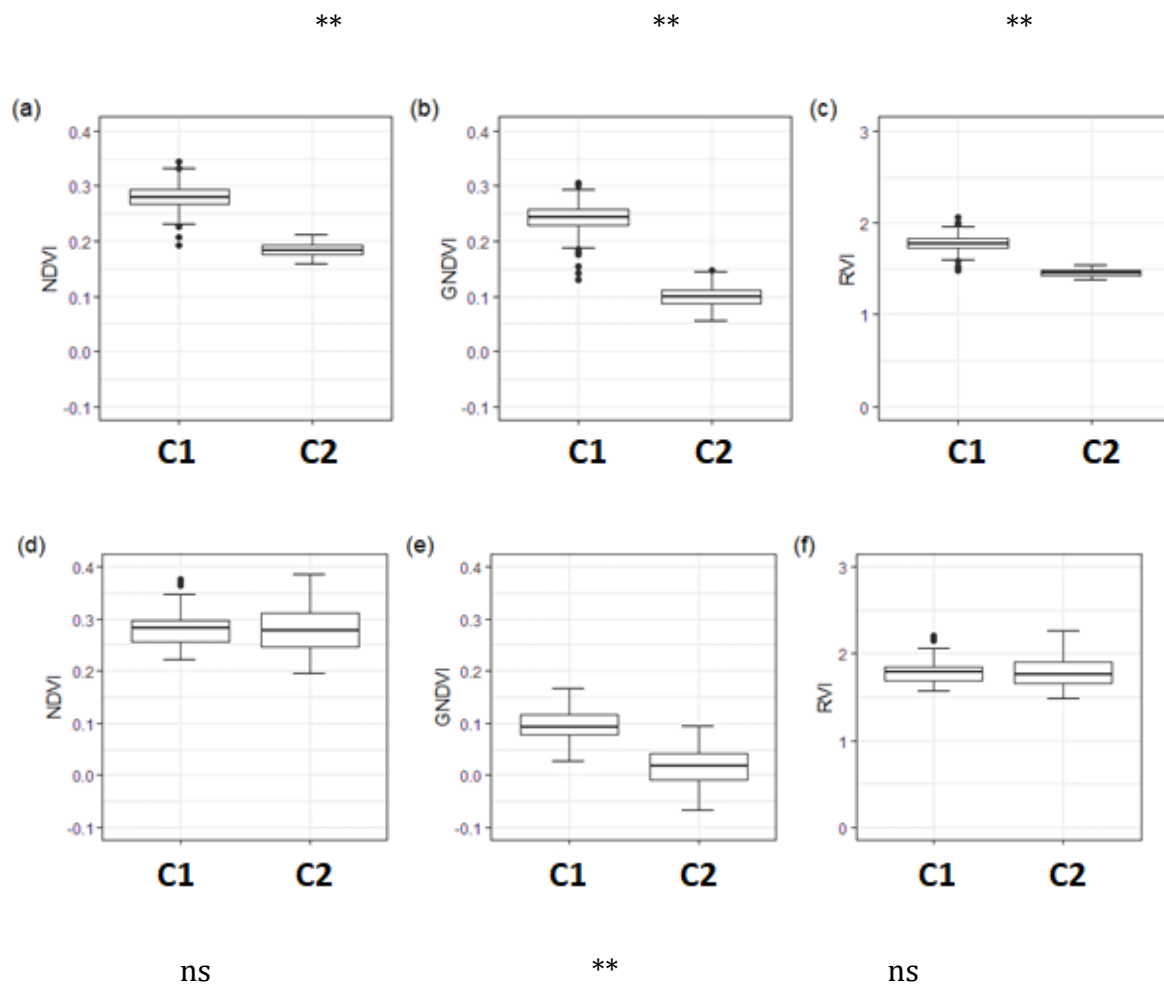


Figura 4.2.8. Índices de vegetación correspondiente a los suelos de estudio (C1 y C2) ubicadas cerca de las cepas experimentales (Toledo, España). La primera fila corresponde a 2021, y la segunda fila corresponde a 2022. Los índices son NDVI (a, d); RVI (b, e); y GNDVI (c, f). Niveles de significancia estadística (Sig.): ns, no significativo; \*  $p < 0.05$ ; \*\*  $p < 0.01$ . Las estadísticas se basan en 500 píxeles por cada tipo de suelo (C1 y C2).

#### **4.2.6 Caracterización de las cepas mediante sensor multiespectral instalado en UAS**

Los valores de IV obtenidos a partir de las imágenes multiespectrales de las copas de las cepas ubicadas en los suelos C1 y C2 se diferenciaron de forma significativa. En 2021, todos los valores de IV de las cepas C1 fueron significativamente más altos que los de las cepas C2 (Tabla 4.2.10). Los valores máximos de cuatro de los IV calculados se encontraron el 20/07/2021 en las cepas C1 (NDVI = 0.83, RVI = 10.48, OSAVI = 0.74 y GNDVI = 0.76).

Los valores de RVI, NDVI y OSAVI de las cepas C1 fueron un 55, 10 y 11% más altos que los de las cepas C2. Los valores más bajos de los IV ocurrieron en las cepas C2 (NDVI = 0.73, RVI = 6.5 y OSAVI = 0.64) en la cosecha, y las diferencias entre las cepas se redujeron. En esta medida, los valores de IV de las cepas C1 fueron un 5, 17 y 3% más altos que los de las cepas C2 para el NDVI, RVI y OSAVI, respectivamente. Los valores medios de 2021 de NDVI, RVI y NDRE fueron significativamente diferentes entre las cepas C1 y C2.

La distribución de los valores de IV cambió drásticamente en 2022 (Tabla 4.2.7). El valor medio de los índices para las cepas de cada tipo de suelo fue más bajo en comparación con 2021. Al principio de la temporada 2022 (30/06/2022), los valores de NDVI, RVI, OSAVI, GNDVI y NDRE en las cepas C1 disminuyeron un 9, 33, 23, 13 y 5%, respectivamente, en comparación con los de 2021. Cerca de la cosecha (12/08/2022), los valores de NDVI, RVI, OSAVI y GNDVI de las cepas C1 disminuyeron un 15, 38, 24 y 19% respectivamente en comparación con la temporada anterior. Por el contrario, el NDRE de las cepas C1 aumentó un 20% en 2022.

Las diferencias entre los IV evaluados de las cepas dependieron de la temporada. El RVI mostró las mayores diferencias entre las cepas en diferentes suelos en la temporada 2021. En 2021, el valor de RVI de las cepas C1 fue un 22% más alto que el de las cepas C2. En 2022, el índice NDRE fue el único que mostró diferencias entre las cepas.

Tabla 4.2.10. Índices de vegetación obtenidos a partir de imágenes multiespectral a las 12:00 en la temporada 2021.

<b>Fechas</b>	<b>Cepas</b>	<b>NDVI</b>	<b>RVI</b>	<b>OSAVI</b>	<b>GNDVI</b>	<b>NDRE</b>
25/06/2021	C1	0.84	11.33	0.75	0.74	0.20
	C2	0.75	7.07	0.65	0.69	0.22
	sig.	*	*	*	*	*
DE	C1	0.011	0.793	0.013	0.009	0.013
	C2	0.046	1.208	0.051	0.029	0.007
05/07/2021	C1	0.79	8.56	0.69	0.71	0.24
	C2	0.79	8.55	0.70	0.73	0.24
	sig.	ns	ns	ns	**	ns
DE	C1	0.004	0.200	0.008	0.005	0.015
	C2	0.019	0.782	0.021	0.011	0.008
20/07/2021	C1	0.83	10.48	0.74	0.76	0.24
	C2	0.77	7.72	0.69	0.74	0.26
	sig.	*	*	*	*	*
DE	C1	0.007	0.465	0.010	0.008	0.011
	C2	0.030	1.005	0.034	0.019	0.013
30/07/2021	C1	0.73	6.48	0.64	0.73	0.21
	C2	0.69	5.46	0.60	0.68	0.21
	sig.	*	*	*	*	ns
DE	C1	0.007	0.200	0.014	0.010	0.010
	C2	0.031	0.591	0.032	0.035	0.018
19/08/2021	C1	0.77	7.85	0.67	0.71	0.20
	C2	0.73	6.64	0.65	0.71	0.22
	sig.	*	*	*	ns	*
DE	C1	0.016	0.598	0.021	0.009	0.017
	C2	0.037	1.001	0.032	0.028	0.020
2021	C1	<b>0.79</b>	<b>8.87</b>	<b>0.69</b>	<b>0.73</b>	<b>0.22</b>
	C2	<b>0.74</b>	<b>6.95</b>	<b>0.65</b>	<b>0.71</b>	<b>0.23</b>
	sig	<b>*</b>	<b>*</b>	<b>ns</b>	<b>ns</b>	<b>*</b>

Niveles de significancia estadística: ns, no significativo;  $p < 0.05$

Tabla 4.2.11. Índices de vegetación obtenidos a partir de imágenes multiespectral a las 12:00 en la temporada 2022.

30/06/2022	C1	0.77	7.57	0.58	0.65	0.19
	C2	0.77	7.87	0.58	0.65	0.21
	sig.	ns	ns	ns	ns	*
DE	C1	0.018	0.58	0.02	0.01	0.01
	C2	0.038	1.15	0.03	0.03	0.01
15/07/2022	C1	0.74	6.70	0.57	0.65	0.24
	C2	0.73	6.55	0.56	0.65	0.20
	sig.	ns	ns	ns	ns	*
DE	C1	0.02	0.45	0.01	0.01	0.02
	C2	0.03	0.78	0.03	0.02	0.02
05/08/2022	C1	0.73	6.32	0.55	0.59	0.24
	C2	0.73	6.38	0.57	0.62	0.28
	sig.	ns	ns	*	*	*
DE	C1	0.02	0.56	0.02	0.02	0.01
	C2	0.02	0.40	0.02	0.01	0.01
12/08/2022	C1	0.66	4.86	0.51	0.58	0.24
	C2	0.64	4.56	0.49	0.58	0.17
	sig.	*	*	*	ns	*
DE	C1	0.02	0.33	0.02	0.02	0.02
	C2	0.02	0.25	0.02	0.01	0.01
2022	C1	0.72	6.31	0.55	0.61	0.23
	C2	0.72	6.33	0.55	0.63	0.22
	sig.	ns	ns	ns	ns	*

Niveles de significancia estadística: ns, no significativo;  $p < 0.05$

## **4.3 Parámetros evaluados Ensayo 2: Caracterización del estado hídrico de las plantas**

En los siguientes apartados se desglosan los resultados obtenidos de los parámetros medidos en campo. Estos se han separado entre parámetros fisiológicos y parámetros agronómicos, así mismo, se hace una referencia del tipo de suelo donde se asientan las cepas de estudio.

### **4.3.1 Descripción de propiedades físicas y químicas de los horizontes. Clasificación**

Basándonos en el mapa de zonificación obtenidos en el Ensayo 1 (Figura 4.2.3) al observar que las características del espectro visible del suelo con clasificación Calcic Haploxeralfs son similares a la zona del Ensayo 2, el mapa de zonificación queda delimitada tal y como se refleja en la Figura 4.3.1. Se reduce las líneas de clasificación en base a esta información, situando el suelo del ensayo de riego perteneciente a la familia franco-gruesa (Atencia Payares et al., 2023).



Figura 4.3.1. Mapa de zonificación de los suelos de la zona de estudio.

## 4.3.2 Características de las cepas

### 4.3.2.1 Características fisiológicas

#### a) Fenología

En la Tabla 4.3.1 se describen todos los estados fenológicos que presentaban los diferentes tratamientos durante las dos temporadas de riego (2021 y 2022).

Los estados mayores fueron: brotación el 25/03/2021 y el 10/04/2022, floración el 06/05/2021 y el 15/05/2022 y cuajado 02/06/2021 y el 31/05/2022.

Tabla 4.3.1. Evolución fenológica de los tratamientos de riego durante las dos campañas de riego.

Tratamientos	Estados fenológicos (2021)	Estados fenológicos (2022)
	Modificado de E-L por Coombe (1995)	Modificado de E-L por Coombe (1995)
<b>Fecha</b>	<b>15/06/2021</b>	
T100	Bayas tamaño guisante (7 mm $\emptyset$ )	
T50		
T25		
T25-S		
T0		
<b>Fecha</b>	<b>18/06/2021</b>	
T100	Bayas tamaño guisante: Comienza el racimo a cerrarse.	
T50		
T25		
T25-S		
T0		
<b>Fecha</b>	<b>25/06/2021</b>	<b>30/06/2022</b>
T100	Bayas tamaño guisante: Bayas aún duras y verdes	Bayas tamaño guisante (7 mm $\emptyset$ )
T50		
T25		
T25-S		
T0		
<b>Fecha</b>	<b>05/07/2021</b>	<b>15/07/2022</b>
T100	Bayas tamaño guisante (1 cm $\emptyset$ ): Comienzan a ablandarse	Bayas aún duras y verdes
T50		

T25	las bayas. Comienza a incrementarse el °Brix	
T25-S		
T0		
<b>Fecha</b>	<b>20/07/2021</b>	<b>27/07/2022</b>
T100	Comienza a incrementarse el °Brix	Bayas con valores intermedios de °Brix
T50	Comienza a incrementarse el °Brix	
T25	Envero: Las bayas comienzan a colorearse y agrandarse	
T25-S	Comienza a incrementarse el °Brix	
T0	Comienza a incrementarse el °Brix	
<b>Fecha</b>	<b>30/07/2021</b>	<b>05/08/2022</b>
T100	Envero: Bayas con valores intermedios de °Brix	Envero: Bayas no suficientemente maduras
T50		
T25		
T25-S		
T0		
<b>Fecha</b>	<b>19/08/2021</b>	<b>16/08/2022</b>
T100	Vendimia: Madurez de recolección	Vendimia: Madurez de recolección
T50	Vendimia: Madurez de recolección	
T25	Vendimia: Madurez de recolección	
T25-S	Vendimia: Madurez de recolección	
T0	Bayas sobremaduras	

### b) Potencial hídrico del tronco (PHT)

La media anual de PHT osciló entre -0.43 MPa (9:00, 05/07/2021) y -1.80 MPa (12:00, 12/08/2022), con una marcada reducción en los valores de PHT en todos los tratamientos en el año más seco (2022) en comparación con 2021, especialmente a las 9:00. Por ejemplo, los valores medios de T100 en 2022 fueron un 106 % más bajos que en 2021 a las 9:00 y un 73 % más bajos a las 12:00.

PHT fue más bajo a las 12:00 (Figura 4.3.2) que a las 9:00, pero las diferencias entre la mañana y el mediodía fueron mayores (41 %) en 2021 en comparación con el año más seco y caluroso de 2022 (16 %). El efecto del déficit de agua en el suelo fue evidente en la media anual de PHT, que fue significativamente más alto en T100 en comparación con T25, T25-S y T0. Parece que las cepas pudieron tolerar un estrés hídrico moderado, ya que el PHT en T100 y T50 no mostró diferencias significativas en la mayoría de las mediciones a pesar de recibir la mitad del riego suministrada a T50.

El efecto de las dosis de riego en el estado hídrico fue más claro en 2021 que en 2022, donde especialmente al mediodía no hubo diferencias significativas en el PHT. El tratamiento de secano (T0) muestra una mayor variabilidad al mediodía que los otros tratamientos.

Valores diarios y medias anuales de PHT en material suplementario (Tabla S1)

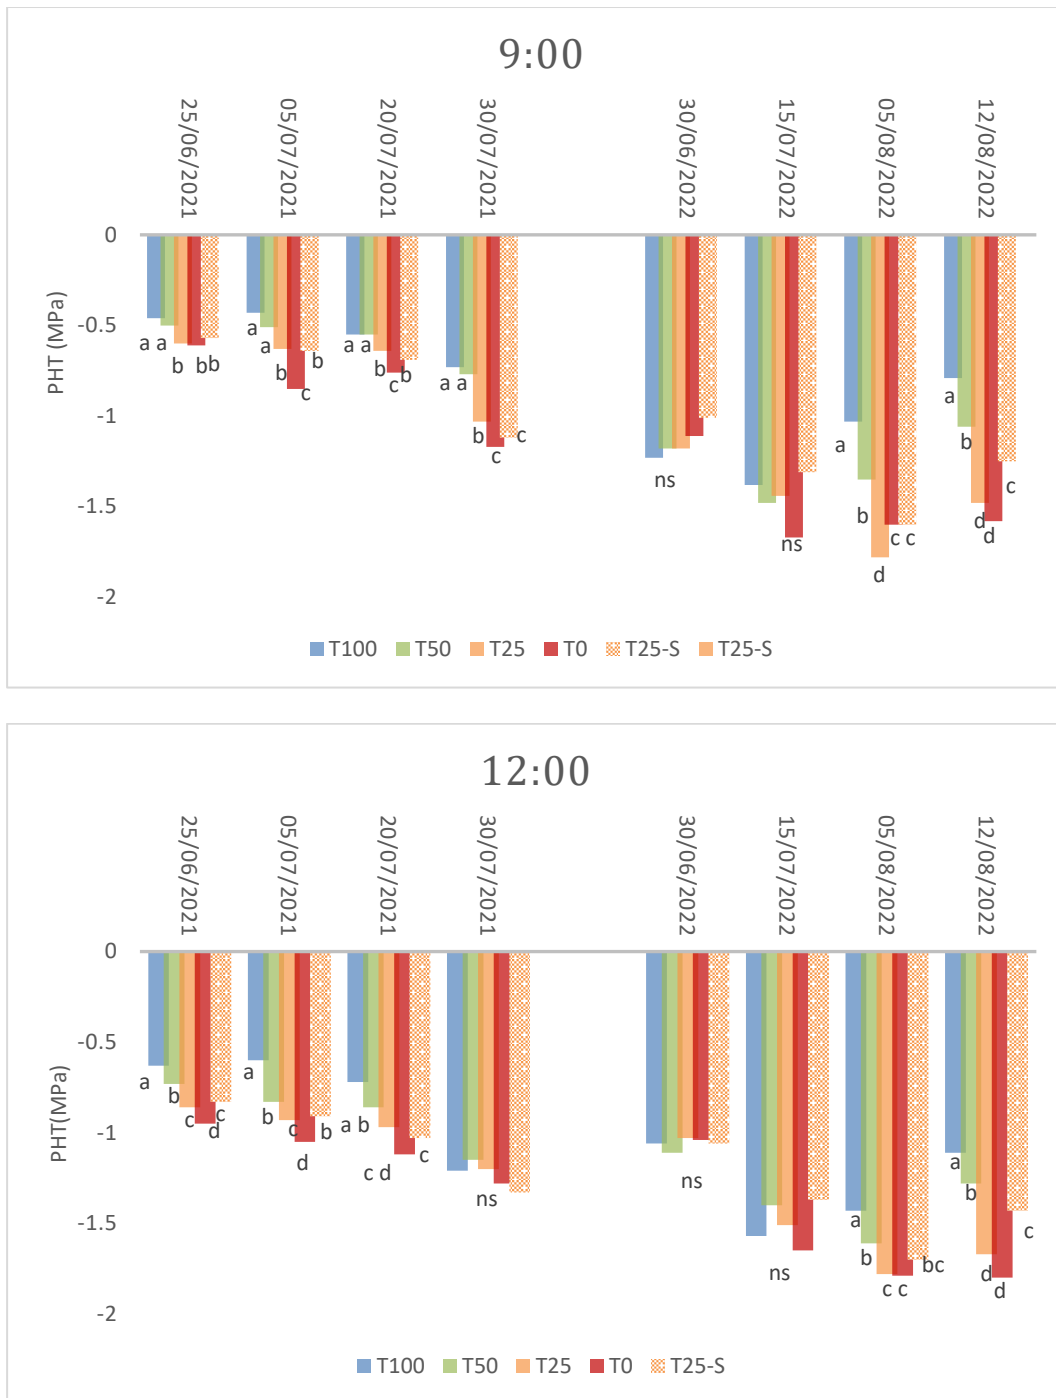


Figura 4.3.2 Potencial hídrico del tronco (PHT, MPa) a las 9:00 y 12:00 en ambos años (2021, 2022) según los tratamientos de riego (T100, T50, T25, T0 y T25-S). Niveles de significancia estadística: ns, no significativo; medias con letra distinta son significativamente diferentes,  $p < 0.05$

## c) Conductancia estomática (gs)

La respuesta de gs (Figura 4.3.3) a las dosis de riego fue similar a la del PHT (Figura 4.3.2), con valores media más bajos en el año más caluroso y seco (2022), especialmente al mediodía. gs fue máximo (222 mmol/m<sup>2</sup>s) el 25/06/2021 a las 9:00 y mínimo a finales del año seco el 05/08/2022 al mediodía (17 mmol/m<sup>2</sup>s). La reducción en gs entre 2021 y 2022 para el tratamiento más regado (T100) fue del 61 % y del 50 % a las 9:00 y 12:00, respectivamente. T25-S presentó la menor reducción en comparación con los otros tratamientos en ambas horas.

gs fue más bajo a las 12:00 que a las 9:00, pero las diferencias fueron mayores (44 %) en 2021 en comparación con 2022 (19 %). Se observaron diferencias significativas en gs entre los tratamientos de riego en ambos años. La media anual de gs fue significativamente mayor en T100 en comparación con los otros tratamientos. Además, T25, T0 y T25-S no presentaron diferencias significativas en la mayoría de las mediciones y valores. Valores diarios y medias anuales de gs en material suplementario (Tabla S2)


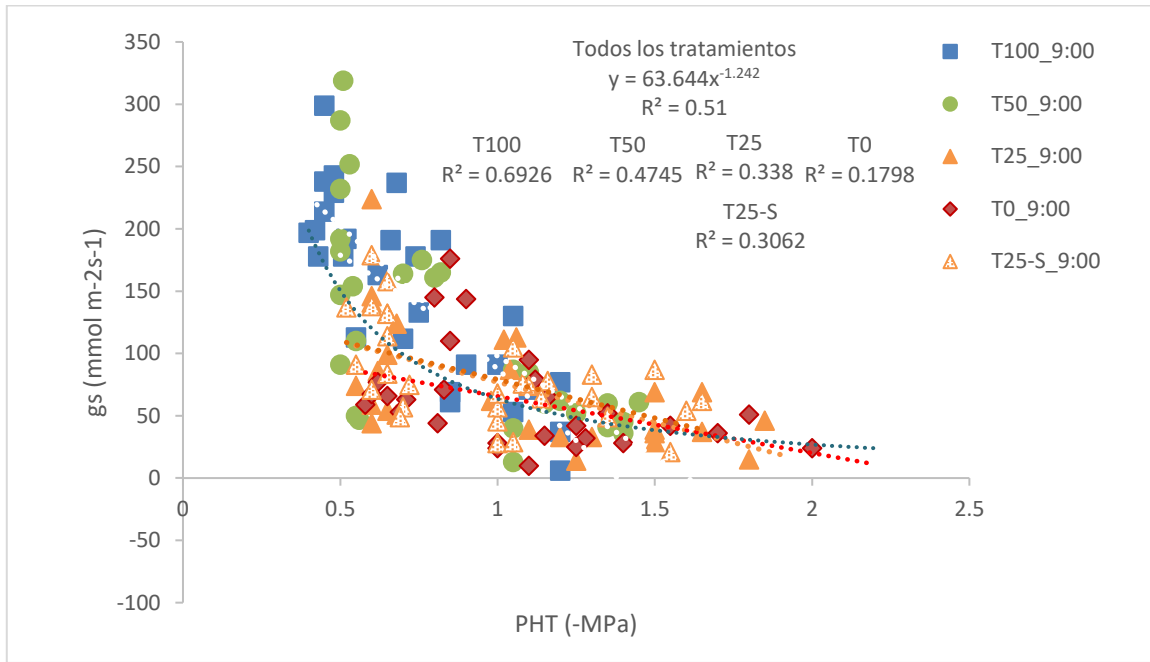


Figura 4.3.3 Conductancia estomática gs ( $\text{mmol/m}^2\text{s}^{-1}$ ) a las 9:00 y 12:00 en ambos años (2021, 2022) según los tratamientos de riego (T100, T50, T25, T0 y T25-S). Niveles de significancia estadística: ns, no significativo; medias con letra distinta son significativamente diferentes,  $p < 0.05$

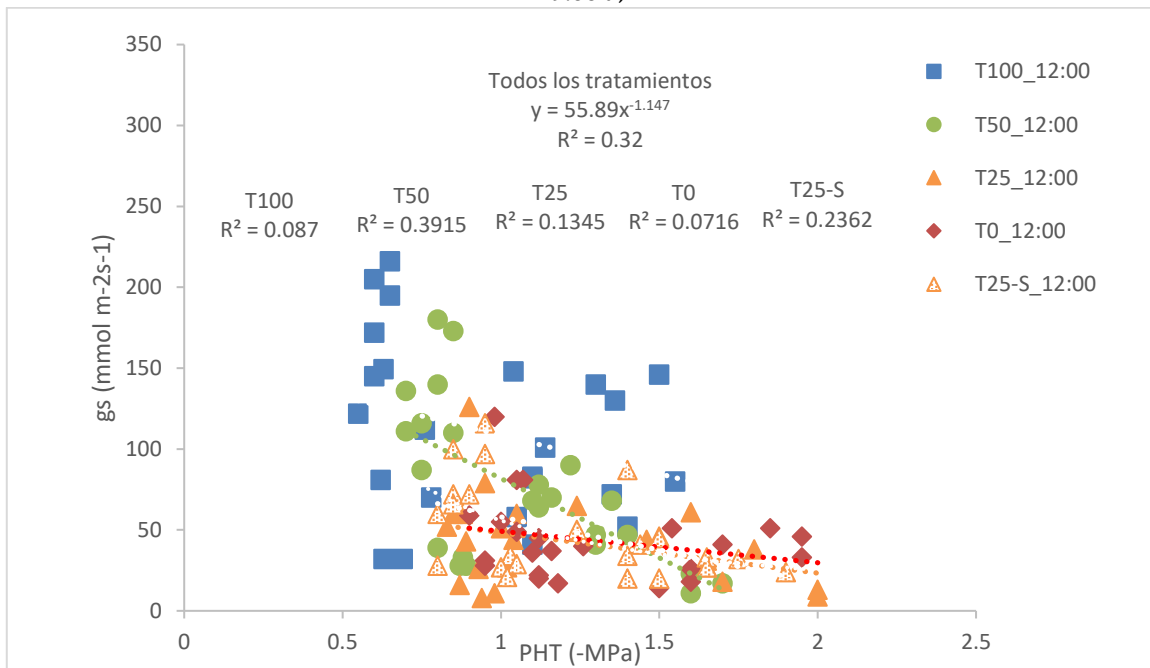
## d) Relación entre PHT y gs

Se muestran en la Figura 4.3.4 los gráficos de gs vs PHT en ambos momentos del día para todos los tratamientos de riego

Se observaron relaciones significativas no lineales entre gs y PHT a las 9:00 (Figura 4.3.4a) y 12:00 (Figura 4.3.4b). Los valores de gs disminuyeron rápidamente a las 9:00 hasta 1.1 MPa y luego de manera más gradual a medida que PHT aumentaba. Sin embargo, este comportamiento no es claro a las 12:00, especialmente debido a la dispersión de las cepas del tratamiento más regado (T100), que mantienen los estomas abiertos a pesar de una marcada reducción en PHT, correspondiente a la fecha 30 de junio de 2022.



9:00 a)



12:00 b)

Figura 4.3.4 Relación entre PHT y gs a las 9:00, (a). Relación entre PHT y gs a las 12:00 (b) (las ecuaciones de regresión se obtuvieron considerando todas las fechas para todos los tratamientos y todas las fechas para los tratamientos por separado)

## e) Clorofila

En la Figura 4.3.5 se observa los valores de clorofila medidos en los tratamientos para las dos horas y para cada día de vuelo de los dos años de estudio.

En el año 2021 se observan diferencias significativas entre los tratamientos el 30 de julio a medio día y el 20/07 por la mañana. El tratamiento T100 presenta los valores más altos para ambas horas con respecto al resto de tratamientos. El tratamiento T25 presenta los valores más bajos a las 9:00 del 20 de julio y el T25-S a las 12:00 del 30/07. Con respecto a la media anual, el tratamiento T100 y T25 aumenta un 11% a las 12:00 con respecto a las 9:00 y el T0 un 9%.

En el año 2022 se observan diferencias significativas entre los tratamientos en ambas horas, principalmente en fechas cercanas a vendimia, es decir, la primera y segunda semana de agosto. El aumento de la clorofila en media anual es menos significativo. Siendo un 5% para T100 y T25 superior a las 12:00 con respecto a las 9:00.

Si observamos los valores medios anuales de los tratamientos entre un año y otro, se aprecia un descenso en 2022 del 19% a las 9:00h y del 23% a las 12:00 en media para todos los tratamientos.

Valores diarios y medias anuales de clorofila en material suplementario (Tabla S3)




Figura 4.3.5 Clorofila (Chl, micromol/m<sup>2</sup>) a las 9:00 y 12:00 en ambos años (2021, 2022) según los tratamientos de riego (T100, T50, T25, T0 y T25-S). Niveles de significancia estadística: ns, no significativo; medias con letra distinta son significativamente diferentes,  $p < 0.05$

f) Temperatura de la hoja (TL) y Temperatura de la copa (Tc)

La Temperatura de la Hoja expuesta al sol (TL), medida manualmente con el equipo de intercambio gaseoso CIRAS2, se muestra (Figura 4.3.6). Los valores

media oscilaron entre 31.4°C (9:00, 25/06/2021) y 46°C (12:00, 05/08/2022). TL fue mayor en 2022 que en 2021. En 2022, TL en T100 fue 2.8°C y 1.7°C más alta que en 2021 a las 9:00 y 12:00 respectivamente. TL fue 6°C más alta a las 12:00 en comparación con las 9:00 en la media anual de 2021 en el tratamiento T100.

Los tratamientos de riego afectaron significativamente la TL, especialmente en 2021 a las 9:00. La media anual para ambos años de TL a las 9:00 fue significativamente más baja en T100 en comparación con los otros tratamientos. En particular, T100 fue 4°C más baja que T0 a las 9:00 en ambos años. T25, T0 y T25-S no difirieron significativamente en la mayoría de las mediciones y valores.

Valores diarios y medias anuales de temperatura de la hoja en material suplementario (Tabla S4).




Figura 4.3.6 Temperatura de la hoja (TL) a las 9:00 y 12:00 en ambos años (2021, 2022) según los tratamientos de riego (T100, T50, T25, T0 y T25-S). Niveles de significancia estadística: ns, no significativo; medias con letra distinta son significativamente diferentes,  $p < 0.05$

En la Figura 4.3.7 se muestra la media anual de Tc estimada por la cámara térmica a bordo de UAS. Los valores oscilaron entre 27.5°C (9:00, 25/06/2021) y 51.2°C (12:00, 15/07/2022). El aumento medio de Tc para todos los tratamientos en 2022 fue de 2 y 7°C más alto que en 2021 a las 9:00 y 12:00 respectivamente. En 2022, Tc en T100 fue 3.5°C y 8°C más alto que en 2021 a las 9:00 y 12:00 respectivamente. Valores diarios y medias anuales de la temperatura de la copa en material suplementario (Tabla S5).




Figura 4.3.7 Temperatura de la copa de las cepas (Tc) a las 9:00 y 12:00 en ambos años (2021, 2022) según los tratamientos de riego (T100, T50, T25, T0 y T25-S). Niveles de significancia estadística: ns, no significativo; medias con letra distinta son significativamente diferentes,  $p < 0.05$

Respecto a ambas temperaturas, la TL presentó diferencias significativas a las 9:00 y 12:00 en 2021. Sin embargo, en 2022, las diferencias entre tratamientos solo se observaron por la mañana. El comportamiento de Tc fue diferente en comparación con la TL. Las temperaturas obtenidas por el dron no pudieron

distinguir entre tratamientos en la medición de las 9:00; sin embargo, fue más sensible en la medición del mediodía.

Tc, la temperatura radiométrica, que refleja principalmente la emisión de onda larga en la parte superior del dosel, estuvo significativamente relacionada con TL ( $y=1.36x-15.52$ ,  $R^2=0.74$ ), donde Tc fue menor que TL para valores de TL por debajo de 43°C. Tc es similar a TL en valores más altos de 43°C.

Esta relación explica que las temperaturas medias del mediodía sean similares entre ambos parámetros en 2021, siendo de 40.6°C y 40.8°C para Tc y TL respectivamente.

#### 4.3.2.2 Características agronómicas

##### a) Crecimiento vegetativo

En la Tabla 4.3.2 y la Tabla 4.3.3 se muestran los parámetros agronómicos con respecto al desarrollo vegetativo del año 2021 y 2022, respectivamente. Se observa que las principales diferencias significativas entre los tratamientos de riego tienen lugar el año 2021. SA del tratamiento más regado (T100) fue un 20% superior con respecto al menos regado (T0). Misma situación se observó en cuanto al volumen de la superficie foliar de la copa, T100 fue un 34% superior al T0. Con respecto al resto de tratamientos, T0 fue significativamente más bajo. Los tratamientos T100, T50 y T25-S presentaban medias similares en cuanto a SA y volumen. El resto de los parámetros no mostraban diferencias significativas entre tratamientos. Con respecto al año 2022 los valores medios de todos los parámetros medidos incrementaron para todos los tratamientos, a excepción del porcentaje de poros que fue mucho menor en 2022. Esto indica que el año 2022 hubo un mayor desarrollo vegetativo. El volumen incrementó en más de un 100% con respecto al 2021 para todos los tratamientos, es decir, todos los tratamientos tenían el doble de volumen.

El peso de madera de poda, sin embargo, presentó una evolución diferente entre años y entre tratamientos. T100 y T50 incrementaron un 4 y 18 % en el 2022 comparado con 2021. T25 disminuyó un 16% y T0 y T25-S incrementaron un 16%. Como se observa, aunque haya habido un desarrollo vegetativo significativo en el 2022, los tratamientos T25, T25-S y T0 presentaron valores más bajos de poda que

el año anterior. El tratamiento más regado T100 presentó valores similares ambos años.

Tabla 4.3.2 Crecimiento vegetativo de la planta en el 2021: contorno de la superficie foliar, ancho del dosel, altura del dosel, área de superficie foliar externa (SA), volumen, poros (%), y peso de madera de poda (MP) de las cepas en los 5 tratamientos de riego. Cada valor representa una media de seis cepas por tipo de suelo o calicata. DE, desviación estándar.

	T100	T50	T25	T0	T25-S
<b>2021</b>					
Contorno (m)	1.77	1.69	1.59	1.45	1.64 ns
DE	0.21	0.24	0.11	0.23	0.27
Anchura (cm)	68.43	65.13	67.78	51.65	71.68 ns
DE	13.0	15.7	9.1	8.7	11.6
Altura (cm)	76.25	77.08	64.83	67.67	72.59 ns
DE	5.8	10.5	5.6	12.9	19.0
SA (m <sup>2</sup> )	2.34 a	2.28 a	2.20 ab	1.88 b	2.38 a *
DE	0.3	0.2	0.14	0.18	0.15
Volumen (m <sup>3</sup> )	0.58 a	0.54 a	0.48 ab	0.38 b	0.56 a *
DE	0.14	0.06	0.03	0.07	0.10
Poros (%)	35	35.83	33.76	32.28	36.85 ns
DE	5.2	1.5	4.0	1.5	3.9
MP (kg/vines)	0.25	0.15	0.21	0.21	0.23 ns
DE	0.07	0.04	0.05	0.09	0.03

Tabla 4.3.3 Crecimiento vegetativo de la planta en el 2022: contorno, ancho, altura, área de superficie foliar externa (SA), volumen, poros (%), y peso de madera de poda (MP) de las cepas en los 5 tratamientos de riego. Cada valor representa una media de seis cepas por tipo de suelo o calicata. DE, desviación estándar

	T100	T50	T25	T0	T25-S
	<b>2022</b>				
Contorno (m)	2.0	2.0	1.9	1.8	2.1 ns
DE	0.39	0.25	0.39	0.29	0.26
Anchura (cm)	93.5	91.2	88.6	81.9	81.4 ns
DE	10.62	17.09	12.62	10.22	12.32
Altura (cm)	102.3	112.8	113	100.6	116.1 ns
DE	10.3	24.02	2.02	29.96	13.96
SA (m <sup>2</sup> )	3.2	3.3	3.9	2.9	3.1 ns
DE	0.22	0.49	0.28	0.28	0.22
Volumen (m <sup>3</sup> )	1.1	1.1	1.1	0.9	1.0 ns
DE	0.13	0.32	0.16	0.23	0.13
Poros (%)	23.3	25.4	21.5	23.5	25.6 ns
DE	1.75	3.51	7.18	2.02	2.17
MP (kg/vines)	0.26	0.18	0.18	0.14	0.26 ns
DE	0.06	0.07	0.06	0.06	0.15

Niveles de significancia estadística: ns, no significativo; medias con letra distinta son significativamente diferentes,  $p < 0.05$

g) Seguimiento de maduración

La Figura 4.3.8 muestra el seguimiento de maduración en tres fechas más la cuarta y última fecha que se corresponde con la vendimia en ambos años.

La Figura 4.3.9 muestra el seguimiento de peso de baya en las mismas fechas.

Los °Brix, en ambos años, no presentaron diferencias significativas las dos primeras fechas del seguimiento de maduración (Fig 4.3.8 a,b). Los tratamientos empiezan a diferenciarse en la fecha anterior a la vendimia. Para el año 2021 estas diferencias no se observaron en el día de vendimia, sin embargo, en el año 2022 tanto el seguimiento de maduración anterior a la vendimia como el día de vendimia, se observaron diferencias significativas entre los tratamientos. En cuanto a los valores medios, los °Brix disminuyeron un 22% en el 2022 con respecto a los valores del 2021 en la fecha anterior a vendimia.

En el año 2022 (Fig 4.3.8b) los tratamientos se diferenciaban claramente en la fecha anterior a la vendimia, formando un grupo los tratamientos más deficitarios (T0, T25 y T25-S) con mayores °Brix con respecto a T100 y T50.

El pH en 2021 (Fig 4.3.8c) presentó un salto cualitativo del segundo seguimiento de maduración (30/07/2021) al tercer seguimiento (19/08/2021). Ambas fechas presentaron diferencias significativas entre los tratamientos.

Los valores de pH en 2022 (Fig 4.3.8d) no presentaron diferencias significativas para ninguno de los tratamientos. Sin embargo, hay una evolución más escalonada a lo largo de la campaña comparado con el 2021.

Finalmente, los valores de acidez de 2021 se observan en la figura 4.3.8.e. Este parámetro no pudo ser evaluado en la campaña de 2022 debido a un problema con el equipo valorador. Los tratamientos fueron significativamente diferentes la segunda y tercera fecha de seguimiento.

El peso de baya en 2021 (Fig 4.3.9a) presentó una tendencia homogénea a lo largo de la campaña manteniendo las diferencias significativas a partir del segundo seguimiento de maduración hasta vendimia. El tratamiento más regado, T100, presentaba los valores más altos de peso de baya a partir del segundo seguimiento de maduración.

El peso de baya en 2022 (Fig 4.3.9b) presenta una importante reducción en los valores medios de peso de baya de todos los tratamientos con respecto al 2021.

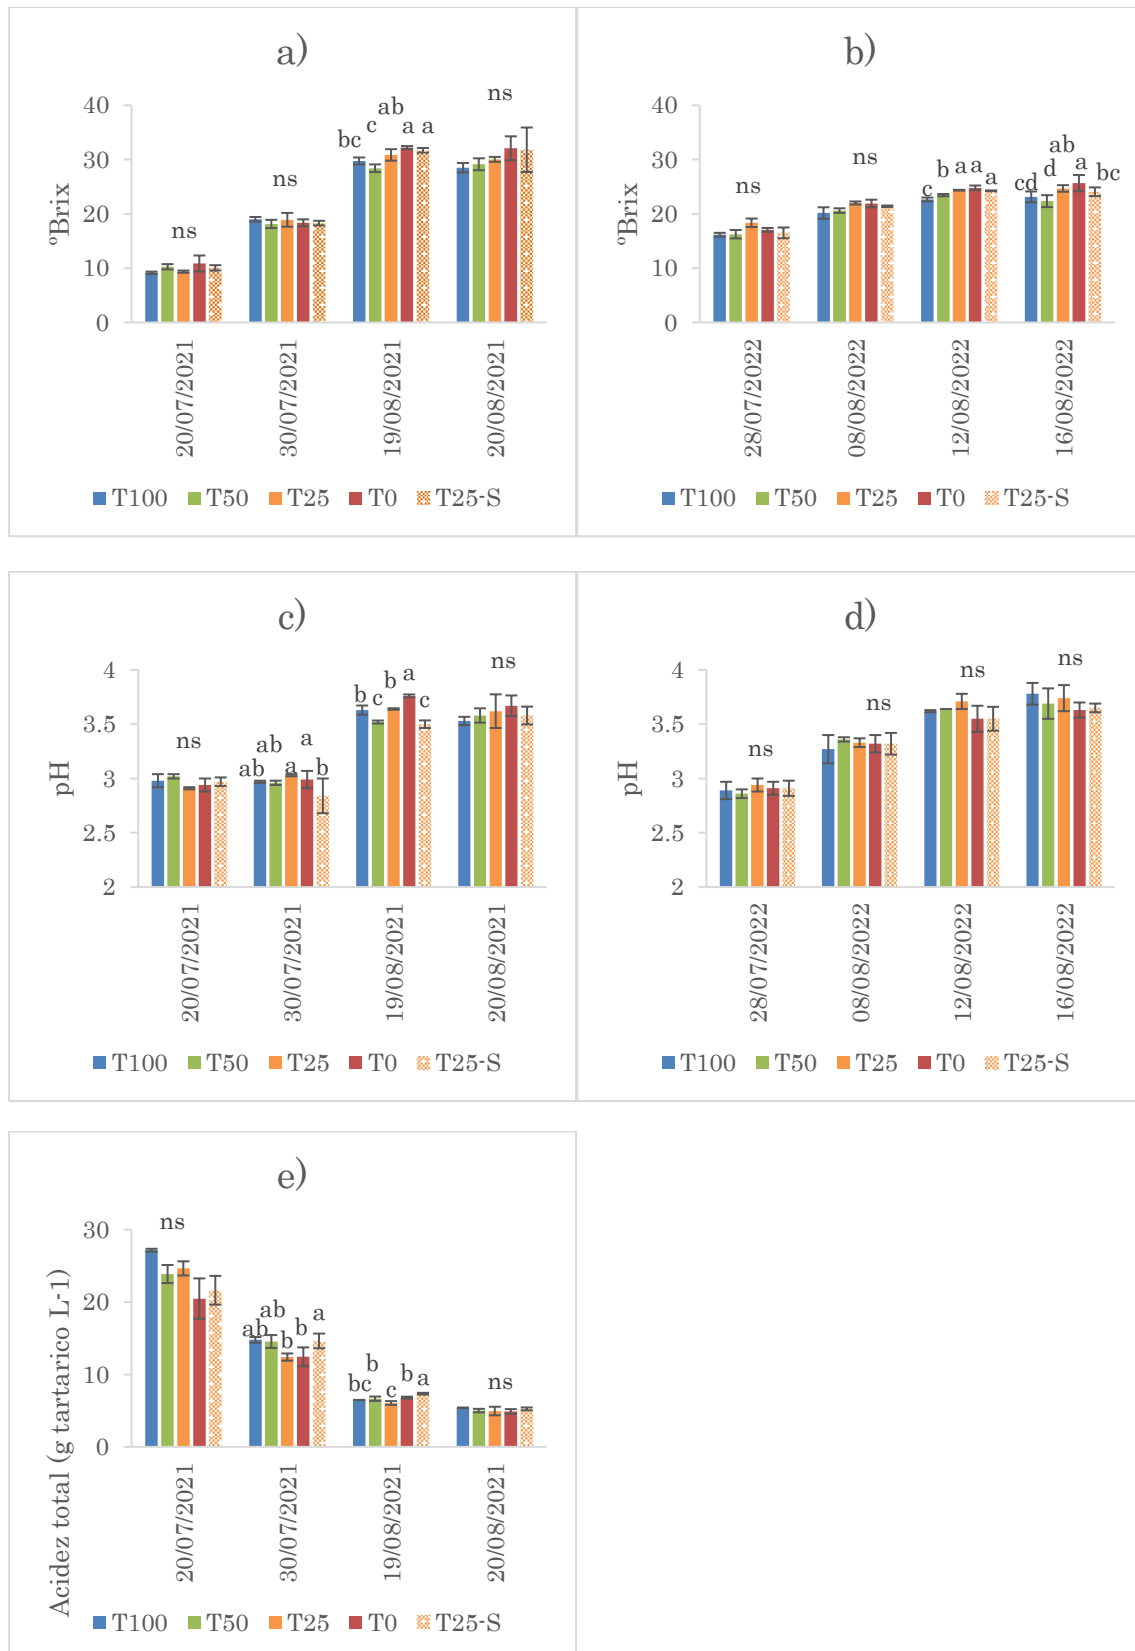


Figura 4.3.8: Seguimiento de maduración. Contenido de sólidos solubles ( $^{\circ}$ Brix); pH y TA, acidez total (g de tartárico  $\text{L}^{-1}$ ) de las cepas de los 5 tratamientos de riego (T100, T50, T25, T0 y T25-S) en el año 2021 a), c), e) y en el año 2022 b) y d)

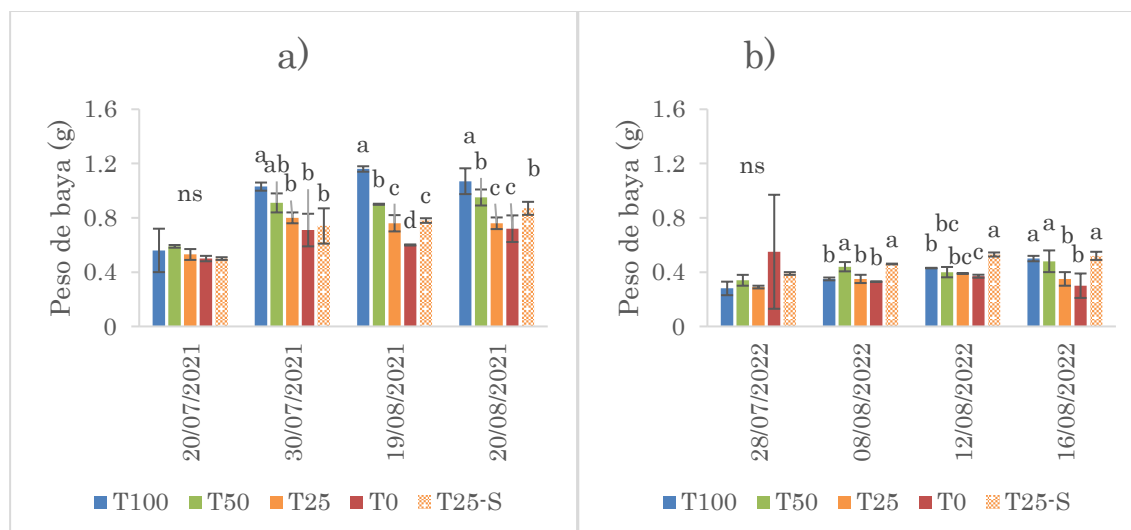


Figura 4.3.9: Seguimiento de maduración. Peso de baya (g) de las cepas de los 5 tratamientos de riego (T100, T50, T25, T0 y T25-S) en el año 2021 a) y en el año 2022 b)

#### h) Producción y calidad en la vendimia

En la tabla 4.3.4 se muestran los parámetros de calidad y rendimiento en fecha de vendimia de ambos años. En el año 2021 no se observaron diferencias significativas entre tratamientos, a excepción del peso de baya. En el año 2022 se observaron diferencias significativas entre tratamientos en peso de baya y °Brix.

Con respecto a los °Brix en 2021 se diferenciaban dos grupos, más regados y menos regados, sin embargo, el T25-S mostraba características de ambos grupos. Los °Brix disminuyeron de media en todos los tratamientos un 21% en el 2022 con respecto a los valores del 2021.

En 2021 se podían clasificar los tratamientos de riego en cuanto a peso de baya en tres grupos. Separándose el más regado T100, seguido de T50 y T25-S, y finalmente quedando los valores más bajos de peso de baya T0 y T25. En 2022 el T100 presentaba una reducción en el peso de baya del 53% con respecto a la vendimia del año anterior.

En producción no hubo diferencias significativas entre tratamientos en las dos campañas evaluadas, sin embargo, entre años, se observa una diferencia de un 40% de media superior en el 2022 con respecto al 2021.

Tabla 4.3.4. Vendimia: Producción (Prod), peso de la baya (B) y calidad del mosto; contenido de sólidos solubles (SST); pH; acidez total (TA) de las cepas de los 5 tratamientos de riego en el año 2021 y 2022. Cada valor representa una media de seis cepas por tratamiento de riego DE, desviación estándar.

<b>2021</b>	<b>T100</b>	<b>T50</b>	<b>T25</b>	<b>T0</b>	<b>T25-S</b>
Prod (Kg)	1.83	1.28	1.46	1.14	1.53 ns
DE	0.22	0.51	0.53	0.49	0.96
B (g)	1.07 a	0.95 b	0.76 c	0.72 c	0.87 b *
DE	0.09	0.06	0.04	0.10	0.05
SST (° Brix)	28.50	29.13	30.03	32.08	31.80 ns
DE	0.87	1.10	0.46	2.20	4.10
pH	3.53	3.58	3.62	3.67	3.58 ns
DE	0.04	0.06	0.15	0.09	0.08
TA (g de tartárico L-1)	5.39	5.01	4.95	4.89	5.24 ns
DE	0.04	0.24	0.59	0.32	0.20
<b>2022</b>	<b>T100</b>	<b>T50</b>	<b>T25</b>	<b>T0</b>	<b>T25-S</b>
Prod (Kg)	2.71	2.39	1.54	1.37	2.21 ns
DE	0.87	0.95	0.65	1.08	0.58
B (g)	0.50 a	0.48 a	0.35 b	0.30 b	0.52 a*
DE	0.02	0.08	0.05	0.09	0.03
SST (° Brix)	23.13 cd	22.34 d	24.68 ab	25.65 a	24.07 bc*
DE	1.0	1.1	0.6	1.5	0.8
pH	3.78	3.69	3.74	3.63	3.65 ns
DE	0.10	0.14	0.12	0.07	0.04
TA (g de tartárico L-1)	5.39	5.01	4.95	4.89	5.24 ns
DE	0.04	0.24	0.59	0.32	0.20

Niveles de significancia estadística: ns, no significativo; medias con letra distinta son significativamente diferentes  $p < 0.05$

### 4.3.3 Caracterización de las cepas mediante sensores térmicos a bordo de UAS

#### 4.3.4.1 Evaluación de los indicadores térmicos

##### a) Diferencia entre temperatura de la cepa y del aire

En la Figura 4.3.10 se observa la evolución del indicador considerado de referencia para este estudio, la temperatura de la copa de las cepas obtenidas con el UAS y la temperatura del aire dentro de la cepa (Tc-Ta).

Tc-Ta osciló entre  $-1.5$  (9:00, 25/06/2021) y  $12^{\circ}\text{C}$  (12:00, 12/08/2022). El Tc-Ta en 2022 fue  $1.5$  y  $4^{\circ}\text{C}$  más alto que en 2021 a las 9:00 (Fig. 4.3.10a) y 12:00 (Fig. 4.3.10b) respectivamente. El Tc-Ta fue afectado significativamente por el tratamiento de riego. En 2022, Tc-Ta en T100 fue  $3^{\circ}\text{C}$  y  $5.4^{\circ}\text{C}$  más alto que en 2021 a las 9:00 y 12:00, respectivamente.

T100 y T50 no mostraron diferencias significativas en la mayoría de las mediciones, y los valores fueron bastante similares. T0 y T25 mostraron los valores más altos,  $11.5$  y  $10.2^{\circ}\text{C}$ , respectivamente, a las 12:00 en 2022. Los tratamientos T100, T50 y T25-S mostraron valores similares a las 12:00 en 2022.

El aumento de 2021 a 2022 en la media anual de todos los tratamientos fue de  $1.4$  y  $4.3^{\circ}\text{C}$  a las 9:00 y 12:00, respectivamente.

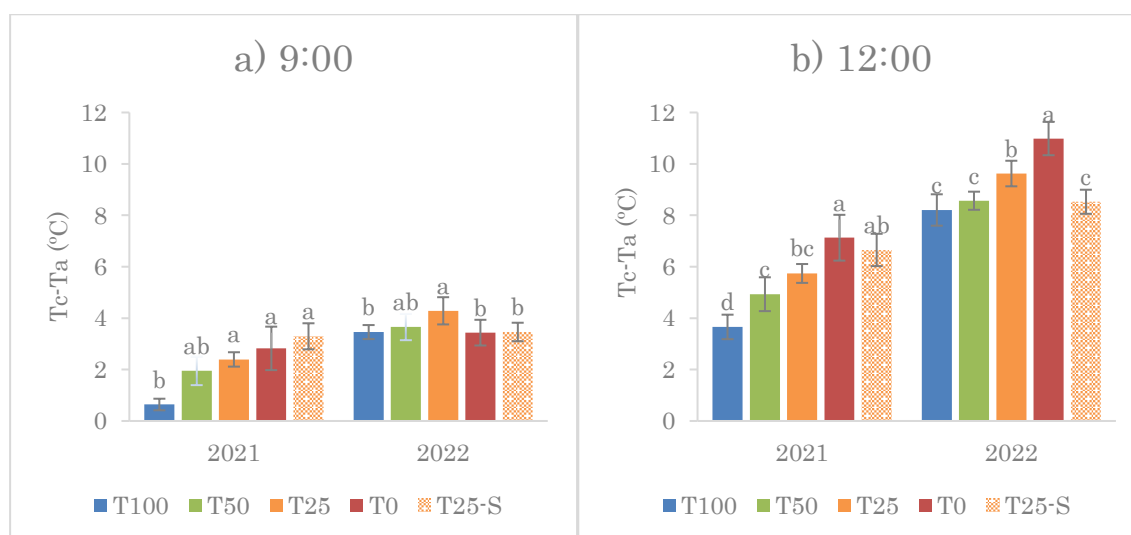


Figura 4.3.10. Evolución de Tc-Ta por tratamientos de riego (T100, T50, T25, T0 y T25-S) a las 9:00 a) y 12:00 b) en dos años (2021 y 2022)

## b) Índices de estrés (CWSI)

La Figura 4.3.11 muestra la evolución de los índices térmicos calculados para determinar el estado hídrico del agua.

CWSI<sub>J</sub> osciló entre -0.04 (9:00, 25/06/2021) y 2.03 (12:00, 12/08/2022). En 2021, se observaron diferencias significativas entre los tratamientos a las 12:00 (Fig. 4.3.11b). Estas diferencias no se observaron en otros momentos de medición. El valor más alto se observó en T0 a las 12:00 en 2022 (1.56). Los tratamientos T100, T50 y T25 mostraron valores similares a las 12:00 en 2021.

CWSI<sub>W</sub> osciló entre 0.43 (9:00, 25/06/2021) y 1.47 (12:00, 12/08/2022). Se observaron diferencias significativas entre los tratamientos a las 12:00 en ambos años. Sin embargo, estas diferencias no se observaron a las 9:00 en ningún año (Fig. 4.3.11c). T100 fue significativamente diferente al resto de los tratamientos a las 12:00 en 2021. T0 mostró los valores más altos a las 12:00 en 2021 (1.14) y 2022 (1.33). Los tratamientos T100, T50 y T25-S mostraron valores similares a las 12:00 en 2022.

CWSI<sub>B</sub> osciló entre 0.17 (9:00, 25/06/2021) y 1.45 (12:00, 30/06/2022). Se observaron diferencias significativas entre los tratamientos a las 12:00 en ambos años. En 2022 a las 9:00 no se observaron diferencias significativas (Fig. 4.3.11e). El valor más alto se observó a las 12:00 en T0 en 2021 (0.99) y 2022 (1.25). T25-S mostró valores similares a T100 y T50 a las 12:00 en 2022.

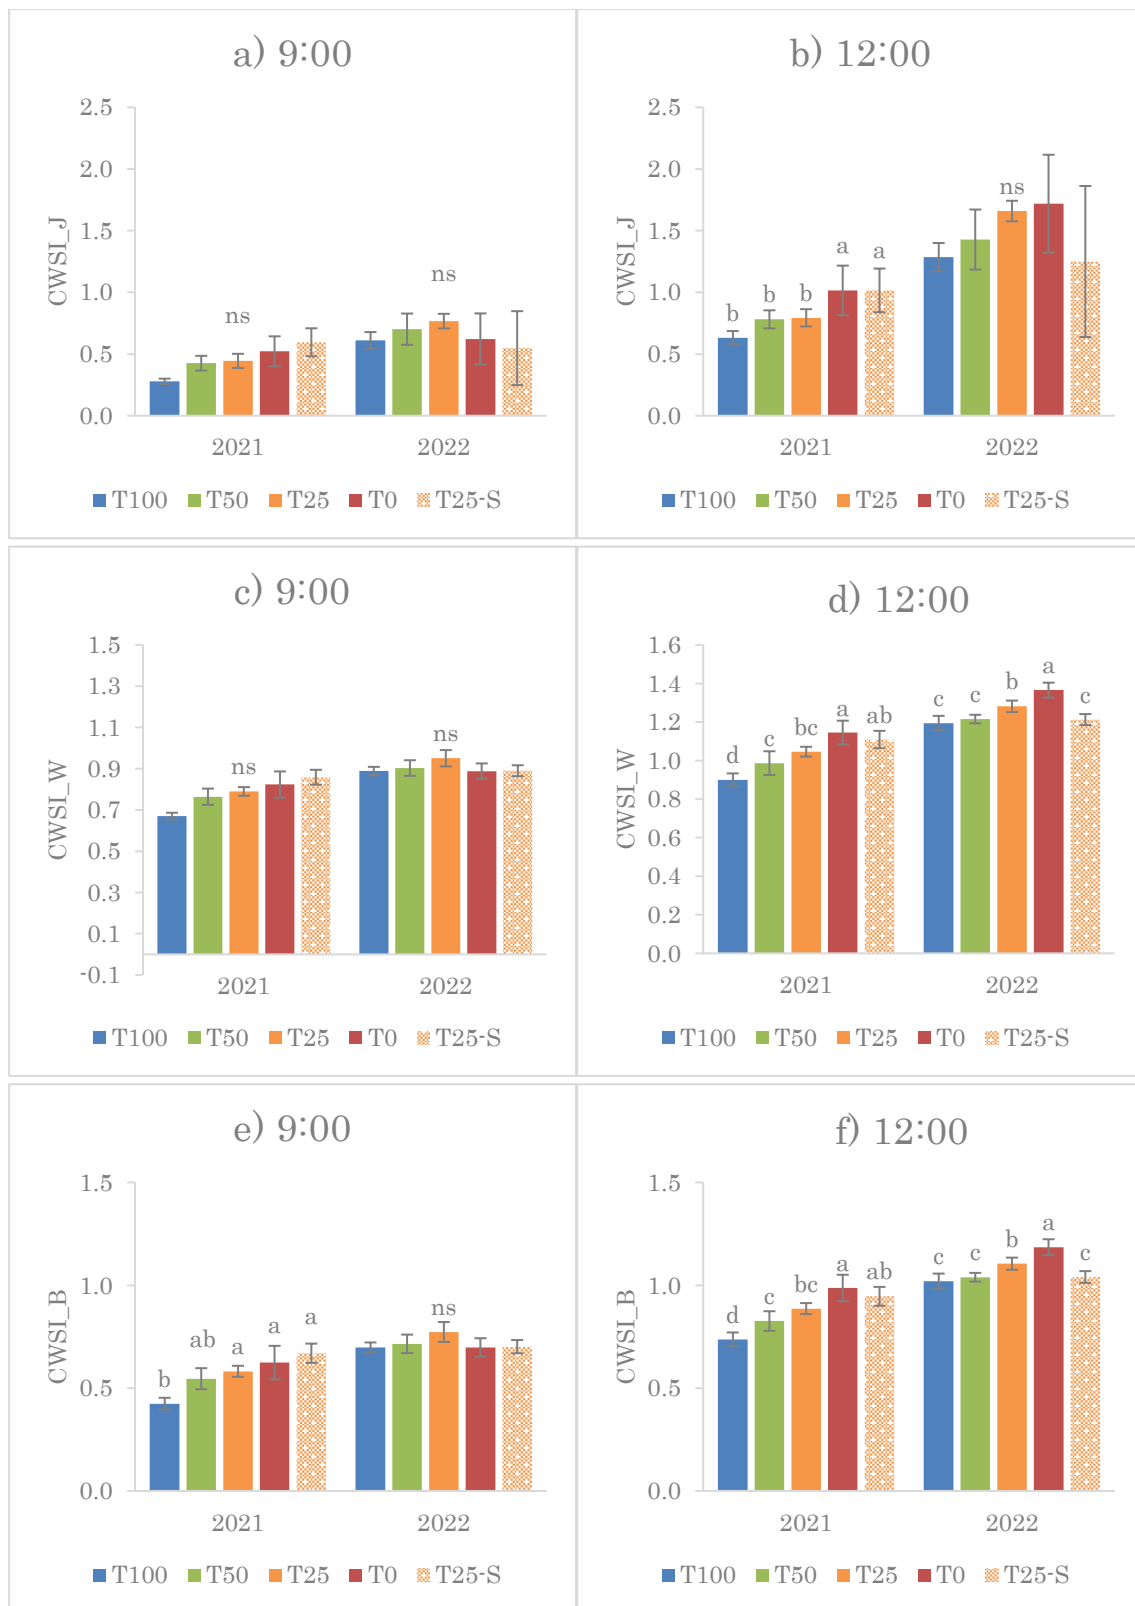


Figura 4.3.11. Evolución de modelos CWSI (CWSI\_J, CWSI\_W, CWSI\_B) por tratamientos de riego (T100, T50, T25, T0 y T25-S) a las 9:00 y 12:00 en dos años (2021 y 2022)

#### 4.3.4.2 Relación entre los indicadores térmicos de la copa y el estado hídrico de las plantas

La regresión lineal entre PHT e índices térmicos se empleó para evaluar su potencial para estimar el estado hídrico de las cepas. Todos los índices térmicos funcionaron mejor a las 12:00 que a las 9:00. Entre ellos, el CWSI\_J a las 12:00 tuvo la correlación más significativa con PHT ( $R^2=0.70$ ) (Fig. 4.3.12 d). Le siguió el índice de referencia  $T_c-T_a$  ( $R^2=0.50$  a las 12:00) (Fig. 4.3.12 b), mientras que los otros dos índices: CWSI\_W (Fig. 4.3.12 f) y CWSI\_B (Fig. 4.3.12 h) tuvieron un rendimiento inferior con valores similares de  $R^2$  a las 12:00 (0.41 y 0.40, respectivamente). Sin embargo, las correlaciones entre los índices térmicos y  $g_s$  fueron más bajas, con  $R^2$  que variaban de 0.11 a 0.27 (datos no mostrados).

Se calculó una matriz de correlación entre todos los indicadores o índices y los parámetros fisiológicos ( $g_s$  y PHT). La Figura 4.3.13 y 4.3.14 nos permite visualizar todas las relaciones positivas y negativas posibles entre los indicadores medidos y estimados y su fuerza.

La correlación más alta para PHT fue con TL ( $r=-0.81$ ) a las 9:00 (Fig. 4.3.13). Sin embargo, la mayor correlación para PHT a las 12:00 fue con CWSI\_J y  $T_c$  ( $r=-0.71$ ) (Fig 4.3.14). PHT tuvo correlaciones significativas con TL y CWSI\_J en ambas horas. Respecto a  $g_s$ , las correlaciones más altas fueron con TL y  $TL-T_a$  en ambas horas, que oscilaron entre  $r=-0.73$  y  $r=-0.77$ .

En general, PHT mostró una correlación más alta con todos los parámetros a las 12:00 que a las 9:00, excepto por TL, que fue más alta a las 9:00, y con CWSI\_J(TL), que no mostró correlación a las 12:00. En cuanto a  $g_s$ , fue similar a PHT, mostró una correlación más alta con todos los parámetros a las 12:00 que a las 9:00, excepto por TL y  $T_c$  que fueron más altos a las 9:00.

Se obtuvieron correlaciones más altas con los índices térmicos con PHT que con  $g_s$ .

Por otro lado, la correlación entre  $g_s$  y PHT es más alta a las 9:00 ( $r=0.64$ ) que a las 12:00 ( $r=0.49$ ).

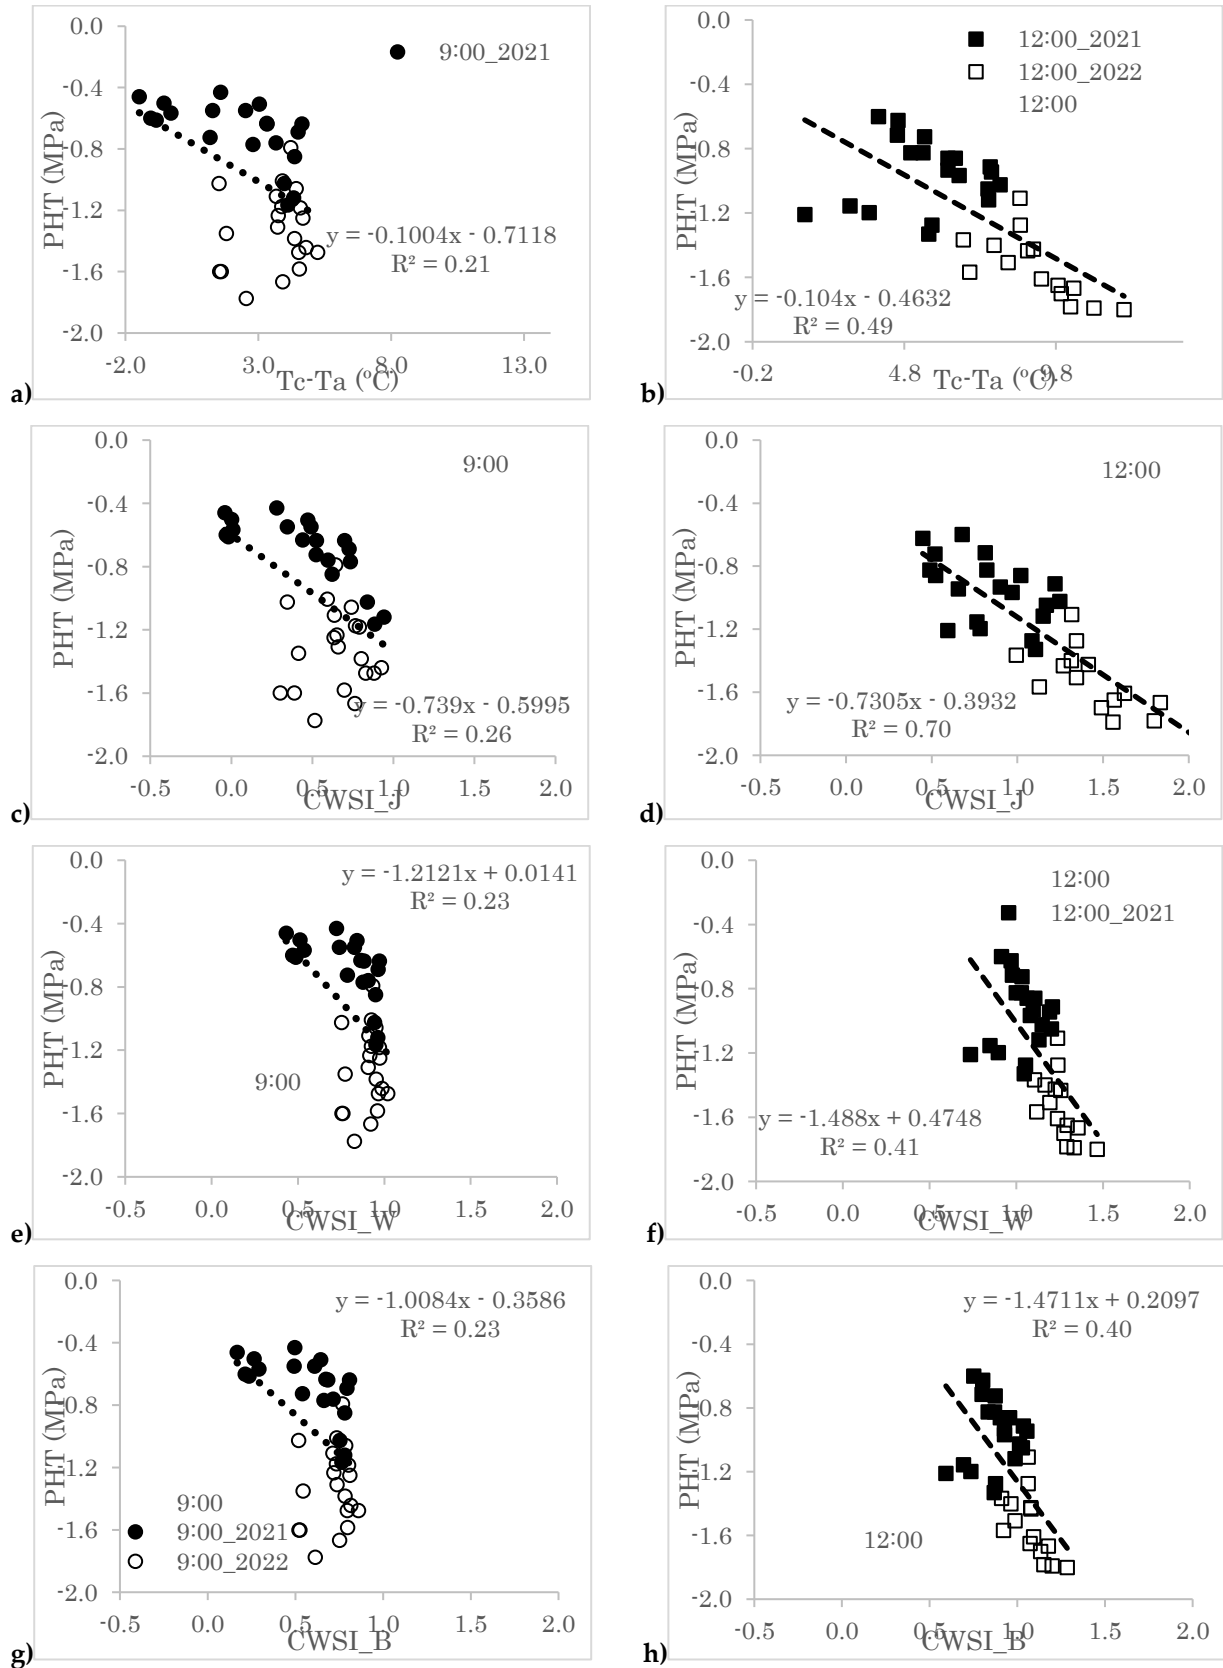


Figura 4.3.12. Relación entre los indicadores térmicos y el Potencial Hídrico del Tronco (PHT) a las 9:00 en 2021 (círculos rellenos) y 2022 (círculos) y a las 12:00 en 2021

(rectángulos rellenos) y 2022 (rectángulos). La línea discontinua es la relación media de ambos años y horas.




Figura 4.3.13: Matriz de correlación de Pearson para indicadores térmicos y parámetros fisiológicos a las 9:00.




Figura 4.3.14: Matriz de correlación de Pearson para indicadores térmicos y parámetros fisiológicos a las 12:00.

## 5 Discusión

Las condiciones climáticas adversas de los últimos años han enfrentado a los viticultores a períodos de sequía cada vez más frecuentes. La evaluación del estado hídrico de la vid se ha convertido en una herramienta cada vez más importante para adaptar las prácticas agronómicas y la monitorización del riego.

El clima afecta el estado hídrico de la vid a través de la lluvia y la evapotranspiración de referencia del cultivo (ET<sub>o</sub>) (Leeuwen et al 2009).

El estrés hídrico puede afectar negativamente el crecimiento vegetativo, el rendimiento, la composición de la uva y los atributos sensoriales del vino (Chapman et al. 2005; Chaves et al. 2007; Ojeda et al. 2002). Por lo tanto, optimizar el riego es un tema clave de investigación y una prioridad para la mayoría de los países vitivinícolas (Baluja et al.,2012).

La vid (*Vitis vinifera* L.) es uno de los cultivos más abundantes e importantes del planeta. Se adapta bien a climas semiáridos o áridos y, por lo tanto, se considera una especie tolerante al déficit hídrico (Chacón-Vozmediano et al.,2020), sin embargo, a lo largo de este estudio se observó los efectos adversos que un estrés hídrico prolongado puede provocar en una vid de la variedad Merlot. Los datos de partida ya sugerían que este cultivo se encontraba bajo restricciones hídricas importantes; ubicado en una zona semiárida como lo es la zona de Castilla la Mancha (España) con escasas precipitaciones anuales y aportaciones de riego deficitaria llevadas a cabo por la bodega.

A lo largo de dos años agroclimáticamente diferentes pudimos observar la respuesta de la vid al estrés hídrico. Tanto a nivel agronómico como nivel fisiológico, los dos años influyeron en gran medida en el comportamiento de la vid. Cuando ocurren situaciones de déficit hídrico, la vid reacciona limitando el crecimiento del área foliar y el rendimiento para favorecer la absorción de agua y minimizar las pérdidas (Santesteban et al.,2012; Acevedo-Opazo., et al 2008; Baeza et al., 2019)

La evaluación de la respuesta de la vid mediante teledetección constituye una contribución significativa de este estudio, complementando trabajos previos que han analizado el potencial de las cámaras térmicas y/o multiespectrales a bordo de UAS (Gennaro et al; 2022; Berry et al.,2023; Zarco-Tejada et al., 2013; Poblete-Echeverría et al 2017; Tanda y Chiarabini, 2019, Lopez-García et al., 2021). No sólo es crucial determinar en qué medida el aporte de los diferentes sensores permite definir mejor el estado hídrico de la vid, que en última estancia es el principal factor que influye en el desarrollo de las plantas, sino el momento del día y el efecto de las condiciones ambientales. Esta información es relevante a la hora de programar los vuelos con UASs.

La variabilidad intra-interparcelaria es uno de los principales retos a la hora de mapear el estado hídrico de las plantas. Evaluar índices que puedan determinar el

estado hídrico de cepas plantadas en suelos distintos o de cepas con distintas aplicaciones de riego, que influyen a su vez en la expresión vegetativa de la vid, es uno de los objetivos desarrollados en los dos ensayos presentados.

## 5.1 Discusión Ensayo 1: Caracterización de suelo

La zonificación del suelo en viñedos puede realizarse a diferentes escalas según el objetivo. A menudo, el suelo presenta una notable variabilidad espacial; esta variabilidad del suelo sería difícil de mapear a pequeña escala (Leeuwen et al., 2012).

La interpretación fotográfica nos permitió establecer una clasificación preliminar de siete suelos diferentes en la zona de estudio (Figura 4.2.1). La información extraída de la descripción de suelos en el campo nos ayudó a ajustar la zona de estudio para considerar solo dos tipos de suelos: C1 y C2 (Figura 4.2.3) Los suelos diferían en algunas características esenciales, como la textura y la profundidad. Las diferencias en estos parámetros entre horizontes afectaron significativamente el desarrollo de la vid, especialmente la capacidad de retención de agua.

En parcelas sin riego, las características del suelo influyen directamente en el estado hídrico de la vid, el rendimiento y la composición de la fruta (Bodin y Morlat, 2006; Van Leeuwen et al., 2004). Bajo condiciones de riego, el efecto de las propiedades del suelo en el estado hídrico de la vid no debería ser fuerte, ya que el suministro de agua a la planta está garantizado más por el riego que por el reservorio de agua en el suelo (Bellvert et al., 2012). El área de estudio se caracterizaba por un régimen de riego deficitario, bajas precipitaciones y alta demanda evaporativa. Se observó una marcada diferencia en la disponibilidad de agua entre los dos años de estudio, lo que provocó una heterogeneidad temporal. La lluvia + riego se redujo un 49% en 2022 en comparación con 2021 (Tabla 3.3.1 y Figura 4.1.1), bajo estas condiciones, la capacidad de retención de agua en el suelo se convierte en un parámetro decisivo para el desarrollo de las plantas. Inicialmente, el suelo C1 tenía un 43% más de capacidad de retención de agua que C2 (Tabla 4.2.4). Los valores promedio de capacidad de retención de agua en C1 y C2 fueron de 175 y 122 mm, respectivamente, considerándose valores dentro de un rango medio (Leeuwen et al., 2009). La capacidad de retención de agua en el suelo se ve afectada por la presencia de elementos gruesos como el contenido de grava (Sirera., et al 2021). Sin embargo, la grava no influyó negativamente en los suelos de estudio. El contenido promedio de grava en los horizontes de C1 fue un 74%

mayor que en C2. Se observó que las principales diferencias entre los suelos, que influían en la capacidad de retención de agua, eran el mayor contenido de materia orgánica y el mayor porcentaje de texturas más finas (arcilla y limo) en C1 en comparación con C2. El agua del suelo se almacena en la porosidad, por lo tanto, el tamaño de los poros, que viene determinada por la textura, tiene una gran influencia en la disponibilidad de agua para las plantas. Sirera et al., (2021) compararon las medidas cuantitativas de la capacidad de retención de agua del suelo para dos suelos en pendientes opuestas y obtuvo resultados similares. Encontró que los suelos con textura fina y mayor porcentaje de materia orgánica presentaban mayor capacidad de retención de agua debido a una mayor porosidad de los suelos.

El suelo y las condiciones climáticas durante los dos años de estudio afectaron el desarrollo de las cepas, especialmente en 2022, un año particularmente seco debido a la reducción de las precipitaciones y a una disminución del riego del 39%.

El buen desarrollo vegetativo de la vid afecta considerablemente al rendimiento y la calidad de la fruta (Hall et al 2003). Por tanto, las medidas del dosel de la vid pueden utilizarse para estimar diferencias en el rendimiento y la calidad de la fruta. Un desarrollo vegetativo deficiente influye directamente en el rendimiento y los parámetros de madurez. Este se observa claramente en el seguimiento de maduración para ambos años (Fig 4.2.5). Las condiciones de alto estrés hídrico afectaron principalmente en la reducción del tamaño de las bayas y de los °Brix. En condiciones climáticas normales como las observadas en 2021, las cepas de C1 tuvieron mejores rendimientos en cuanto al número de racimos en comparación con las cepas de C2. A medida que el déficit hídrico aumenta (valores más bajos del potencial hídrico de la vid), se observó que los parámetros de rendimiento en cuanto a calidad y producción disminuyeron.

El potencial hídrico del tronco (PHT) representa el estado hídrico completo de la vid y es una herramienta particularmente útil para la gestión del riego. En 2021, las cepas estudiadas mostraron un déficit hídrico moderado (Leeuwen et al 2009) con valores promedio de PHT de -0.99 y -1.04 MPa para las mediciones del mediodía en las cepas de C1 y C2, respectivamente. Sin embargo, en 2022, los valores de PHT fueron de -1.43 y -1.47 MPa en las cepas de C1 y C2, respectivamente, presentando un déficit hídrico severo debido al aumento de las condiciones de evaporación y reducción del riego.

La limitación en la absorción de agua de la vid podría reducir el crecimiento de los brotes y por tanto el rendimiento. Las cepas de C2 con menor vigor en 2021, en términos de contorno y mayor porosidad (Tabla 4.2.7), resistieron las condiciones de déficit en 2022, presentando un desarrollo vegetativo y rendimiento similar a las cepas C1 en 2022 (Tabla 4.2.7, 4.2.8). Sin embargo, las cepas de C1 mostraron un contorno, volumen, superficie foliar externa menor y un aumento de los poros en el dosel en 2022 en comparación con 2021, es decir un menor desarrollo vegetativo.

Según Hall et al (2003) el vigor puede manifestar el efecto de los factores ambientales y el manejo en las cepas. El vigor se puede mapear fácilmente utilizando índices de vegetación como herramienta de zonificación. Los índices NDVI, RVI, OSAVI, GNDVI y NDRE indicaron diferencias entre las cepas de C1 y C2 en 2021. En 2021, los valores promedio anuales del NDVI, RVI y NDRE fueron significativamente diferentes entre las cepas de C1 y C2 (Tabla 4.2.10). C1 presentó valores más altos para cada índice de vegetación (IVs) y fecha, correspondiendo a un mayor desarrollo vegetativo. Excluyendo NDRE, el promedio de las cepas de C2 en 2021 fue ligeramente mayor que el de las cepas de C1. Los valores de IVs en 2022 no mostraron diferencias significativas entre las cepas. Sin embargo, debido a que no hubo una tendencia clara entre los valores de NDRE para las cepas de C1 y C2 durante los dos años del estudio, no se pueden sacar conclusiones.

Los valores de RVI de las cepas mostraron un comportamiento inusual. A diferencia de los otros índices, se observó una tendencia en los valores de RVI en 2021. Al comenzar la temporada, los valores para las cepas de ambos suelos fueron más altos, pero disminuyeron a medida que avanzaba la temporada. Este índice mostró el valor más bajo en el último día (18/08/2021), cerca de la cosecha. En general, el RVI mostró mayores diferencias entre los valores de IVs evaluados en términos del promedio anual. En las cepas de C1, el RVI fue un 22% más alto que en las cepas de C2. En 2022, aunque la diferencia fue menos evidente, el índice mostró una tendencia similar. Al principio de la temporada, los valores de RVI fueron más altos (pero más bajos en comparación con el inicio de 2021). Estos valores se mantuvieron estables durante las fechas intermedias (15/07/2022 y 05/08/2022) y luego disminuyeron, al igual que lo observado en 2021. Pádua et al (2019) observó la variabilidad de los índices de las cepas a través de una campaña de vuelos en su zona de estudio. Observó una disminución general del NDVI a partir del tercer vuelo de la campaña. Esto se relacionó con el ciclo vegetativo de

las cepas. La etapa de madurez de la hoja explicó mejor la reducción en los valores de IVs que la disminución del vigor.

En general NDVI y RVI mostraron diferencias significativas entre las cepas de ambos suelos en 2021, probablemente por la relación entre las bandas NIR y RED que se usan en estos índices. En el caso del OSAVI que también usa las mismas bandas, el parámetro de corrección de suelo usado (0.16) quizás influyó de forma negativa en los valores de reflectancia. Por otro lado, en condiciones de aridez como las presentadas en 2022, ningún índice vegetativo pudo determinar diferencias entre ambos grupos de cepas (Tabla 4.2.11).

Al igual que los IVs reflejan las diferencias en el desarrollo vegetativo de las cepas, se pudo observar, mediante bandas multiespectrales, diferencias entre los dos suelos estudiados (Figura 4.2.7). Los valores de las bandas NIR, RedEdge y verde diferenciaron mejor los suelos en ambos años. La banda roja no presentó diferencias entre los dos suelos, especialmente en 2021. Los valores de las bandas multiespectrales obtenidas de los suelos presentaron un comportamiento diferenciado para cada tipo de suelo, esto sugiere que las propiedades del suelo pueden influir en una mayor o menor absorción de radiación para cada banda. La combinación de características fundamentales del suelo tiene matices que pueden causar firmas espectrales en las regiones visible y NIR, lo que hace que estas regiones sean potencialmente útiles para determinar muchos componentes del suelo (Ge et al 2011). López-Granados et al., (2005) observó una correlación entre propiedades físicas, como el porcentaje de arcilla y arena, con la banda verde visible. Estos hallazgos validaron las diferencias observadas en los valores de IVs, donde el GNDVI mostró variaciones significativas entre suelos en comparación con el NDVI o RVI, principalmente debido a la influencia de la banda verde (Figura 4.2.8). Para comprender esto, se deben considerar las variaciones en la textura del suelo entre los suelos estudiados. Específicamente, C1 tiene un contenido de arcilla más alto en sus horizontes superficiales que C2 (Tabla 4.2.2) por lo que quizás fue más notable las diferencias entre ambos suelos usando índices que contienen la banda verde.

Se obtuvieron datos de sensores térmicos sobre UAS para complementar la información del suelo (Tabla 4.2.9). La temperatura del suelo depende del balance de energía, que está relacionado con el color del suelo y el albedo (proporción de luz solar reflejada en el suelo), la pendiente y la dirección de la pendiente (Van Leeuwen et al, 2018). Puede medirse, pero debido a que es espacial y temporalmente variable, es desafiante calcularlo como un indicador relevante. Los

suelos cálidos y fríos pueden identificarse mediante una evaluación por expertos, ya que los suelos cálidos tienden a tener una textura gruesa y una alta presencia de elementos gruesos (Van Leeuwen et al, 2018; Ferrer et al 2020). Así, C1 fue más frío que C2, con una diferencia de 2.5 °C en verano. Se observó el valor máximo el 20/07/2021, con una diferencia de 3 °C. Por un lado, esto sugirió que más que los elementos de grava presentes en C1, la textura fina o el color podrían haber influenciado la temperatura más baja. Por otro lado, el color del suelo puede haber tenido una influencia, ya que C1 era un suelo más claro, reflejaba más energía y, por lo tanto, se calentaba menos que el suelo más oscuro de C2.

Estos resultados indicaron la efectividad de utilizar UASs para contribuir en diferencias de manejo basado en las diferencias entre los suelos de una misma parcela.

Muchos estudios se han centrado en caracterizar la variabilidad del viñedo usando IVs obtenidos de imágenes de alta resolución, como es el uso del NDVI para delinear áreas con vigor heterogéneo dentro de los viñedos, que corresponden con diferentes desempeños de las plantas (Hall et al., 2003; Ferrer et al 2020; Tagarakis et al., 2013; Baluja et al 2012; Kasimati et al 2023) Sin embargo, este estudio ha demostrado que, bajo condiciones de estrés severo, la variabilidad de las cepas podría pasar desapercibida. Los mapas de rendimiento o mapas de zonas de manejo basados en el crecimiento vegetativo de las cepas deberían considerarse solo bajo condiciones no estresantes. Es por ello por lo que debe tomarse en consideración la información del suelo a nivel de muestreo y a nivel de teledetección mediante imágenes de alta resolución para realizar mapas de zonificación más precisos.

## **5.2 Discusión Ensayo 2: Caracterización estado hídrico de las plantas**

El estado hídrico de las plantas se ve influenciado directamente por el riego. En condiciones climáticas normales el efecto del riego puede ser evaluado como una fuente de variabilidad en el desarrollo de la vid.

Durante el primer año de estudio (2021), las condiciones climáticas en cuanto a temperatura y evapotranspiración estuvieron en el promedio histórico de la zona (Figura 4.1.1). Esta situación favoreció el efecto del riego en el estado hídrico de la

vid. Tanto a nivel agronómico como a nivel fisiológico el efecto de los diferentes tratamientos de riego fue observado. Sin embargo, bajo condiciones de alta demanda evaporativa y poca disponibilidad de riego (2022), los tratamientos de riego se vieron más afectados.

En las cepas de estudio, los valores de PHT más bajos fueron alcanzados por el tratamiento en secano para ambas horas y años, llegando a valores de  $-1.8\text{MP}$  a las 12:00 (Figura 4.3.2) considerado estrés severo (Van leeuwen, et al.,2008).

Uno de los resultados más destacados con respecto a los tratamientos es la evolución del PHT entre los años, las condiciones de estrés hídrico fueron tan elevados en el 2022 que en las medidas de la mañana las cepas del tratamiento más regado presentaban un estado de déficit fuerte y el resto de tratamiento déficit severo (por debajo de  $-1.2\text{MPa}$ ). Un déficit severo de agua puede causar pérdidas en cantidad y calidad, y puede amenazar la longevidad de un viñedo al reducir las reservas de partes perennes (Pellegrino et al., 2014). Estas pérdidas se observaron en el seguimiento de maduración y vendimia donde, aunque haya habido una mayor producción en kilogramos (Tabla 4.3.9) el peso de baya (Figura 4.3.9b) y los grados brix (Fig 4.3.8b) se vieron afectados en el año de sequía.

En condiciones donde las restricciones hídricas son menos severas, como el que tuvo lugar en el año 2021, una mayor dosis de riego (T100) producirá un mayor peso de baya (Figura 4.3.9 a) y un menor rendimiento en azúcares comparado con el tratamiento en secano (T0) (Figura 4.3.8 a). El rendimiento y el crecimiento vegetativo son dos factores estrechamente relacionados; el rendimiento depende fundamentalmente de la actividad fotosintética de las hojas y, como consecuencia, de la cantidad de luz interceptada por el dosel de la vid. La disminución en el peso individual de las bayas debido a un aumento del déficit hídrico ha sido observada por otros autores como Acevedo-Opazo et al., 2008; Bellvert et al., 2015; Chacón-Vozmediano et al., 2020.

Otro de los aspectos agronómicos que influyen en el estado hídrico de la vid es el desarrollo foliar. En nuestro estudio, este parámetro no presentó grandes diferencias entre tratamientos (Tabla 4.3.2 y 4.3.3). Sin embargo, sí que se observó un cambio de un año a otro. En el año 2022 tuvo lugar un desarrollo vegetativo mayor, lo que junto a las altas temperaturas y poco riego influyó en gran medida en los altos niveles de estrés hídrico alcanzados. Las lluvias en primavera fueron mayores en 2022 comparadas con las de 2021, esto podría explicar que hubiese un mayor desarrollo vegetativo de casi el doble (las precipitaciones fueron el doble que

en 2021). El peso de poda en el año 2021 no presentó diferencias entre los tratamientos, algo similar fue observado por Intrigolo y Castel (2008) donde las viñas regadas y no regadas presentaron niveles similares de rendimiento con respecto al peso de la poda y las proporciones entre el área foliar, de manera que el riego no alteró el equilibrio entre la demanda de la vid y el suministro de agua. Sin embargo, entre años, se observa que sí que hubo una reducción en el peso de poda para el año 2022 en comparación con el 2021 para los tratamientos menos regados (Tabla 4.3.3)

Otro parámetro que se vio afectado fue la clorofila, en donde hubo una clara reducción en los promedios de cada tratamiento en el año 2021 con respecto al 2022 (Figura 4.3.5). Es importante considerar que el déficit hídrico afecta la disponibilidad y absorción de nitrógeno (Rienth y Scholasch 2019; Helwi et al., 2016) afectando finalmente a la concentración de clorofila. Menor disponibilidad de agua induce estrés en las plantas que lo que puede causar una reducción en la fotosíntesis y el crecimiento, también disminuyendo el contenido de clorofila (Berry et al., 2023)

Por todo lo anterior queda en evidencia la importancia de conocer el estado hídrico de la vid ya que afecta en el desarrollo fisiológico y agronómico de las plantas.

El uso de cámaras térmicas a bordo de UAS se presenta como una alternativa para la evaluación del estado hídrico de las plantas. En concreto, en este estudio se evaluaron técnicas de termografía para estimar el potencial hídrico del tronco (PHT). El PHT ha sido considerado agronómicamente como el indicador de referencia a la hora de estimar el estado hídrico de las plantas.

Los indicadores del estado hídrico basados en la temperatura radiométrica de UAS permitieron estimar el estado hídrico medido en un viñedo. Los vuelos se realizaron durante el período de riego (junio-agosto) cuando el DPV era alto y el dosel se encontraba completamente desarrollado.

CWSI como indicador de referencia, mostraba diferencias significativas en cuanto a las diversas formas de calcular los límites húmedos y secos, el momento del día y el año del estudio. El año 2022 fue más seco que el 2021, y las cepas alcanzaron una  $T_c-T_a$  máxima a las 12:00 (12.8°C) (Fig. 4.3.10b) y valores mínimos de PHT a las 12:00 (-2 MPa) (Figura 4.3.2) que se consideran estrés hídrico severo (Leeuwen et al. 2009), durante el cual los índices térmicos fueron menos sensibles a los cambios en PHT.

El CWSI basado en  $T_c$ , calculado usando el modelo de balance de energía (CWSI<sub>J</sub>) refleja el estado hídrico de toda la planta. De hecho, cuando el CWSI se estimó utilizando la temperatura de la hoja (CWSI<sub>J</sub> (TL)) (Fig. 4.3.13, 4.3.14) en lugar de  $T_c$ , se correlacionó mejor con la conductancia estomática (gs) una variable de estado hídrico medida a nivel de la hoja, mientras que al estimar CWSI<sub>J</sub> con  $T_c$ , se correlacionó mejor con PHT. Este indicador refleja el estado hídrico de toda la planta (Naor 2000).

Una dificultad general al evaluar indicadores basados en teledetección con datos de campo es la falta de correspondencia entre las escalas espaciales y las diferencias en los controles de los procesos a nivel de hoja y dosel. Por ejemplo, a nivel de hoja, TL mostró diferencias significativas entre las cepas de los tratamientos más regados y el resto de los tratamientos (Figura 4.3.6) y mejores correlaciones a las 9:00 con PHT que a las 12:00 al contrario de  $T_c$  (Fig. 4.3.14). TL también mostró buenas correlaciones con PHT y gs en ambos momentos (Fig. 4.3.13, 4.3.14). Sin embargo, la correlación de TL con PHT es menor al mediodía que entre  $T_c$  y PHT. Es crucial tener en cuenta que las mediciones de las hojas no representan bien el estado hídrico de toda la planta. Turner (1990), Hernández-Montes et al., (2020), Gates (1964) y Jones (2002) también observaron que TL era más susceptible a cambios debido a fluctuaciones en las condiciones ambientales que el estado hídrico de toda la planta. Estas diferencias entre  $T_c$  y TL también podrían atribuirse a la falta de correspondencia de escala entre ambas mediciones, desde el nivel de la hoja hasta la parte superior del dosel. Otro factor que influye en las diferencias entre TL y  $T_c$  podría estar relacionado con el hecho de que por la mañana hay más sombras en la imagen (Bellvert et al., 2015), que no se tuvieron completamente en cuenta en nuestras correcciones y el mayor error de la cámara térmica sin sistema de enfriamiento en comparación con los termopares.

Un hallazgo importante fue que el mediodía fue el mejor momento para obtener el CWSI, ya que se correlacionó mejor con PHT y gs en todas las metodologías aplicadas que a las 9:00 (Fig. 4.3.13). De hecho, se ha demostrado que el mejor momento del día para evaluar el estrés hídrico basado en  $T_c$  fue a las 12:00 (Ehrler et al., 1978). Esta observación se puede explicar por el papel significativo de  $T_c$  en el CWSI, ya que nuestro estudio es más sensible a las disminuciones en la disponibilidad de agua a las 12:00 en comparación con las 9:00. Así, para condiciones micro climáticas dadas,  $T_c$  depende principalmente de gs, que modifica las tasas de transpiración estrechamente relacionadas con el estado hídrico de la planta (Jackson 1982). Por la mañana,  $T_c$  fue más similar entre los tratamientos

de riego que al mediodía, ya que las plantas transpiran cerca de las tasas potenciales y los estomas están completamente abiertos debido a que la demanda evaporativa es mucho menor. Además, por la mañana, la actividad respiratoria afecta a la apertura y cierre de los estomas, afectando a la relación lineal negativa entre  $T_c$  y PHT (Gardner et al. 1981). Estos factores explican por qué  $T_c$  fue menos sensible a los cambios en PHT a las 9:00 en nuestro estudio (Figura 4.3.7), lo que llevó a un menor rendimiento de CWSI a las 9:00 (Fig. 4.3.11.a, c. e).

Hubo un claro efecto del año en la fisiología de la vid; en el año más cálido (2022), PHT fue notablemente más bajo que en 2021. Las plantas mostraron valores bajos y anómalos de PHT a las 9:00, similares a los observados al mediodía (Figura 4.3.2). Este efecto indicó un aumento del estrés hídrico durante la temporada 2022 en comparación con 2021, manteniendo la relación lineal CWSI-PHT en ambos años a las 12:00 (Fig. 4.3.12 b, d, f y h). Sin embargo, esta tendencia lineal fue menos evidente en la medida de las 9:00 en 2022. Se observó que más allá de un valor umbral, alrededor de  $-1.1$  MPa, en PHT y un CWSI cercano a 1 (cero transpiraciones), los índices térmicos a las 9:00 tendían a estabilizarse, volviéndose menos sensibles a las reducciones en PHT. Este umbral fue particularmente notable en los índices CWSI\_W y CWSI\_B (Fig. 4.3.12 e, g). Sin embargo, CWSI\_J y  $T_c$ - $T_a$  mostraron una mayor dispersión bajo estas condiciones (Fig. 4.3.12 a, c). Esto podría explicarse por su mayor sensibilidad a los valores de temperatura del aire. Nuestro estudio utilizó la temperatura del aire dentro del dosel, que podría verse afectada por cambios micro climáticos (Jones., 2002), en lugar de la temperatura a la altura de la estación (a 2 m de altura).

Se observó un valor umbral de PHT a las 9:00 ( $-1.1$  MPa) a partir del cual coincide un cierre estomático, derivado de la relación entre  $g_s$  medido y PHT (Fig. 4.3.4 a) (Pou, 2011; Rogiers et al., 2011), mostrando una relación no lineal. Este comportamiento no lineal entre PHT y  $g_s$  ha sido observado en otros cultivos, como el olivar (Ahumada-Orellana et al., 2019) y la vid (Gutiérrez et al., 2021).

Aunque la relación entre PHT y los diferentes índices basados en imágenes térmicas mostró una clara relación lineal al mediodía (Fig. 4.3.12), un comportamiento también observado por otros autores (Yuan et al., 2004; Bellvert et al., 2014; González-Dugo et al., 2014; Gutiérrez et al., 2021). Esta linealidad fue menos evidente a las 12:00 en 2021, especialmente para el índice  $T_c$ - $T_a$  (Fig. 4.3.12 b). Durante este año, hubo una fecha específica (30/06/2021) en la que PHT no se correlacionó bien con  $T_c$ , con un PHT por debajo de lo esperado según la relación lineal (datos no mostrados). Esto puede atribuirse al efecto de un DPV muy alto y

una alta demanda evaporativa ( $ETo$ ) en las tasas de transpiración y  $g_s$ , ya que la demanda evaporativa ese día fue la más alta durante todo el período de estudio, mientras que la humedad relativa fue la más baja (Tabla 4.1.1). Esta situación podría haber causado una alta tasa de transpiración debido a una alta difusividad de vapor y un alto  $g_s$ , especialmente en el tratamiento más regado ese día (datos no mostrados), reduciendo el PHT y causando que  $T_c$  y  $TL$  fueran más bajos de lo esperado para esos valores de PHT.

En nuestro estudio, para calcular el  $CWSI_B$ , seleccionamos la ecuación desarrollada por Bellvert et al. (2015) que utiliza  $DPV$  y  $T_c-T_a$  correspondientes a variedades de vid con comportamiento anisohídrico. En otras palabras, un control de  $g_s$  menos estricto. Sin embargo, en nuestro caso, las cepas parecían tener un comportamiento más isohídrico por la mañana (Fig 4.3.4 a) y anisohídrico al mediodía (Fig 4.3.4 b). Otros autores también han observado transiciones del comportamiento anisohídrico e isohídrico bajo condiciones de estrés hídrico (Lovisoló et al., 2010; Tombesi et al., 2014; Martínez-Vilalta y García-Forner 2017; Charrier et al., 2018; Levin et al., 2020; Gallo et al., 2022).

En última instancia, el  $CWSI$  indica tasas relativas de transpiración potencial; en este estudio lo hemos correlacionado como un proxy para PHT. Evaluamos el  $g_s$  derivado del modelo para evaluar la precisión de  $CWSI_J$  como indicador confiable. Comparamos  $g_s$  de la hoja medido con el  $g_s$  estimado por el modelo de Jackson alimentado con  $TL$  ( $g_{s\_model}(TL)$ ) y con  $T_c$  ( $g_{s\_model}(T_c)$ ) (Fig. 4.3.13 y 4.3.14

). Al utilizar el  $TL$  en lugar de  $T_c$ , las correlaciones mejoraron a las 9:00 h (de  $R^2=0.33$  a  $R^2=0.69$ ) y a las 12:00 h (de 0.55 a 0.58). Esto sugiere que el modelo  $CWSI$  de Jackson es razonable, pero que hay una falta de correspondencia entre los datos utilizados a una escala (dron - hojas en la parte superior del dosel) y aquellos utilizados para validar las hojas y aquellos utilizados para medir a nivel de hoja. Además, para escalar desde  $g_s$  medidos a nivel de hoja hasta  $g_s$  a nivel del dosel, habría que tener en cuenta los cambios en el LAI (Índice de Área Foliar) (Bu et al., 2021).

La robustez de los índices basados en la termografía depende de su capacidad para estimar el indicador fisiológico PHT en cualquier condición meteorológica o estado fenológico. Nuestros resultados confirman que índices térmicos simples como  $T_c-T_a$  pueden identificar niveles variables de hidratación del cultivo utilizando

valores de temperatura UAS ( $T_c$ ) a un nivel superior que CWSI\_B o CWSI\_W a las 12:00 h. Sin embargo, dicho índice es menos preciso en condiciones extremas de aridez, alto DPV y bajo PHT, y se desvían de las relaciones lineales. En cambio, CWSI\_J se presenta como una alternativa adecuada desde una perspectiva de cambio climático ante el aumento de calor y aridez, con un comportamiento robusto en diferentes días y momentos del día. Sin embargo, se requieren varios parámetros para estimar el CWSI\_J, como la temperatura del aire y del dosel, la resistencia aerodinámica y del dosel, la resistencia potencial del dosel, la emisividad del dosel, la radiación solar incidente y la radiación emitida. Se espera que las tecnologías emergentes o futuras permitan la adquisición más rápida y precisa de los parámetros del balance energético. En última instancia, es crucial considerar todos los parámetros climáticos involucrados para desarrollar metodologías o herramientas que permitan el monitoreo de cultivos bajo diferentes escenarios climáticos. Finalmente, será responsabilidad del agricultor evaluar el potencial de estos índices y tomar decisiones en función de las necesidades específicas de gestión del cultivo.

## 6 Conclusiones

A continuación, desglosamos las conclusiones obtenidas en los dos ensayos realizados para luego llegar a la conclusión general que da respuesta al objetivo de esta tesis doctoral.

### Ensayo 1: Caracterización de suelo

Este estudio puso en evidencia el papel del suelo como principal factor de la heterogeneidad espacial mientras que el clima fue el factor determinante en la heterogeneidad temporal.

La realización de mapas de zonificación mediante métodos de fotointerpretación junto análisis de suelo permitieron delimitar zonas de manejo homogéneas, sin embargo, son actividades que requieren tiempo y mano de obra especializada.

Como alternativa este estudio demostró el potencial que tiene la información obtenida de sensores remotos para la evaluación de la heterogeneidad de los cultivos. A través de la observación, a nivel de vegetación y de suelo, se pudo evaluar la heterogeneidad espacial y temporal de una forma más sencilla.

Las diferencias más significativas entre las cepas estudiadas fueron provocadas por la disponibilidad de agua entre años, en términos de precipitaciones y riego, influyendo en la heterogeneidad temporal. Esto a su vez influyó en la heterogeneidad espacial expresada en términos de capacidad de retención de agua. La capacidad de retención de agua del suelo es un parámetro decisivo que afecta al rendimiento de las cepas, principalmente en condiciones de riego limitado.

Los índices de vegetación lograron identificar diferencias en el desarrollo vegetativo entre las cepas del suelo C1 (Typic Calcixerepts) y las cepas del suelo C2 (Calcic Haploxeralfs) en el año 2021. Sin embargo, en condiciones de aridez como las que tuvo lugar en 2022, los índices no detectaron diferencias entre las cepas de los suelos estudiados. Esto resalta la necesidad de observar el suelo y no solo la vegetación para delimitar zonas de manejo.

Las imágenes espectrales de los suelos revelaron diferencias notables en ambos años de estudio, atribuibles a las propiedades físicas del suelo, como el color y la textura. Específicamente, las bandas espectrales de verde, borde rojo y NIR demostraron ser efectivas para distinguir los dos tipos de suelo.

Entre los índices de vegetación, el GNDVI mostró las mayores diferencias entre los tipos de suelo, subrayando su utilidad en la evaluación de la variabilidad del suelo.

La información térmica obtenida del suelo confirmó que los suelos con texturas más arenosas, como C2, registraron temperaturas 2.5 °C más altas que los suelos con texturas más finas, como C1. Estos hallazgos demuestran que la información térmica puede ser una herramienta valiosa para delimitar zonas con diferentes tipos de suelo, facilitando una gestión más precisa y adaptada de las parcelas agrícolas.

Independientemente de las condiciones climáticas, las características espectrales y térmicas del suelo son una fuente fiable de información, lo que las convierte en un elemento más robusto para la zonificación que la vegetación de la vid. Estos resultados confirmaron que los UAS son una herramienta valiosa para evaluar la heterogeneidad espacial y temporal y monitorear los viñedos con un gasto operativo mínimo. En cuanto a la aplicabilidad de la zonificación, la información espectral y térmica del suelo es esencial, ya que se ve influenciada mucho menos entre años que la información vegetativa.

### Ensayo 2: Caracterización del estado hídrico de las plantas

Los hallazgos de este estudio resaltaron la eficacia de los indicadores térmicos derivados de sensores montados en UAS. Estos indicadores son herramientas poderosas para evaluar el estado hídrico de las plantas, incluso bajo condiciones de estrés climático. Así, permite el uso de la gestión de riego de precisión.

El momento óptimo para obtener imágenes térmicas para el riego es alrededor del mediodía, cuando los índices térmicos y la relación PHT son más robustos. Sin embargo, las relaciones fueron más débiles en condiciones de alto estrés hídrico ( $PHT < -1.1$  MPa).

Tc-Ta y CWSI\_J fueron los índices térmicos que mejor detectaron la variabilidad de PHT dentro del viñedo. Los índices térmicos simples como Tc-Ta pueden identificar niveles variables de hidratación del cultivo utilizando los valores de temperatura del UAS (Tc) y calcularlo con mayor precisión que CWSI\_B o CWSI\_W a las 12:00. Se requieren pocos parámetros para calcular Tc-Ta. Sin embargo, bajo estrés hídrico severo debido al calor y la aridez, CWSI\_J se presenta como una alternativa adecuada desde una perspectiva de cambio climático con un comportamiento robusto en diferentes días y horas del día.

### Conclusión general

En este trabajo, hemos demostrado que la aplicación de sensores multiespectrales y térmicos a bordo de UASs ha permitido determinar diferencias significativas entre tipos de suelo y estimar con gran precisión el estado hídrico de un viñedo comercial. Esta metodología pone de relieve el valor de las imágenes de alta resolución para la creación de mapas de zonificación y del estado hídrico de la vid, proporcionando una herramienta potente para gestionar la variabilidad espacial y temporal en el campo.

Una de las novedades de este trabajo es poner en relieve la combinación de información térmica y multiespectral de los suelos para delimitar zonas de manejo. La discriminación de suelos obtenidas mediante la banda térmica o la banda verde puede ser un punto de partida relevante a la hora de realizar estudios de zonificación.

También se confirmó, una vez más, la relevancia de los índices de vegetación para evaluar el desarrollo de las plantas, principalmente en condiciones de aridez extrema.

En esta línea los posibles trabajos futuros deberían ir enfocado a la creación de algoritmos de clasificación que permitan discriminar suelos con información térmica y multiespectral.

Por otro lado, se obtuvo un índice térmico robusto que permite estimar el estado hídrico de la vid en cualquier escenario climático, poniendo en evidencia la novedad de este trabajo.

Estos resultados tienen implicaciones agrícolas comerciales a gran escala, donde se deben monitorear rápidamente cientos de hectáreas, se preferiría el uso de UAS de ala fija con mayor resistencia, velocidades de crucero moderadas y operación más sencilla. Se espera que las plataformas de teledetección basadas en UAS se conviertan en una herramienta clave para monitorear el estado hídrico de los cultivos, con el objetivo de realizar programaciones de riego en tiempo real y el monitoreo de cultivos.

Trabajos futuros puede ser la combinación de información obtenida de la geometría de las plantas mediante sensores lidar que permitan obtener parámetros necesarios para el cálculo del CWSI teórico de Jackson. El uso potencial de nuevas metodologías de teledetección basadas en sensores activos podría proporcionar un mejor conocimiento de la estructura del dosel de diferentes variedades y con

diferentes sistemas de conducción y ayudaría a refinar las estimaciones de algunos de los parámetros involucrados en esta metodología, como la resistencia aerodinámica y la radiación neta.

La frecuencia de adquisición de imágenes para tomar decisiones de riego requiere combinar la alta resolución de los drones con la resolución temporal de los satélites. En esta línea, la empresa UTW ha estado trabajando con técnicas de teledetección híbrida, combinando las ventajas de ambas plataformas. Si añadimos información referente a la geometría (usando sensores Lidar) y datos de estaciones climáticas establecidas en las propias parcelas, se podría ajustar los índices de estrés hídricos a cada parcela particular.

Un aporte relevante de este estudio para UTW, es el desarrollo de una metodología para la corrección de imágenes térmicas. Implementar estas correcciones puede reducir significativamente la necesidad de realizar mediciones en campo, optimizando así los recursos y mejorando la eficiencia operativa de la empresa.

Finalmente, se espera que un futuro los agricultores puedan ajustar los programas de riego combinando información de tipos de suelo con información de estrés hídrico de las plantas. Es decir, en zonas en las que se observe suelos más arenosos podrán programar riegos cortos y frecuentes y en zonas con suelos arcillosos, aplicar riegos más largos; esto unido a la información obtenida de mapas de potencial hídrico se conseguiría una mayor eficiencia en el uso del agua de riego.

## 7 Referencias

- Acevedo-Opazo, C., B. Tisseyre, S. Guillaume, and H. Ojeda. 2008. "The Potential of High Spatial Resolution Information to Define Within-Vineyard Zones Related to Vine Water Status." *Precision Agriculture* 9(5):285–302. doi: 10.1007/s11119-008-9073-1.
- Adamchuk, Viacheslav I., Richard B. Ferguson, and Gary W. Hergert. 2010. "Soil Heterogeneity and Crop Growth." Pp. 3–16 in *Precision Crop Protection - the Challenge and Use of Heterogeneity*. Dordrecht: Springer Netherlands.
- Acevedo-Opazo, C., B. Tisseyre, S. Guillaume, and H. Ojeda. 2008. "The Potential of High Spatial Resolution Information to Define Within-Vineyard Zones Related to Vine Water Status." *Precision Agriculture* 9(5):285–302. doi: 10.1007/s11119-008-9073-1.
- Adamchuk, Viacheslav I., Richard B. Ferguson, and Gary W. Hergert. 2010. "Soil Heterogeneity and Crop Growth." Pp. 3–16 in *Precision Crop Protection - the Challenge and Use of Heterogeneity*. Dordrecht: Springer Netherlands.
- Agencia Estatal de Meteorología, 2023. AEMET OpenData. URL <https://opendata.aemet.es/centrodedescargas/inicio> (accessed 10/05/2023)
- Ahumada-Orellana, L., S. Ortega-Farías, C. Poblete-Echeverría, and P. S. Searles. 2019. "Estimation of Stomatal Conductance and Stem Water Potential Threshold Values for Water Stress in Olive Trees (Cv. Arbequina)." *Irrigation Science* 37(4):461–67. doi: 10.1007/s00271-019-00623-9.
- Allen, R. G.; Hill; R.W.&Srikanth, V. (1994). 1994. "Evapotranspiration Parameters for Variably-Sied Wetland." American Society of Agricultural Engineers. Meeting (USA).
- Asrar, G., R. B. Myneni, and B. J. Choudhury. 1992. "Spatial Heterogeneity in Vegetation Canopies and Remote Sensing of Absorbed Photosynthetically Active Radiation: A Modeling Study." *Remote Sensing of Environment* 41(2–3):85–103. doi: 10.1016/0034-4257(92)90070-Z.
- Awais, M., W. Li, M. J. M. Cheema, Q. U. Zaman, A. Shaheen, B. Aslam, W. Zhu, M. Ajmal, M. Faheem, S. Hussain, A. A. Nadeem, M. M. Afzal, and C. Liu. 2023. "UAV-Based Remote Sensing in Plant Stress Imagine Using High-Resolution Thermal Sensor for Digital Agriculture Practices: A Meta-Review."

- International Journal of Environmental Science and Technology 20(1):1135–52. doi: 10.1007/s13762-021-03801-5.
- Baeza, Pilar, Patricia Sánchez-de-Miguel, Ana Centeno, Pedro Junquera, Rubén Linares, and José Ramón Lissarrague. 2007. “Water Relations between Leaf Water Potential, Photosynthesis and Agronomic Vine Response as a Tool for Establishing Thresholds in Irrigation Scheduling.” *Scientia Horticulturae* 114(3):151–58. doi: 10.1016/j.scienta.2007.06.012.
- Baluja, Javier, Maria P. Diago, Pedro Balda, Roberto Zorer, Franco Meggio, Fermin Morales, and Javier Tardaguila. 2012. “Assessment of Vineyard Water Status Variability by Thermal and Multispectral Imagery Using an Unmanned Aerial Vehicle (UAV).” *Irrigation Science* 30(6):511–22. doi: 10.1007/s00271-012-0382-9.
- Barbagallo, Maria Gabriella, Giuseppe Vesco, Rosario Di Lorenzo, Riccardo Lo Bianco, and Antonino Pisciotta. 2021. “Soil and Regulated Deficit Irrigation Affect Growth, Yield and Quality of ‘Nero d’Avola’ Grapes in a Semi-Arid Environment.” *Plants* 10(4). doi: 10.3390/plants10040641.
- Begg, John E., and Neil C. Turner. 1970. “Water Potential Gradients in Field Tobacco.” *Plant Physiology* 46(2):343–46. doi: 10.1104/pp.46.2.343.
- Bellvert, J., J. Marsal, J. Girona, and P. J. Zarco-Tejada. 2015. “Seasonal Evolution of Crop Water Stress Index in Grapevine Varieties Determined with High-Resolution Remote Sensing Thermal Imagery.” *Irrigation Science* 33(2):81–93. doi: 10.1007/s00271-014-0456-y.
- Bellvert, J., J. Marsal, M. Mata, and J. Girona. 2012. “Identifying Irrigation Zones across a 7.5-Ha ‘Pinot Noir’ Vineyard Based on the Variability of Vine Water Status and Multispectral Images.” *Irrigation Science* 30(6):499–509. doi: 10.1007/s00271-012-0380-y.
- Bellvert, J., P. J. Zarco-Tejada, J. Girona, and E. Fereres. 2014. “Mapping Crop Water Stress Index in a ‘Pinot-Noir’ Vineyard: Comparing Ground Measurements with Thermal Remote Sensing Imagery from an Unmanned Aerial Vehicle.” *Precision Agriculture* 15(4):361–76. doi: 10.1007/s11119-013-9334-5.
- Bellvert, Joaquim, Jordi Marsal, Joan Girona, Victoria Gonzalez-Dugo, Elías Fereres, Susan L. Ustin, and Pablo J. Zarco-Tejada. 2016. “Airborne Thermal Imagery to Detect the Seasonal Evolution of Crop Water Status in Peach,

- Nectarine and Saturn Peach Orchards.” *Remote Sensing* 8(1):1–17. doi: 10.3390/rs8010039.
- Benediktsson, Jon Atli, Jocelyn Chanussot, and Wooil M. Moon. 2012. “Very High-Resolution Remote Sensing: Challenges and Opportunities [Point of View].” *Proceedings of the IEEE* 100(6):1907–10. doi: 10.1109/JPROC.2012.2190811.
- Berger, Katja, Miriam Machwitz, Marlena Kycko, Shawn C. Kefauver, Shari Van Wittenberghe, Max Gerhards, Jochem Verrelst, Clement Atzberger, Christiaan van der Tol, Alexander Damm, Uwe Rascher, Ittai Herrmann, Veronica Sobejano Paz, Sven Fahrner, Roland Pieruschka, Egor Prikaziuk, Ma Luisa Buchailot, Andrej Halabuk, Marco Celesti, Gerbrand Koren, Esra Tunc Gormus, Micol Rossini, Michael Foerster, Bastian Siegmann, Asmaa Abdelbaki, Giulia Tagliabue, Tobias Hank, Roshanak Darvishzadeh, Helge Aasen, Monica Garcia, Isabel Pôças, Subhajt Bandopadhyay, Mauro Sulis, Enrico Tomelleri, Offer Rozenstein, Lachezar Filchev, Gheorghe Stancile, and Martin Schlerf. 2022. “Multi-Sensor Spectral Synergies for Crop Stress Detection and Monitoring in the Optical Domain: A Review.” *Remote Sensing of Environment* 280(July). doi: 10.1016/j.rse.2022.113198.
- Berni, Jose A. J., Pablo J. Zarco-Tejada, Lola Suárez, and Elias Fereres. 2009. “Thermal and Narrowband Multispectral Remote Sensing for Vegetation Monitoring from an Unmanned Aerial Vehicle.” *IEEE Transactions on Geoscience and Remote Sensing* 47(3):722–38. doi: 10.1109/TGRS.2008.2010457.
- Berry, A., M. A. Vivier, and C. Poblete-Echeverría. 2024. “Evaluation of Canopy Fraction-Based Vegetation Indices, Derived from Multispectral UAV Imagery, to Map Water Status Variability in a Commercial Vineyard.” *Irrigation Science* (0123456789). doi: 10.1007/s00271-023-00907-1.
- Bodin, Fabrice, and René Morlat. 2006. “Characterization of Viticultural Terroirs Using a Simple Field Model Based on Soil Depth I. Validation of the Water Supply Regime, Phenology and Vine Vigour, in the Anjou Vineyard (France).” *Plant and Soil* 281(1–2):37–54. doi: 10.1007/s11104-005-3768-0.
- Bonfante, A., A. Agrillo, R. Albrizio, A. Basile, R. Buonomo, R. De Mascellis, A. Gambuti, P. Giorio, G. Guida, G. Langella, P. Manna, L. Minieri, L. Moio, T. Siani, and F. Terribile. 2015. “Functional Homogeneous Zones (FHZs) in Viticultural Zoning Procedure: An Italian Case Study on Aglianico Vine.” *Soil* 1(1):427–41. doi: 10.5194/soil-1-427-2015.

- Bramley, R. G. V., and R. P. Hamilton. 2007. "Terroir and Precision Viticulture: Are They Compatible?" *Journal International Des Sciences de La Vigne et Du Vin* 41(1):1–8. doi: 10.20870/oenone.2007.41.1.855.
- Brenner, Claire, Christina Elisabeth Thiem, Hans Dieter Wizemann, Matthias Bernhardt, and Karsten Schulz. 2017. "Estimating Spatially Distributed Turbulent Heat Fluxes from High-Resolution Thermal Imagery Acquired with a UAV System." *International Journal of Remote Sensing* 38(8–10):3003–26. doi: 10.1080/01431161.2017.1280202.
- Bruce, Bill, and John K. Hornsby. 1987. "A Canadian Perspective on the Application of Satellite Remote Sensing to Regional Geobotany." *Geocarto International* 2(3):53–59. doi: 10.1080/10106048709354108.
- Bu, Jingyi, Guojing Gan, Jiahao Chen, Yanxin Su, Mónica García, and Yanchun Gao. 2021. "Biophysical Constraints on Evapotranspiration Partitioning for a Conductance-Based Two Source Energy Balance Model." *Journal of Hydrology* 603:127179. doi: 10.1016/j.jhydrol.2021.127179.
- Bucci, Sandra J., Guillermo Goldstein, Frederick C. Meinzer, Augusto C. Franco, Paula Campanello, and Fabián G. Scholz. 2005. "Mechanisms Contributing to Seasonal Homeostasis of Minimum Leaf Water Potential and Predawn Disequilibrium between Soil and Plant Water Potential in Neotropical Savanna Trees." *Trees - Structure and Function* 19(3):296–304. doi: 10.1007/s00468-004-0391-2.
- Bunce, James A. 2006. "How Do Leaf Hydraulics Limit Stomatal Conductance at High Water Vapour Pressure Deficits?" *Plant, Cell and Environment* 29(8):1644–50. doi: 10.1111/j.1365-3040.2006.01541.x.
- Carvalho, L.C., Vidigal, P., Amâncio, S., 2015. Oxidative stress homeostasis in grapevine (*Vitis vinifera* L.). *Front. Environ. Sci.* 3, 20
- Chacón-Vozmediano, Juan L., Jesús Martínez-Gascuña, Francisco J. García-Navarro, and Raimundo Jiménez-Ballesta. 2020. "Effects of Water Stress on Vegetative Growth and 'Merlot' Grapevine Yield in a Semi-Arid Mediterranean Climate." *Horticulturae* 6(4):1–18. doi: 10.3390/horticulturae6040095.
- Chapman, Dawn M., Mark A. Matthews, and Jean Xavier Guinard. 2004. "Sensory Attributes of Cabernet Sauvignon Wines Made from Vines with Different Crop Yields." *American Journal of Enology and Viticulture* 55(4):325–34. doi: 10.5344/ajev.2004.55.4.325.

- Charrier, Guillaume, Sylvain Delzon, Jean Christophe Domec, Li Zhang, Chloe E. L. Delmas, Isabelle Merlin, Deborah Corso, Andrew King, Hernan Ojeda, Nathalie Ollat, Jorge A. Prieto, Thibaut Scholach, Paul Skinner, Cornelis Van Leeuwen, and Gregory A. Gambetta. 2018. "Drought Will Not Leave Your Glass Empty: Low Risk of Hydraulic Failure Revealed by Long-Term Drought Observations in World's Top Wine Regions." *Science Advances* 4(1):1–10. doi: 10.1126/sciadv.aao6969.
- Chaves, M. M., T. P. Santos, C. R. Souza, M. F. Ortuño, M. L. Rodrigues, C. M. Lopes, J. P. Maroco, and J. S. Pereira. 2007. "Deficit Irrigation in Grapevine Improves Water-Use Efficiency While Controlling Vigour and Production Quality." *Annals of Applied Biology* 150(2):237–52. doi: 10.1111/j.1744-7348.2006.00123.x.
- Chaves, M. M., O. Zarrouk, R. Francisco, J. M. Costa, T. Santos, A. P. Regalado, M. L. Rodrigues, and C. M. Lopes. 2010. "Grapevine under Deficit Irrigation: Hints from Physiological and Molecular Data." *Annals of Botany* 105(5):661–76. doi: 10.1093/aob/mcq030.
- Choné, Xavier, Valérie Lavigne-Cruège, Takatoshi Tominaga, Cornelis Van Leeuwen, Caroline Castagnède, Cédric Saucier, and Denis Dubourdieu. 2006. "Effect of Vine Nitrogen Status on Grape Aromatic Potential: Flavor Precursors (S-Cysteine Conjugates), Glutathione and Phenolic Content in *Vitis Vinifera* L. Cv Sauvignon Blanc Grape Juice." *OENO One* 40(1):1. doi: 10.20870/oenone.2006.40.1.880.
- Choné, Xavier, Cornelis van Leeuwen, P. Chéry, and P. Ribéreau-Gayon. 2001. "Terroir Influence on Water Status and Nitrogen Status of Non-Irrigated Cabernet Sauvignon (*Vitis Vinifera*). Vegetative Development, Must and Wine Composition (Example of a Medoc Top Estate Vineyard, Saint Julien Area, Bordeaux, 1997)." *South African Journal of Enology and Viticulture* 22(1):8–15.
- Chuvienco, Emilio. 2016. *Fundamentals of Satellite Remote Sensing*. Second Edi. London: CRC Press. Taylor & Francis Group.
- Clawson, K. L., R. D. Jackson, and P. J. Pinter. 1989. "Evaluating Plant Water Stress with Canopy Temperature Differences." *Agronomy Journal* 81(6):858–63. doi: 10.2134/agronj1989.00021962008100060004x.

- Cohen, Y., V. Alchanatis, M. Meron, Y. Saranga, and J. Tsipris. 2005. "Estimation of Leaf Water Potential by Thermal Imagery and Spatial Analysis." *Journal of Experimental Botany* 56(417):1843–52. doi: 10.1093/jxb/eri174.
- COOMBE, B. G. 1995. "Growth Stages of the Grapevine: Adoption of a System for Identifying Grapevine Growth Stages." *Australian Journal of Grape and Wine Research* 1(2):104–10. doi: 10.1111/j.1755-0238.1995.tb00086.x.
- Corwin, D. L., and S. M. Lesch. 2005. "Apparent Soil Electrical Conductivity Measurements in Agriculture." *Computers and Electronics in Agriculture* 46(1–3):11–43. doi: 10.1016/j.compag.2004.10.005.
- Costa, J. M., M. Vaz, J. Escalona, R. Egipto, C. Lopes, H. Medrano, and M. M. Chaves. 2016. "Modern Viticulture in Southern Europe: Vulnerabilities and Strategies for Adaptation to Water Scarcity." *Agricultural Water Management* 164:5–18. doi: 10.1016/j.agwat.2015.08.021.
- Costa, J. M., Garcia-Tejero, I., Egipto, R., Tomás, M., Vaz, M., Lopes, C. M., & Chaves, M. M. (2015). Assessing canopy temperature patterns in two grapevine varieties subjected to deficit irrigation: a tool to optimize water management?. In 19<sup>th</sup> International Meeting of Viticulture GiESCO, Peach Rouge-Montpellier, 31 May-5 June, vol. 1, p. 130-133. GiESCO.
- Costa, Joaquim M., Maria F. Ortuño, Carlos M. Lopes, and Maria M. Chaves. 2012. "Grapevine Varieties Exhibiting Differences in Stomatal Response to Water Deficit." *Functional Plant Biology* 39(3):179. doi: 10.1071/FP11156.
- Daponte, Pasquale, Luca De Vito, Luigi Glielmo, Luigi Iannelli, Davide Liuzza, Francesco Picariello, and Giuseppe Silano. 2019. "A Review on the Use of Drones for Precision Agriculture." *IOP Conference Series: Earth and Environmental Science* 275(1). doi: 10.1088/1755-1315/275/1/012022.
- Delgado, Antonio, and José A. Gómez. 2016. "The Soil. Physical, Chemical and Biological Properties." Pp. 15–26 in *Principles of Agronomy for Sustainable Agriculture*. Cham: Springer International Publishing.
- Deng, Lei, Zhihui Mao, Xiaojuan Li, Zhuowei Hu, Fuzhou Duan, and Yanan Yan. 2018. "UAV-Based Multispectral Remote Sensing for Precision Agriculture: A Comparison between Different Cameras." *ISPRS Journal of Photogrammetry and Remote Sensing* 146(March):124–36. doi: 10.1016/j.isprsjprs.2018.09.008.
- Ditzler, C.; Scheffe, K.; Monger, H. C. .. 2017. *Soil Survey Manual*. USDA Handbook 18. edited by G. Printing and Office. Washington, DC, USA,.

- Ehrler, W. L., S. B. Idso, R. D. Jackson, and R. J. Reginato. 1978. "Wheat Canopy Temperature: Relation to Plant Water Potential 1." *Agronomy Journal* 70(2):251–56. doi: 10.2134/agronj1978.00021962007000020010x.
- Ministerio de Agricultura, Pesca y Alimentación. (2023). Encuesta sobre Superficies y Rendimientos Cultivos en España (ESYRCE). [https://www.mapa.gob.es/es/estadistica/temas/estadisticas-agrarias/resultados\\_provisionales\\_esyrce2023\\_tcm30-673287.pdf](https://www.mapa.gob.es/es/estadistica/temas/estadisticas-agrarias/resultados_provisionales_esyrce2023_tcm30-673287.pdf)
- Esteves, Catarina, Henrique Ribeiro, Ricardo P. Braga, and David Fangueiro. 2022. "Remote Sensing (NDVI) and Apparent Soil Electrical Conductivity (ECap) to Delineate Different Zones in a Vineyard." 42. doi: 10.3390/iecag2021-10021.
- FAO. 2020. *The State of Food and Agriculture 2020. Overcoming Water Challenges in Agriculture*. Roma <https://doi.org/10.4060/cb1447en>.
- Fawcett, Dominic, Cinzia Panigada, Giulia Tagliabue, Mirco Boschetti, Marco Celesti, Anton Evdokimov, Khelvi Biriukova, Roberto Colombo, Franco Miglietta, Uwe Rascher, and Karen Anderson. 2020. "Multi-Scale Evaluation of Drone-Based Multispectral Surface Reflectance and Vegetation Indices in Operational Conditions." *Remote Sensing* 12(3). doi: 10.3390/rs12030514.
- Fernández-Guisuraga, José Manuel, Enoc Sanz-Ablanedo, Susana Suárez-Seoane, and Leonor Calvo. 2018. "Using Unmanned Aerial Vehicles in Postfire Vegetation Survey Campaigns through Large and Heterogeneous Areas: Opportunities and Challenges." *Sensors (Switzerland)* 18(2). doi: 10.3390/s18020586.
- Ferrer, Milka, Gerardo Echeverría, Gustavo Pereyra, Gustavo Gonzalez-Neves, Dinorah Pan, and José Manuel Mirás-Avalos. 2020. "Mapping Vineyard Vigor Using Airborne Remote Sensing: Relations with Yield, Berry Composition and Sanitary Status under Humid Climate Conditions." *Precision Agriculture* 21(1):178–97. doi: 10.1007/s11119-019-09663-9.
- Fisher, Joshua B., Kevin P. Tu, and Dennis D. Baldocchi. 2008. "Global Estimates of the Land–Atmosphere Water Flux Based on Monthly AVHRR and ISLSCP-II Data, Validated at 16 FLUXNET Sites." *Remote Sensing of Environment* 112(3):901–19. doi: 10.1016/j.rse.2007.06.025.
- Franks, P. J., and G. D. Farquhar. 1999. "A Relationship between Humidity Response, Growth Form and Photosynthetic Operating Point in C 3 Plants."

- Plant, Cell & Environment 22(11):1337–49. doi: 10.1046/j.1365-3040.1999.00494.x.
- Franzini, Marica, Giulia Ronchetti, Giovanna Sona, and Vittorio Casella. 2019. “Geometric and Radiometric Consistency of Parrot Sequoia Multispectral Imagery for Precision Agriculture Applications.” *Applied Sciences (Switzerland)* 9(24). doi: 10.3390/app9245314.
- FUCHS, E. E., and N. J. LIVINGSTON. 1996. “Hydraulic Control of Stomatal Conductance in Douglas Fir [ *Pseudotsuga Menziesii* (Mirb.) Franco] and Alder [ *Alnus Rubra* (Bong)] Seedlings.” *Plant, Cell & Environment* 19(9):1091–98. doi: 10.1111/j.1365-3040.1996.tb00216.x.
- Fuentes, Sigfredo, Roberta De Bei, and Stephen D. Tyerman. 2013. “New and Emerging Technologies for the Vineyard: The Vineyard of the Future Initiative.” *Wine & Viticulture Journal* 28(3):38–45.
- Gallo, A. E., J. E. Perez Peña, C. V. González, and J. A. Prieto. 2022. “Syrah and Grenache (*Vitis Vinifera*) Revealed Different Strategies to Cope with High Temperature.” *Australian Journal of Grape and Wine Research* 28(3):383–94. doi: 10.1111/ajgw.12530.
- Gao, W. 1995. “Parameterization of Subgrid-scale Land Surface Fluxes with Emphasis on Distributing Mean Atmospheric Forcing and Using Satellite-derived Vegetation Index.” *Journal of Geophysical Research: Atmospheres* 100(D7):14305–17. doi: 10.1029/95JD01464.
- Gardner, B. R., B. L. Blad, and D. G. Watts. 1981. “Plant and Air Temperatures in Differentially-Irrigated Corn.” *Agricultural Meteorology* 25:207–17. doi: 10.1016/0002-1571(81)90073-X.
- Garnier, E., and A. Berger. 1985. “Testing Water Potential in Peach Trees as an Indicator of Water Stress.” *Journal of Horticultural Science* 60(1):47–56. doi: 10.1080/14620316.1985.11515600.
- Garratt, J. R., A. J. Prata, L. D. Rotstayn, B. J. McAvaney, and S. Cusack. 1998. “The Surface Radiation Budget over Oceans and Continents.” *Journal of Climate* 11(8):1951–68. doi: 10.1175/1520-0442-11.8.1951.
- Garrigues, S., D. Allard, F. Baret, and M. Weiss. 2006. “Influence of Landscape Spatial Heterogeneity on the Non-Linear Estimation of Leaf Area Index from Moderate Spatial Resolution Remote Sensing Data.” *Remote Sensing of Environment* 105(4):286–98. doi: 10.1016/j.rse.2006.07.013.

- Gates, David M. 1964. "Leaf Temperature and Transpiration 1." *Agronomy Journal* 56(3):273–77. doi: 10.2134/agronj1964.00021962005600030007x.
- Ge, Yufeng, J. Alex Thomasson, and Ruixiu Sui. 2011. "Remote Sensing of Soil Properties in Precision Agriculture: A Review." *Frontiers of Earth Science* 5(3):229–38. doi: 10.1007/s11707-011-0175-0.
- Di Gennaro, Salvatore Filippo, Piero Toscano, Matteo Gatti, Stefano Poni, Andrea Berton, and Alessandro Matese. 2022. "Spectral Comparison of UAV-Based Hyper and Multispectral Cameras for Precision Viticulture." *Remote Sensing* 14(3):1–21. doi: 10.3390/rs14030449.
- Gerhards, Max, Martin Schlerf, Kaniska Mallick, and Thomas Udelhoven. 2019. "Challenges and Future Perspectives of Multi-/Hyperspectral Thermal Infrared Remote Sensing for Crop Water-Stress Detection: A Review." *Remote Sensing* 11(10). doi: 10.3390/rs11101240.
- Gitelson, Anatoly A., Yoram J. Kaufman, and Mark N. Merzlyak. 1996. "Use of a Green Channel in Remote Sensing of Global Vegetation from EOS-MODIS." *Remote Sensing of Environment* 58(3):289–98. doi: 10.1016/S0034-4257(96)00072-7.
- Gonzalez-Dugo, V., P. J. Zarco-Tejada, and E. Fereres. 2014. "Applicability and Limitations of Using the Crop Water Stress Index as an Indicator of Water Deficits in Citrus Orchards." *Agricultural and Forest Meteorology* 198–199:94–104. doi: 10.1016/j.agrformet.2014.08.003.
- Gowda, Prasanna H., Jose L. Chavez, Paul D. Colaizzi, Steve R. Evett, Terry A. Howell, and Judy A. Tolck. 2008. "ET Mapping for Agricultural Water Management: Present Status and Challenges." *Irrigation Science* 26(3):223–37. doi: 10.1007/s00271-007-0088-6.
- VAN DE GRIEND, A. A., and M. OWE. 1993. "On the Relationship between Thermal Emissivity and the Normalized Difference Vegetation Index for Natural Surfaces." *International Journal of Remote Sensing* 14(6):1119–31. doi: 10.1080/01431169308904400.
- Gutiérrez, Salvador, Juan Fernández-Novales, María Paz Diago, Rubén Iñiguez, and Javier Tardaguila. 2021. "Assessing and Mapping Vineyard Water Status Using a Ground Mobile Thermal Imaging Platform." *Irrigation Science* 39(4):457–68. doi: 10.1007/s00271-021-00735-1.

- Gutman, G. Gari. 1991. "Vegetation Indices from AVHRR: An Update and Future Prospects." *Remote Sensing of Environment* 35(2-3):121-36. doi: 10.1016/0034-4257(91)90005-Q.
- Hall, Andrew, John Louis, and David Lamb. 2001. "A Method For Extracting Detailed Information From High Resolution Multispectral Images Of Vineyards." *Proceedings of the 6th International Conference on Geocomputation (January 2001)*:ISBN 1864995637.
- Hall, Andrew, John Louis, and David Lamb. 2003. "Characterising and Mapping Vineyard Canopy Using High-Spatial- Resolution Aerial Multispectral Images." *Computers and Geosciences* 29(7):813-22. doi: 10.1016/S0098-3004(03)00082-7.
- Hamblin, AP, and J. Hamblin. 1985. "Root Characteristics of Some Temperate Legume Species and Varieties on Deep, Free-Draining Entisols." *Australian Journal of Agricultural Research* 36(1):63. doi: 10.1071/AR9850063.
- Heil, D., and G. Sposito. 1997. "Chapter 3 Chemical Attributes and Processes Affecting Soil Quality." Pp. 59-79 in.
- Helwi, Pierre, Sabine Guillaumie, Cécile Thibon, Céline Keime, Aude Habran, Ghislaine Hilbert, Eric Gomes, Philippe Darriet, Serge Delrot, and Cornelis van Leeuwen. 2016. "Vine Nitrogen Status and Volatile Thiols and Their Precursors from Plot to Transcriptome Level." *BMC Plant Biology* 16(1):1-23. doi: 10.1186/s12870-016-0836-y.
- Hernández-Montes, Esther, José Mariano Escalona, Magdalena Tomàs, and Hipólito Medrano. 2020. "Plant Water Status and Genotype Affect Fruit Respiration in Grapevines." *Physiologia Plantarum* 169(4):544-54. doi: 10.1111/ppl.13093.
- Hoffmann, H., H. Nieto, R. Jensen, R. Guzinski, P. Zarco-Tejada, and T. Friborg. 2016. "Estimating Evaporation with Thermal UAV Data and Two-Source Energy Balance Models." *Hydrology and Earth System Sciences* 20(2):697-713. doi: 10.5194/hess-20-697-2016.
- Hsiao.T.C. 1990. "Measurement of Plant Water Status." *Agronomy* No.30:243-79.
- Huete, A. 1997. "A Comparison of Vegetation Indices over a Global Set of TM Images for EOS-MODIS." *Remote Sensing of Environment* 59(3):440-51. doi: 10.1016/S0034-4257(96)00112-5.

- Huete, A., C. Justice, and H. Liu. 1994. "Development of Vegetation and Soil Indices for MODIS-EOS." *Remote Sensing of Environment* 49(3):224–34. doi: 10.1016/0034-4257(94)90018-3.
- Idso, Sherwood B. 1982. "Non-Water-Stressed Baselines: A Key to Measuring and Interpreting Plant Water Stress." *Agricultural Meteorology* 27(1–2):59–70. doi: 10.1016/0002-1571(82)90020-6.
- Instituto geografico nacional, ATLAS NACIONAL DE ESPAÑA, GEOLOGIA, GEOMORFOLOGIA Y EDAFOLOGIA MONOGRAFIA 2006
- Imai, Francisco H., Mitchell R. Rosen, and Roy S. Berns. 2000. "Comparison of Spectrally Narrow-Band Capture versus Wide-Band with a Priori Sample Analysis for Spectral Reflectance Estimation." *Final Program and Proceedings - IS and T/SID Color Imaging Conference* 234–41. doi: 10.2352/cic.2000.8.1.art00043.
- Intrigliolo, Diego S., and Juan Ramón Castel. 2010. "Response of Grapevine Cv. 'Tempranillo' to Timing and Amount of Irrigation: Water Relations, Vine Growth, Yield and Berry and Wine Composition." *Irrigation Science* 28(2):113–25. doi: 10.1007/s00271-009-0164-1.
- Intrigliolo, Diego Sebastiano, and Juan Ramón Castel. 2008. "Effects of Irrigation on the Performance of Grapevine Cv. Tempranillo in Requena, Spain." *American Journal of Enology and Viticulture* 59(1):30–38. doi: 10.5344/ajev.2008.59.1.30.
- Irmak, S., D. Z. Haman, and R. Bastug. 2000. "Determination of Crop Water Stress Index for Irrigation Timing and Yield Estimation of Corn." *Agronomy Journal* 92(6):1221–27. doi: 10.2134/agronj2000.9261221x.
- Jackson, R. D., S. B. Idso, R. J. Reginato, and P. J. Pinter. 1981. "Canopy Temperature as a Crop Water Stress Indicator." *Water Resources Research* 17(4):1133–38. doi: 10.1029/WR017i004p01133.
- Jackson, R. D., R. J. Reginato, and S. B. Idso. 1977. "Wheat Canopy Temperature: A Practical Tool for Evaluating Water Requirements." *Water Resources Research* 13(3):651–56. doi: 10.1029/WR013i003p00651.
- Jackson, Stephen D. 2009. "Plant Responses to Photoperiod." *New Phytologist* 181(3):517–31. doi: 10.1111/j.1469-8137.2008.02681.x.

- Jacob, Frédéric, François Petitcolin, Thomas Schmugge, Éric Vermote, Andrew French, and Kenta Ogawa. 2004. "Comparison of Land Surface Emissivity and Radiometric Temperature Derived from MODIS and ASTER Sensors." *Remote Sensing of Environment* 90(2):137–52. doi: 10.1016/j.rse.2003.11.015.
- Jones, H. G. 2002. "Use of Infrared Thermography for Monitoring Stomatal Closure in the Field: Application to Grapevine." *Journal of Experimental Botany* 53(378):2249–60. doi: 10.1093/jxb/erf083.
- Jones, Hamlyn G. 1999. "Use of Infrared Thermometry for Estimation of Stomatal Conductance as a Possible Aid to Irrigation Scheduling." *Agricultural and Forest Meteorology* 95(3):139–49. doi: 10.1016/S0168-1923(99)00030-1.
- Jones, Hamlyn G. 2004. "Application of Thermal Imaging and Infrared Sensing in Plant Physiology and Ecophysiology." Pp. 107–63 in.
- Jones, Hamlyn G., Rachid Serraj, Brian R. Loveys, Lizhong Xiong, Ashley Wheaton, and Adam H. Price. 2009. "Thermal Infrared Imaging of Crop Canopies for the Remote Diagnosis and Quantification of Plant Responses to Water Stress in the Field." *Functional Plant Biology* 36(11):978. doi: 10.1071/FP09123.
- Jordan, Carl F. 1969. "Derivation of Leaf-Area Index from Quality of Light on the Forest Floor." *Ecology* 50(4):663–66. doi: 10.2307/1936256.
- Kasimati, A., V. Psiroukis, N. Darra, A. Kalogrias, D. Kalivas, J. A. Taylor, and S. Fountas. 2023. "Investigation of the Similarities between NDVI Maps from Different Proximal and Remote Sensing Platforms in Explaining Vineyard Variability." *Precision Agriculture* (0123456789). doi: 10.1007/s11119-022-09984-2.
- Khaliq, Aleem, Lorenzo Comba, Alessandro Biglia, Davide Ricauda Aimonino, Marcello Chiaberge, and Paolo Gay. 2019. "Comparison of Satellite and UAV-Based Multispectral Imagery for Vineyard Variability Assessment." *Remote Sensing* 11(4). doi: 10.3390/rs11040436.
- Khanal, Sami, John Fulton, and Scott Shearer. 2017. "An Overview of Current and Potential Applications of Thermal Remote Sensing in Precision Agriculture." *Computers and Electronics in Agriculture* 139:22–32. doi: 10.1016/j.compag.2017.05.001.
- Leeuwen, C. Van, O. Tregoat, X. Choné, B. Bois, D. Pernet, and J. P. Gaudillère. 2009. "Vine Water Status Is a Key Factor in Grape Ripening and Vintage

- Quality for Red Bordeaux Wine. How Can It Be Assessed for Vineyard Management Purposes?" *Journal International Des Sciences de La Vigne et Du Vin* 43(3):121–34. doi: 10.20870/oenone.2009.43.3.798.
- Leeuwen, Cornelis Van, Bordeaux Sciences Agro, and Benjamin Bois. 2012. "Methodology of Soil-Based Zoning for Viticultural Terroirs." (May 2016).
- Van Leeuwen, Cornelis, Philippe Friant, Xavier Choné, Olivier Tregoat, Stephanos Koundouras, and Denis Dubourdieu. 2004. "Influence of Climate, Soil, and Cultivar on Terroir." *American Journal of Enology and Viticulture* 55(3):207–17. doi: 10.5344/ajev.2004.55.3.207.
- Van Leeuwen, Cornélis, Jean-Philippe Roby, and Laure De Rességuier. 2018. "Soil-Related Terroir Factors: A Review." *OENO One* 52(2):173–88. doi: 10.20870/oenone.2018.52.2.2208.
- Leinonen, Ilkka, and Hamlyn G. Jones. 2004. "Combining Thermal and Visible Imagery for Estimating Canopy Temperature and Identifying Plant Stress." *Journal of Experimental Botany* 55(401):1423–31. doi: 10.1093/jxb/erh146.
- Levin, Alexander D., Larry E. Williams, and Mark A. Matthews. 2020. "A Continuum of Stomatal Responses to Water Deficits among 17 Wine Grape Cultivars (*Vitis Vinifera*)." *Functional Plant Biology* 47(1):11. doi: 10.1071/FP19073.
- Liao, Kaihua, Shaohui Xu, Jichun Wu, and Qing Zhu. 2013. "Spatial Estimation of Surface Soil Texture Using Remote Sensing Data." *Soil Science and Plant Nutrition* 59(4):488–500. doi: 10.1080/00380768.2013.802643.
- Liu WT, Wenkart W, Allen LH, Lemon ER. 1978. Soil-plant-water relations in a New York vineyard: resistances to water movement. *Journal of American Society of Horticulture and Science* 103: 226±230
- López-García, Patricia, Diego S. Intrigliolo, Miguel A. Moreno, Alejandro Martínez-Moreno, Jose F. Ortega, Eva P. Pérez-álvarez, and Rocío Ballesteros. 2021. "Assessment of Vineyard Water Status by Multispectral and Rgb Imagery Obtained from an Unmanned Aerial Vehicle." *American Journal of Enology and Viticulture* 72(4):285–97. doi: 10.5344/ajev.2021.20063.
- López-Granados, F., M. Jurado-Expósito, J. M. Peña-Barragán, and L. García-Torres. 2005. "Using Geostatistical and Remote Sensing Approaches for Mapping Soil Properties." *European Journal of Agronomy* 23(3):279–89. doi: 10.1016/j.eja.2004.12.003.

- Lovisolò, Claudio, Wolfram Hartung, and Andrea Schubert. 2002. "Whole-Plant Hydraulic Conductance and Root-to-Shoot Flow of Abscisic Acid Are Independently Affected by Water Stress in Grapevines." *Functional Plant Biology* 29(11):1349. doi: 10.1071/FP02079.
- Lovisolò, Claudio, Irene Perrone, Andrea Carra, Alessandra Ferrandino, Jaume Flexas, Hipolito Medrano, and Andrea Schubert. 2010. "Drought-Induced Changes in Development and Function of Grapevine (*Vitis* Spp.) Organs and in Their Hydraulic and Non-Hydraulic Interactions at the Whole-Plant Level: A Physiological and Molecular Update." *Functional Plant Biology* 37(2):98. doi: 10.1071/FP09191.
- Lovisolò, Claudio, Irene Perrone, Wolfram Hartung, and Andrea Schubert. 2008. "An Abscisic Acid-related Reduced Transpiration Promotes Gradual Embolism Repair When Grapevines Are Rehydrated after Drought." *New Phytologist* 180(3):642–51. doi: 10.1111/j.1469-8137.2008.02592.x.
- Madruga, J., E. B. Azevedo, J. F. Sampaio, F. Fernandes, F. Reis, and J. Pinheiro. 2015. "Analysis and Definition of Potential New Areas for Viticulture in the Azores (Portugal)." *Soil* 1(2):515–26. doi: 10.5194/soil-1-515-2015.
- Maes, W. H., and K. Steppe. 2012. "Estimating Evapotranspiration and Drought Stress with Ground-Based Thermal Remote Sensing in Agriculture: A Review." *Journal of Experimental Botany* 63(13):4671–4712. doi: 10.1093/jxb/ers165.
- Mahlein, Anne-Katrin. 2016. "Plant Disease Detection by Imaging Sensors – Parallels and Specific Demands for Precision Agriculture and Plant Phenotyping." *Plant Disease* 100(2):241–51. doi: 10.1094/PDIS-03-15-0340-FE.
- Martínez-Vilalta, Jordi, and Núria Garcia-Forner. 2017. "Water Potential Regulation, Stomatal Behaviour and Hydraulic Transport under Drought: Deconstructing the Iso/Anisohydric Concept." *Plant Cell and Environment* 40(6):962–76. doi: 10.1111/pce.12846.
- Matese, A., S. F. Di Gennaro, and L. G. Santesteban. 2019. "Methods to Compare the Spatial Variability of UAV-Based Spectral and Geometric Information with Ground Autocorrelated Data. A Case of Study for Precision Viticulture." *Computers and Electronics in Agriculture* 162(May):931–40. doi: 10.1016/j.compag.2019.05.038.
- McBratney, Alex B., Inakwu O. A. Odeh, Thomas F. A. Bishop, Marian S. Dunbar, and Tamara M. Shatar. 2000. "An Overview of Pedometric Techniques for Use

- in Soil Survey.” *Geoderma* 97(3–4):293–327. doi: 10.1016/S0016-7061(00)00043-4.
- Meron, M., J. Tsipris, Valerie Orlov, V. Alchanatis, and Yafit Cohen. 2010. “Crop Water Stress Mapping for Site-Specific Irrigation by Thermal Imagery and Artificial Reference Surfaces.” *Precision Agriculture* 11(2):148–62. doi: 10.1007/s11119-009-9153-x.
- Messina, Gaetano, and Giuseppe Modica. 2020. “Applications of UAV Thermal Imagery in Precision Agriculture: State of the Art and Future Research Outlook.” *Remote Sensing* 12(9). doi: 10.3390/RS12091491.
- Möller, M., V. Alchanatis, Y. Cohen, M. Meron, J. Tsipris, A. Naor, V. Ostrovsky, M. Sprintsin, and S. Cohen. 2007. “Use of Thermal and Visible Imagery for Estimating Crop Water Status of Irrigated Grapevine.” *Journal of Experimental Botany* 58(4):827–38. doi: 10.1093/jxb/erl115.
- Moyano, Maria C., Monica Garcia, Alicia Palacios-Orueta, Lucia Tornos, Joshua B. Fisher, Néstor Fernández, Laura Recuero, and Luis Juana. 2018. “Vegetation Water Use Based on a Thermal and Optical Remote Sensing Model in the Mediterranean Region of Doñana.” *Remote Sensing* 10(7). doi: 10.3390/rs10071105.
- Mulders, M.A. (1987). *Remote Sensing in Soil Science*. Amsterdam, the Netherlands: Elsevier
- Naor, A. 2000. “Midday Stem Water Potential as a Plant Water Stress Indicator for Irrigation Scheduling in Fruit Trees.” *Acta Horticulturae* 537:447–54. doi: 10.17660/ActaHortic.2000.537.52.
- Oades, J. M. 1993. “The Role of Biology in the Formation, Stabilization and Degradation of Soil Structure.” Pp. 377–400 in *Soil Structure/Soil Biota Interrelationships*. Elsevier.
- Ojeda H, Andary C, Kraeva E, Carbonneau A, Deloire A (2002) Influence of pre and postveraison water deficit on synthesis and concentration of skin phenolic compounds during berry growth of *Vitis vinifera* cv Shiraz. *Am J Enol Vitic* 53:261–267
- Oldoni, Henrique, Bruno Ricardo Silva Costa, Itamar Antônio Bognola, Claudia Rita de Souza, and Luís Henrique Bassoi. 2020. “Homogeneous Zones of Vegetation Index for Characterizing Variability and Site-Specific Management in Vineyards.” *Scientia Agricola* 78(4):1–10. doi: 10.1590/1678-992x-2019-0243.

- Oren, R., J. S. Sperry, G. G. Katul, D. E. Pataki, B. E. Ewers, N. Phillips, and K. V. R. Schäfer. 1999. "Survey and Synthesis of Intra- and Interspecific Variation in Stomatal Sensitivity to Vapour Pressure Deficit." *Plant, Cell & Environment* 22(12):1515–26. doi: 10.1046/j.1365-3040.1999.00513.x.
- Ortega-Blu, Rodrigo, and Mauricio Molina-Roco. 2016. "Evaluation of Vegetation Indices and Apparent Soil Electrical Conductivity for Site-Specific Vineyard Management in Chile." *Precision Agriculture* 17(4):434–50. doi: 10.1007/s11119-016-9429-x.
- Ortega-Fariás, Samuel, Samuel Ortega-Salazar, Tomas Poblete, Ayse Kilic, Richard Allen, Carlos Poblete-Echeverría, Luis Ahumada-Orellana, Mauricio Zuñiga, and Daniel Sepúlveda. 2016. "Estimation of Energy Balance Components over a Drip-Irrigated Olive Orchard Using Thermal and Multispectral Cameras Placed on a Helicopter-Based Unmanned Aerial Vehicle (UAV)." *Remote Sensing* 8(8):1–18. doi: 10.3390/rs8080638.
- P, Duchaufour. 2001. "Introduction à La Science Du Sol." in *Sol, Végétation, Environnement*. (6e éd) de l'Abrégé de Pédologie. Paris.
- Pádua, Luís, Pedro Marques, Telmo Adão, Nathalie Guimarães, António Sousa, Emanuel Peres, and Joaquim João Sousa. 2019. "Vineyard Variability Analysis through UAV-Based Vigour Maps to Assess Climate Change Impacts." *Agronomy* 9(10). doi: 10.3390/agronomy9100581.
- Pádua, Luís, Alessandro Matese, Salvatore Filippo Di Gennaro, Raul Morais, Emanuel Peres, and Joaquim J. Sousa. 2022. "Vineyard Classification Using OBIA on UAV-Based RGB and Multispectral Data: A Case Study in Different Wine Regions." *Computers and Electronics in Agriculture* 196(March). doi: 10.1016/j.compag.2022.106905.
- Pellegrino, Anne, Peter Clingeffer, Nicola Cooley, and Rob Walker. 2014. "Management Practices Impact Vine Carbohydrate Status to a Greater Extent than Vine Productivity." *Frontiers in Plant Science* 5. doi: 10.3389/fpls.2014.00283.
- Peralta, Nahuel Raúl, and José Luis Costa. 2013. "Delineation of Management Zones with Soil Apparent Electrical Conductivity to Improve Nutrient Management." *Computers and Electronics in Agriculture* 99:218–26. doi: 10.1016/j.compag.2013.09.014.

- Poblete-Echeverría, Carlos, Guillermo Federico Olmedo, Ben Ingram, and Matthew Bardeen. 2017. "Detection and Segmentation of Vine Canopy in Ultra-High Spatial Resolution RGB Imagery Obtained from Unmanned Aerial Vehicle (UAV): A Case Study in a Commercial Vineyard." *Remote Sensing* 9(3). doi: 10.3390/rs9030268.
- Poncet, Aurelie M., Thorsten Knappenberger, Christian Brodbeck, Michael Fogle, Joey N. Shaw, and Brenda V. Ortiz. 2019. "Multispectral UAS Data Accuracy for Different Radiometric Calibration Methods." *Remote Sensing* 11(16):1–22. doi: 10.3390/rs11161917.
- Poni, S., Bernizzoni, F. and Civardi, S. (2007) The issue of canopy efficiency in the grapevine: assessment and approaches for its improvement. *Acta Horticulturae* 754,163–174.
- Pou, Alícia, Maria P. Diago, Hipólito Medrano, Javier Baluja, and Javier Tardaguila. 2014. "Validation of Thermal Indices for Water Status Identification in Grapevine." *Agricultural Water Management* 134:60–72. doi: 10.1016/j.agwat.2013.11.010.
- Pou, Alícia, Jaume Flexas, Maria del Mar Alsina, Josefina Bota, Cecilia Carambula, Felicidad De Herralde, Jeroni Galmés, Claudio Lovisolo, Miguel Jiménez, Miquel Ribas-Carbó, Denis Rusjan, Francesca Secchi, Magdalena Tomàs, Zsolt Zsófi, and Hipólito Medrano. 2008. "Adjustments of Water Use Efficiency by Stomatal Regulation during Drought and Recovery in the Drought-adapted *Vitis* Hybrid Richter-110 ( *V. Berlandieri* × *V. Rupestris* )." *Physiologia Plantarum* 134(2):313–23. doi: 10.1111/j.1399-3054.2008.01138.x.
- Pou, Alícia, Hipólito Medrano, Magdalena Tomàs, Sebastià Martorell, Miquel Ribas-Carbó, and Jaume Flexas. 2012. "Anisohydric Behaviour in Grapevines Results in Better Performance under Moderate Water Stress and Recovery than Isohydric Behaviour." *Plant and Soil* 359(1–2):335–49. doi: 10.1007/s11104-012-1206-7.
- Pou Mir, Alícia. 2011. "Grapevine Physiological Responses during Water Stress and Re-Watering: Implications for Water-Use-Efficiency."
- Prata, A. J., I. F. Grant, R. P. Cechet, and G. F. Rutter. 1998. "Five Years of Shortwave Radiation Budget Measurements at a Continental Land Site in Southeastern Australia." *Journal of Geophysical Research Atmospheres* 103(D20):26093–106. doi: 10.1029/98JD02349.

- Purdy, A. J., J. B. Fisher, M. L. Goulden, and J. S. Famiglietti. 2016. "Ground Heat Flux: An Analytical Review of 6 Models Evaluated at 88 Sites and Globally." *Journal of Geophysical Research: Biogeosciences* 121(12):3045–59. doi: 10.1002/2016JG003591.
- Reginato, R. J., S. B. Idso, J. F. Vedder, R. D. Jackson, M. B. Blanchard, and R. Goettelman. 1976. "Soil Water Content and Evaporation Determined by Thermal Parameters Obtained from Ground-Based and Remote Measurements." *Journal of Geophysical Research* 81(9):1617–20. doi: 10.1029/JC081i009p01617.
- Rienth, Markus, and Thibaut Scholasch. 2019. "State-of-the-Art of Tools and Methods to Assess Vine Water Status." *Oeno One* 53(4):619–37. doi: 10.20870/oenone.2019.53.4.2403.
- Rogiers, S. Y., W. J. Hardie, and J. P. Smith. 2011. "Stomatal Density of Grapevine Leaves (*Vitis Vinifera* L.) Responds to Soil Temperature and Atmospheric Carbon Dioxide." *Australian Journal of Grape and Wine Research* 17(2):147–52. doi: 10.1111/j.1755-0238.2011.00124.x.
- Rondeaux, Geneviève, Michael Steven, and Frédéric Baret. 1996. "Optimization of Soil-Adjusted Vegetation Indices." *Remote Sensing of Environment* 55(2):95–107. doi: 10.1016/0034-4257(95)00186-7.
- Rossiter, D. G. (2000). *Methodology for soil resource inventories*. ITC Lecture Notes SOL, 27.
- Rouse, J. W., R. H. Haas, J. A. Schell, D. W. Deering, and J. C. Harlan. 1974. "Monitoring the Vernal Advancements and Retrogradation of Natural Vegetation." NASA/GSFC, Final Report, Greenbelt, MD, USA (September 1972):1–137.
- Salleo, Sebastiano, Andrea Nardini, Franco Pitt, and Maria A. Lo Gullo. 2000. "Xylem Cavitation and Hydraulic Control of Stomatal Conductance in Laurel (*Laurus Nobilis* L.)." *Plant, Cell & Environment* 23(1):71–79. doi: 10.1046/j.1365-3040.2000.00516.x.
- Sampson, Paul H., Pablo J. Zarco-Tejada, Gina H. Mohammed, John R. Miller, and Thomas L. Noland. 2003. "Hyperspectral Remote Sensing of Forest Condition: Estimating Chlorophyll Content in Tolerant Hardwoods." *Forest Science* 49(3):381–91. doi: 10.1093/forestscience/49.3.381.

- Santesteban, L. G., S. Guillaume, J. B. Royo, and B. Tisseyre. 2013. "Are Precision Agriculture Tools and Methods Relevant at the Whole-Vineyard Scale?" *Precision Agriculture* 14(1):2–17. doi: 10.1007/s11119-012-9268-3.
- Scholander, P. F., Edda D. Bradstreet, E. A. Hemmingsen, and H. T. Hammel. 1965. "Sap Pressure in Vascular Plants." *Science* 148(3668):339–46. doi: 10.1126/science.148.3668.339.
- SCHULTZ, H. R. 2003. "Differences in Hydraulic Architecture Account for Near-isohydric and Anisohydric Behaviour of Two Field-grown *Vitis Vinifera* L. Cultivars during Drought." *Plant, Cell & Environment* 26(8):1393–1405. doi: 10.1046/j.1365-3040.2003.01064.x.
- Sepulcre-Cantó, G., P. J. Zarco-Tejada, J. C. Jiménez-Muñoz, J. A. Sobrino, E. de Miguel, and F. J. Villalobos. 2006. "Detection of Water Stress in an Olive Orchard with Thermal Remote Sensing Imagery." *Agricultural and Forest Meteorology* 136(1–2):31–44. doi: 10.1016/j.agrformet.2006.01.008.
- Shackel, Kenneth A., H. Ahmadi, W. Biasi, R. Buchner, D. Goldhamer, S. Gurusinghe, J. Hasey, D. Kester, B. Krueger, B. Lampinen, G. McGourty, W. Micke, E. Mitcham, B. Olson, K. Pelletrau, H. Philips, D. Ramos, L. Schwankl, S. Sibbett, R. Snyder, S. Southwick, M. Stevenson, M. Thorpe, S. Weinbaum, and J. Yeager. 1997. "Plant Water Status as an Index of Irrigation Need in Deciduous Fruit Trees." *HortTechnology* 7(1):23–29.
- Sirera, Àngela Puig, Daniele Antichi, Dylan Warren Raffa, and Giovanni Rallo. 2021. "Application of Remote Sensing Techniques to Discriminate the Effect of Different Soil Management Treatments over Rainfed Vineyards in Chianti Terroir." *Remote Sensing* 13(4):1–25. doi: 10.3390/rs13040716.
- SOAR, C. J., J. SPEIRS, S. M. MAFFEI, A. B. PENROSE, M. G. MCCARTHY, and B. R. LOVEYS. 2006. "Grape Vine Varieties Shiraz and Grenache Differ in Their Stomatal Response to VPD: Apparent Links with ABA Physiology and Gene Expression in Leaf Tissue." *Australian Journal of Grape and Wine Research* 12(1):2–12. doi: 10.1111/j.1755-0238.2006.tb00038.x.
- Sona, Giovanna, Daniele Passoni, Livio Pinto, Diana Pagliari, Daniele Masseroni, Bianca Ortuani, and Arianna Facchi. 2016. "UAV Multispectral Survey to Map Soil and Crop for Precision Farming Applications." *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* -

- ISPRS Archives 2016-Janua(July):1023–29. doi: 10.5194/isprsarchives-XLI-B1-1023-2016.
- Soil Survey Staff. 2017. Web soil survey. USDA-NRCS <https://www.nrcs.usda.gov/sites/default/files/2022-09/The-Soil-Survey-Manual.pdf> accessed 22 september 2021
- Stark, Brandon, Brendan Smith, and Yangquan Chen. 2014. “Survey of Thermal Infrared Remote Sensing for Unmanned Aerial Systems.” 2014 International Conference on Unmanned Aircraft Systems, ICUAS 2014 - Conference Proceedings 1294–99. doi: 10.1109/ICUAS.2014.6842387.
- Tagarakis, A., V. Liakos, S. Fountas, S. Koundouras, and T. A. Gemtos. 2013. “Management Zones Delineation Using Fuzzy Clustering Techniques in Grapevines.” *Precision Agriculture* 14(1):18–39. doi: 10.1007/s11119-012-9275-4.
- Tanda, G., and V. Chiarabini. 2019. “Use of Multispectral and Thermal Imagery in Precision Viticulture.” *Journal of Physics: Conference Series* 1224(1):0–10. doi: 10.1088/1742-6596/1224/1/012034.
- Tanner, C. B. 1963. “Plant Temperatures 1.” *Agronomy Journal* 55(2):210–11. doi: 10.2134/agronj1963.00021962005500020043x.
- Tardieu, François, and Thierry Simonneau. 1998. “Variability among Species of Stomatal Control under Fluctuating Soil Water Status and Evaporative Demand: Modelling Isohydric and Anisohydric Behaviours.” *Journal of Experimental Botany* 49(SPEC. ISS.):419–32. doi: 10.1093/jxb/49.special\_issue.419.
- TISDALL, J. M., and J. M. OADES. 1982. “Organic Matter and Water-stable Aggregates in Soils.” *Journal of Soil Science* 33(2):141–63. doi: 10.1111/j.1365-2389.1982.tb01755.x.
- Tomás, M., H. Medrano, E. Brugnoli, J. M. Escalona, S. Martorell, A. Pou, M. Ribas-Carbó, and J. Flexas. 2014. “Variability of Mesophyll Conductance in Grapevine Cultivars under Water Stress Conditions in Relation to Leaf Anatomy and Water Use Efficiency.” *Australian Journal of Grape and Wine Research* 20(2):272–80. doi: 10.1111/ajgw.12069.
- Tombesi, Sergio, Andrea Nardini, Daniela Farinelli, and Alberto Palliotti. 2014. “Relationships between Stomatal Behavior, Xylem Vulnerability to Cavitation

- and Leaf Water Relations in Two Cultivars of *Vitis Vinifera*.” *Physiologia Plantarum* 152(3):453–64. doi: 10.1111/ppl.12180.
- Tsegay, D., Amsalem, D., Almeida, M., Crandles, M., 2014. Responses of grapevine rootstocks to drought stress. *Int. J. Plant Physiol. Biochem.* 6 (1), 1–6.
- Tucker, Compton J. 1979. “Red and Photographic Infrared Linear Combinations for Monitoring Vegetation.” *Remote Sensing of Environment* 8(2):127–50. doi: 10.1016/0034-4257(79)90013-0.
- Turner, N. C. 1990. “Plant Water Relations and Irrigation Management.” *Agricultural Water Management* 17(1–3):59–73. doi: 10.1016/0378-3774(90)90056-5.
- Tyree, Melvin T., and John S. Sperry. 1988. “Do Woody Plants Operate Near the Point of Catastrophic Xylem Dysfunction Caused by Dynamic Water Stress?” *Plant Physiology* 88(3):574–80. doi: 10.1104/pp.88.3.574.
- Vandeleur, Rebecca K., Gwenda Mayo, Megan C. Shelden, Matthew Gilliam, Brent N. Kaiser, and Stephen D. Tyerman. 2009. “The Role of Plasma Membrane Intrinsic Protein Aquaporins in Water Transport through Roots: Diurnal and Drought Stress Responses Reveal Different Strategies between Isohydric and Anisohydric Cultivars of Grapevine.” *Plant Physiology* 149(1):445–60. doi: 10.1104/pp.108.128645.
- Vogt, UK. 2001. “Hydraulic Vulnerability, Vessel Refilling, and Seasonal Courses of Stem Water Potential of *Sorbus Aucuparia* L. and *Sambucus Nigra* L.” *Journal of Experimental Botany* 52(360).
- Wang, Chuyuan, and Soe W. Myint. 2015. “A Simplified Empirical Line Method of Radiometric Calibration for Small Unmanned Aircraft Systems-Based Remote Sensing.” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 8(5):1876–85. doi: 10.1109/JSTARS.2015.2422716.
- Wang, Sheng, Monica Garcia, Peter Bauer-Gottwein, Jakob Jakobsen, Pablo J. Zarco-Tejada, Filippo Bandini, Verónica Sobejano Paz, and Andreas Ibrom. 2019. “High Spatial Resolution Monitoring Land Surface Energy, Water and CO<sub>2</sub> Fluxes from an Unmanned Aerial System.” *Remote Sensing of Environment* 229(June 2018):14–31. doi: 10.1016/j.rse.2019.03.040.
- Weiss, M., F. Jacob, and G. Duveiller. 2020. “Remote Sensing for Agricultural Applications: A Meta-Review.” *Remote Sensing of Environment* 236(August 2019):111402. doi: 10.1016/j.rse.2019.111402.

- Wheaton, A. D., N. C. Cooley, G. M. Dunn, I. Goodwin, X. Wang, B. Moran, and W. Yang. 2011. "USE OF THERMAL IMAGERY TO DETECT WATER STRESS DURING BERRY RIPENING IN VITIS VINIFERA L. 'CABERNET SAUVIGNON.'" *Acta Horticulturae* (889):123–30. doi: 10.17660/ActaHortic.2011.889.12.
- White, Robert E. 2020. "The Value of Soil Knowledge in Understanding Wine Terroir." *Frontiers in Environmental Science* 8(February):1–6. doi: 10.3389/fenvs.2020.00012.
- White, R. E. "The status of soil health in the viticulture and wine industry, a review." Final Report to Grape and Wine Research and Development Corporation, Project GWR 918 (2010).
- White, R. E. (2003). *Soils for fine wines*. Oxford University Press.
- Williams, Larry E., and Pilar Baeza. 2007. "Relationships among Ambient Temperature and Vapor Pressure Deficit and Leaf and Stem Water Potentials of Fully Irrigated, Field-Grown Grapevines." *American Journal of Enology and Viticulture* 58(2):173–81. doi: 10.5344/ajev.2007.58.2.173.
- Yao, C., S. Moreshet, and B. Aloni. 2001. "Water Relations and Hydraulic Control of Stomatal Behaviour in Bell Pepper Plant in Partial Soil Drying." *Plant, Cell & Environment* 24(2):227–35. doi: 10.1111/j.1365-3040.2001.00667.x.
- Yuan, Guofu, Yi Luo, Xiaomin Sun, and Dengyin Tang. 2004. "Evaluation of a Crop Water Stress Index for Detecting Water Stress in Winter Wheat in the North China Plain." *Agricultural Water Management* 64(1):29–40. doi: 10.1016/S0378-3774(03)00193-8.
- Zarco-Tejada, P. J., V. González-Dugo, L. E. Williams, L. Suárez, J. A. J. Berni, D. Goldhamer, and E. Fereres. 2013. "A PRI-Based Water Stress Index Combining Structural and Chlorophyll Effects: Assessment Using Diurnal Narrow-Band Airborne Imagery and the CWSI Thermal Index." *Remote Sensing of Environment* 138:38–50. doi: 10.1016/j.rse.2013.07.024.
- Zeraatpisheh, Mojtaba, Azam Jafari, Mohsen Bagheri Bodaghabadi, Shamsollah Ayoubi, Ruhollah Taghizadeh-Mehrjardi, Norair Toomanian, Ruth Kerry, and Ming Xu. 2020. "Conventional and Digital Soil Mapping in Iran: Past, Present, and Future." *Catena* 188(August 2019):104424. doi: 10.1016/j.catena.2019.104424.

Zhang, R., A. W. Warrick, and D. E. Myers. 1992. "Improvement of the Prediction of Soil Particle Size Fractions Using Spectral Properties." *Geoderma* 52(3–4):223–34. doi: 10.1016/0016-7061(92)90038-9.

ZHANG, XIKE, ROB R. WALKER, ROB M. STEVENS, and LYNDA D. PRIOR. 2002. "Yield-Salinity Relationships of Different Grapevine (*Vitis Vinifera* L.) Scion-Rootstock Combinations." *Australian Journal of Grape and Wine Research* 8(3):150–56. doi: 10.1111/j.1755-0238.2002.tb00250.x.

## 8 Material complementario

Epígrafe 4.3: Parámetros evaluados Ensayo 2: Caracterización del estado hídrico de las plantas

S1. Potencial hídrico del tronco (PHT, MPa) a las 9:00 y 12:00 en ambos años (2021, 2022) según los tratamientos de riego (T100, T50, T25, T0 y T25-S)

	<b>9:00</b>				
<b>Fecha</b>	<b>T100</b>	<b>T50</b>	<b>T25</b>	<b>T0</b>	<b>T25-S</b>
25/06/2021	-0.46 a	-0.50 a	-0.60 b	-0.61 b	-0.57 b
05/07/2021	-0.43 a	-0.51 a	-0.63 b	-0.85 c	-0.64 b
20/07/2021	-0.55 a	-0.55 a	-0.64 b	-0.76 c	-0.69 b
30/07/2021	-0.73 a	-0.77 a	-1.03 b	-1.17 c	-1.12 c
<b>MEDIA 2021</b>	<b>-0.54 a</b>	<b>-0.58 a</b>	<b>-0.72 b</b>	<b>-0.85 b</b>	<b>-0.75 b</b>
30/06/2022	-1.23	-1.18	-1.18	-1.11	-1.01 ns
15/07/2022	-1.38	-1.48	-1.44	-1.67	-1.31 ns
05/08/2022	-1.03 a	-1.35 b	-1.78 d	-1.60 c	-1.60 c
12/08/2022	-0.79 a	-1.06 b	-1.48 d	-1.58 d	-1.25 c
<b>MEDIA 2022</b>	<b>-1.11 a</b>	<b>-1.26 b</b>	<b>-1.47 c</b>	<b>-1.49 c</b>	<b>-1.29 b</b>
	<b>12:00</b>				
<b>Fecha</b>	<b>T100</b>	<b>T50</b>	<b>T25</b>	<b>T0</b>	<b>T25-S</b>
25/06/2021	-0.63 a	-0.73 b	-0.86 c	-0.95 d	-0.83 c
05/07/2021	-0.60 a	-0.83 b	-0.93 c	-1.05 d	-0.91 b
20/07/2021	-0.72 a	-0.86 b	-0.97 c	-1.12 d	-1.03 c
30/07/2021	-1.21	-1.15	-1.20	-1.28	-1.33 ns
<b>MEDIA 2021</b>	<b>-0.79 a</b>	<b>-0.89 ab</b>	<b>-0.99 bc</b>	<b>-1.10 c</b>	<b>-1.02 bc</b>
30/06/2022	-1.06	-1.11	-1.03	-1.04	-1.06 ns
15/07/2022	-1.57	-1.40	-1.51	-1.65	-1.37 ns
05/08/2022	-1.43 a	-1.61 b	-1.78 c	-1.79 c	-1.70 bc
12/08/2022	-1.11 a	-1.28 b	-1.67 d	-1.80 d	-1.43 c
<b>MEDIA 2022</b>	<b>-1.37 a</b>	<b>-1.43 a</b>	<b>-1.65 b</b>	<b>-1.74 b</b>	<b>-1.50 ab</b>

S2. Conductancia estomática gs ( $\text{mmol/m}^2\text{s}^{-1}$ ) a las 9:00 y 12:00 en ambos años (2021, 2022) según los tratamientos de riego (T100, T50, T25, T0 y T25-S).

	<b>9:00</b>				
<b>Fecha</b>	<b>T100</b>	<b>T50</b>	<b>T25</b>	<b>T0</b>	<b>T25-S</b>
25/06/2021	222 a	187 a	90 b	67 b	109 b
05/07/2021	227 a	238 a	157 b	144 b	146 b
20/07/2021	162 a	90 b	63 b	58 b	66 b
30/07/2021	199 a	166 b	93 c	68 c	73 c
<b>MEDIA 2021</b>	<b>202 a</b>	<b>170 a</b>	<b>100 b</b>	<b>84 b</b>	<b>99 b</b>
30/06/2022	48	47	30	24	46 ns
15/07/2022	80 a	46 b	38 bc	34 c	50 b
05/08/2022	91a	46 b	42b	40 b	56 b
12/08/2022	94 a	68 abc	43bc	35 c	76 ab
<b>MEDIA 2022</b>	<b>78 a</b>	<b>52 b</b>	<b>38 c</b>	<b>33 c</b>	<b>57 b</b>
	<b>12:00</b>				
<b>Fecha</b>	<b>T100</b>	<b>T50</b>	<b>T25</b>	<b>T0</b>	<b>T25-S</b>
25/06/2021	149 a	112 ab	43 c	60 c	65 bc
05/07/2021	172 a	151 a	79 b	55 b	88 b
20/07/2021	62 a	32 ab	18 b	40 ab	28 b
30/07/2021	130 a	76 b	53 c	38 c	40 c
<b>MEDIA 2021</b>	<b>128 a</b>	<b>93 b</b>	<b>48 c</b>	<b>48 c</b>	<b>55 c</b>
30/06/2022	33	41	56	39	22 ns
15/07/2022	69 a	35 b	26 b	32 b	25 b
05/08/2022	88 a	25 b	17 b	29 b	27 b
12/08/2022	66	56	44	31	48 ns
<b>MEDIA 2022</b>	<b>64 a</b>	<b>39 b</b>	<b>36 b</b>	<b>33 b</b>	<b>31 b</b>

S3. Clorofila (Chl, micromol/m<sup>2</sup>) a las 9:00 y 12:00 en ambos años (2021, 2022) según los tratamientos de riego (T100, T50, T25, T0 y T25-S).

	<b>9:00</b>				
<b>Fecha</b>	<b>T100</b>	<b>T50</b>	<b>T25</b>	<b>T0</b>	<b>T25-S</b>
25/06/2021	16.3	16.2	19.1	17.4	16.4 ns
05/07/2021	20.9	20.7	17.5	20.7	20.5 ns
20/07/2021	21.2 a	18.5 ab	14.3 b	17.7 ab	16.2 b
30/07/2021	28.8	26.4	22.9	24.6	22.9 ns
<b>MEDIA 2021</b>	<b>21.8</b>	<b>20.4</b>	<b>18.4</b>	<b>20.1</b>	<b>19.0 ns</b>
30/06/2022	16.3	17.1	16.6	16.2	17.0 ns
15/07/2022	15.1	17.1	17.3	15.4	17.3 ns
05/08/2022	18.4 a	16.2 b	14.2 b	14.5 b	15.7 b
12/08/2022	16.6 a	17.3 a	14.9 b	13.9 b	16.3 a
<b>MEDIA 2022</b>	<b>16.6 ab</b>	<b>16.9 a</b>	<b>15.7 bc</b>	<b>15.0 c</b>	<b>16.6 ab</b>
<b>Fecha</b>	<b>12:00</b>				
	<b>T100</b>	<b>T50</b>	<b>T25</b>	<b>T0</b>	<b>T25-S</b>
25/06/2021					
05/07/2021	20.3	19.9	18.8	18.5	17.3 ns
20/07/2021	23.7	20.3	21.5	21.1	19.0 ns
30/07/2021	23.1	23.7	22.2	22.6	24.2 ns
<b>MEDIA 2021</b>	24.1 ab	27.1 a	21.0 bc	22.5 abc	17.6 c
30/06/2022	<b>22.8</b>	<b>22.7</b>	<b>20.9</b>	<b>21.2</b>	<b>19.5ns</b>
15/07/2022	18.1	16.9	18.4	17.7	17.6 ns
05/08/2022	17.0	18.0	18.0	18.0	17.8 ns
12/08/2022	18.9 a	14.5 b	15.1 b	13.3 b	15.5 b
<b>MEDIA 2022</b>	16.2 ab	16.6 a	14.5bc	13.0 c	15.1 ab
	<b>17.5</b>	<b>16.5</b>	<b>16.5</b>	<b>15.5</b>	<b>16.5 ns</b>

S4. Temperatura de la hoja (TL) a las 9:00 y 12:00 en ambos años (2021, 2022) según los tratamientos de riego (T100, T50, T25, T0 y T25-S).

(°C)	<b>9:00</b>				
<b>Fecha</b>	<b>T100</b>	<b>T50</b>	<b>T25</b>	<b>T0</b>	<b>T25-S</b>
25/06/2021	31.4 b	31.9 b	34.1 a	34.5 a	34.1 a
05/07/2021	32.7 c	33.58 b	36.3a	36.3 a	36.1 a
20/07/2021	34.1 c	35.5 b	36.5 ab	37.3 a	37.3 a
30/07/2021	31.9 d	33.8 c	36.4 b	37.5 ab	38.2 a
<b>MEDIA 2021</b>	<b>32.5 c</b>	<b>33.7 b</b>	<b>35.8 a</b>	<b>36.4 a</b>	<b>36.4 a</b>
30/06/2022	33.7 b	37.1 a	37.0 a	37.5 a	36.9 a
15/07/2022	34.4 b	38.1 a	38.5 a	39.12 a	38.1 a
05/08/2022	36.83 b	40.3 a	40.9 a	41.2 a	40.3 a
12/08/2022	36.4 c	38.1 b	39.0 ab	39.8 a	39.1 a
<b>MEDIA 2022</b>	<b>35.3 b</b>	<b>38.4 a</b>	<b>38.9 a</b>	<b>39.4 a</b>	<b>38.6 a</b>
	<b>12:00</b>				
<b>Fecha</b>	<b>T100</b>	<b>T50</b>	<b>T25</b>	<b>T0</b>	<b>T25-S</b>
25/06/2021	36.9 b	37.5 b	40.5 a	40.1 a	39.5 a
05/07/2021	37.9 d	39.3 c	41.6 ab	42.3 a	40.7 b
20/07/2021	41.9 c	43.5 ab	44.4 a	43.2 b	43.8 ab
30/07/2021	38.2 c	39.7 b	41.33 a	42.0 a	41.1 a
<b>MEDIA 2021</b>	<b>38.8 c</b>	<b>40 bc</b>	<b>41.9 a</b>	<b>41.9 a</b>	<b>41.3 ab</b>
30/06/2022	36.9 b	37.4 b	37.0 b	38.4 a	39.0 a
15/07/2022	38.3	39.1	40.0	39.1	38.8 ns
05/08/2022	44.0 c	45.98 a	45.6 ab	45.2 abc	44.4 bc
12/08/2022	42.4 b	43.2 a	43.9 a	42.7 ab	42.8 ab
<b>MEDIA 2022</b>	<b>40.4</b>	<b>41.4</b>	<b>41.6</b>	<b>41.4</b>	<b>41.3 ns</b>

S5. Temperatura de la copa de las cepas ( $T_c$ ) a las 9:00 y 12:00 en ambos años (2021, 2022) según los tratamientos de riego (T100, T50, T25, T0 y T25-S). Niveles de significancia estadística: ns, no significativo; medias con letra distinta son significativamente diferentes,  $p < 0.05$

(°C)	9:00				
Fecha	T100	T50	T25	T0	T25-S
25/06/2021	27.5 c	28.4 b	27.9 bc	28.2 abc	28.7a
05/07/2021	31.4 c	32.8 b	33.1 b	34.1 a	34.4 a
20/07/2021	32.1 d	33.4 c	34.2 c	34.5 ab	35.3 a
30/07/2021	33.3 c	34.8 b	36.0 a	36.2 a	36.4 a
<b>MEDIA 2021</b>	<b>31.1</b>	<b>32.4</b>	<b>32.8</b>	<b>33.2</b>	<b>33.7 ns</b>
30/06/2022	31.4	31.2	32.2	31.3	31.5 ns
15/07/2022	39.5 ab	39.7 a	39.9 a	39.1 bc	38.9 c
05/08/2022	32.7 b	33.0 b	33.8 a	32.8 b	32.8 b
12/08/2022	34.8 b	35.0 b	35.8 a	35.1 b	35.3 ab
<b>MEDIA 2022</b>	<b>34.6</b>	<b>34.8</b>	<b>35.4</b>	<b>34.6</b>	<b>34.6</b>
	12:00				
Fecha	T100	T50	T25	T0	T25-S
25/06/2021	38.1 c	38.9 c	39.9 b	41.1 a	38.9 c
05/07/2021	38.9 c	40.0 c	41.2 b	42.6 a	42.6 a
20/07/2021	42.1 c	43.8 b	44.2 b	45.1 a	45.5 a
30/07/2021	35.6 c	37.1 b	37.7 b	39.8 a	39.7 a
<b>MEDIA 2021</b>	<b>38.7 c</b>	<b>40bc</b>	<b>40.7 ab</b>	<b>42.2 a</b>	<b>41.7 ab</b>
30/06/2022	41.6	41.1	41.7	43.1	41.3 ns
15/07/2022	48.3 c	49.1 b	49.5 b	51.2 a	48.0 c
05/08/2022	46.9 d	47.2 cd	48.2 b	48.9 a	47.9 bc
12/08/2022	45.9 c	46.0 c	47.7 b	49.4 a	46.2 c
<b>MEDIA 2022</b>	<b>46.7c</b>	<b>47.1 c</b>	<b>48.1 b</b>	<b>49.2 a</b>	<b>46.9 c</b>