



**universidad
de león**

**ESCUELA DE INGENIERÍA
AGRARIA Y FORESTAL**

Programa de Doctorado en Ingeniería de Biosistemas

Tesis Doctoral - PhD Thesis

**Aplicación de imágenes multispectrales e indicadores
clave monitorizados para optimizar la gestión eficiente
de parcelas de viñedo (*Vitis vinifera* L.)**

**Using multispectral imagery and monitored key parameters to
optimise the efficient management of vineyards (*Vitis vinifera* L.)**

Sergio Vélez Martín

Ingeniero Agrónomo

León, diciembre 2021

Instituto Tecnológico Agrario de Castilla y León (ITACyL)

Unidad de Cultivos Leñosos y Hortícolas



**INSTITUTO
TECNOLÓGICO
AGRARIO**



**Junta de
Castilla y León**



**Instituto Nacional de Investigación
y Tecnología Agraria y Alimentaria**



Aplicación de imágenes multispectrales e indicadores clave monitorizados para optimizar la gestión eficiente de parcelas de viñedo (*Vitis vinifera* L.)

Using multispectral imagery and monitored key parameters to optimise the efficient management of vineyards (*Vitis vinifera* L.)

Sergio Vélez Martín

MEMORIA PRESENTADA PARA LA CONSECUCCIÓN DEL TÍTULO DE DOCTOR

Dirigida por el **Dr. José Antonio Rubio Cano** y el **Dr. Enrique Barajas Tola**

Tutor: **Dr. Pedro Antonio Casquero Luelmo**

PROGRAMA DE DOCTORADO: **INGENIERÍA DE BIOSISTEMAS**



UNIVERSIDAD DE LEÓN

ESCUELA DE INGENIERÍA AGRARIA Y FORESTAL

León, diciembre 2021

Gracias a todas aquellas personas que han aportado su granito de arena para formarme como persona, como individuo, que han despertado en mí el interés por conocer y explicar las cosas que me rodean, y han contribuido a que entienda que el tiempo disponible para cumplir y desarrollar nuestras metas es limitado. Todos ellos son “mis gigantes”.

*Y, en especial, a mis padres y abuelos,
Sin ellos, no sería la persona que soy hoy.*

Gracias al Instituto Nacional de Investigación y Tecnología Agraria y Alimentaria (INIA) por financiar mi beca FPI-INIA2016-017, así como el proyecto INIA VIDIMAG RTA2014-00077-C02. Al ITACyL y JCyL, por darme la oportunidad de desarrollar esta tesis doctoral en sus instalaciones y facilitar mi labor. Sin ellos, nada de esto habría sido posible. Gracias a Bodegas Martín Berdugo y a Bodegas Cuatro Rayas por apostar por la innovación y ceder sus viñedos. A Raúl y Antonio, José y Enrique, por su colaboración, compartir sus conocimientos sobre viticultura y apoyar la investigación.

Gracias a Pedro por su accesibilidad, a Marcos y Jesús Adolfo por realizar los informes para la mención internacional. Y a José Ramón, Héctor, João, Luis Gonzaga y Claudio, por prestarse a formar parte del tribunal de la tesis. A mis profesores, en especial de INEA y de la Universidad de León, por instruirme durante la carrera y, más recientemente, facilitarme la vida con los trámites del doctorado.

Y gracias al trabajo de todos esos investigadores, sin olvidar a los “*et al.*”, que han encontrado en la investigación, la innovación y el progreso humano su razón de ser. Parafraseando a Isaac Newton: “*Si he llegado a ver más lejos que otros es porque me subí a hombros de gigantes*”.

A mis directores de Tesis, mentores y amigos José Antonio y Enrique por haberme guiado en este camino, así como por transmitirme su saber, pasión por la viticultura y por la investigación. Por el apoyo y la confianza depositada en mí, dejándome total libertad no sólo para echar a volar el dron, sino también la imaginación. Por tener el buen tino de enviarme de estancia allá donde he ido, que me ha permitido conocer gente increíble. Gracias a mis supervisores en las estancias: Federico Olmedo, Carlos Poblete y Bruno Tisseyre, no sólo por compartir su conocimiento, sino también por su hospitalidad y apoyo hasta el último momento de la tesis. Y también gracias por esos momentos de relajación y de juegos de mesa después del laburo. No todo iba a ser trabajar.

A mi buen amigo David Castrillo, compañero de penas desde la carrera, por animarme a realizar el doctorado, y a Bea, por ser clave en el inicio de esta andadura. A Vicky, Florian y la gente del INTA, Stellenbosch y SupAgro, con la que he compartido mis tareas y mis estancias, por mostrarme que el mundo es un lugar amplio y diverso, con distintas formas de enfocar el trabajo y la vida. A Raquel, por entender, saber escuchar y compartir este viaje conmigo. A Juan Carlos y Mariángeles, por apoyarme y facilitarlo todo. A Eusebio, por su garbo y por transmitirme parte de su inabarcable experiencia en viñedo. A Rubén, otro *friki* tecnológico como yo, un gran profesional que pone todos los medios a su alcance para que el trabajo salga adelante.

A mis compañeros de Unidad y amigos del ITACyL, por los cafés, conversaciones y momentos de desconexión. Pasamos un tercio de la vida trabajando y no podría haber tenido mejores camaradas, haciendo del trabajo un lugar genial y agradable, al que querer ir cada día. Y al resto de compañeros del ITACyL en investigación, laboratorios, infraestructuras, Estación Enológica y administración, por su buen hacer y su disposición. Los tengo muy presentes y todos han aportado su granito de arena para que esta tesis doctoral llegue a buen puerto. Porque hacer el doctorado es como un concierto: posible no sólo gracias a los integrantes de la banda, sino también gracias a todo el equipo ubicado entre bambalinas, que se preocupa de que todo salga como es debido.

A mis amigos, que siempre han estado ahí.

Y, en especial, a mis padres y abuelos, Nati y Alberto, y Mari y Tito, por haberme enseñado el valor del trabajo y el esfuerzo desde pequeño y porque sin ellos no sería lo que soy hoy. Y a mi hermano y al resto de la familia por hacer de ésta un entorno encantador y agradable en el que crecer.

A todos, gracias.

Abreviaturas

- ANN:** Artificial Neural Networks (Red Neuronal Artificial)
- ARIMA:** AutoRegressive Integrated Moving Average (Modelo autorregresivo integrado de media móvil)
- BOA:** Bottom of atmosphere (Parte baja de la atmósfera)
- DO:** Denominación de Origen
- DOs:** Denominaciones de Origen
- ESA:** European Space Agency (Agencia Espacial Europea)
- ETc:** Evapotranspiración del cultivo
- FAO:** Food and Agriculture Organization of the United Nations (Organización de las Naciones Unidas para la Alimentación)
- f-PCA:** functional PCA analysis (Análisis PCA funcional)
- GIS/SIG:** Geographic Information System (Sistema de Información Geográfica)
- IR:** InfraRed (Infrarrojo)
- ITACyL:** Instituto Tecnológico Agrario de Castilla y León
- LAI:** Leaf Area Index (Índice de Área Foliar)
- LWIR:** Long Wave Infrared (Infrarrojo de Onda Larga)
- METRIC:** Mapping EvapoTranspiration at high Resolution with Internalized Calibration
- MLST:** Mean Local Solar Time (Hora solar local media)
- MSI:** Multispectral Instrument
- NDVI:** Normalized Difference Vegetation Index (Índice de Vegetación de Diferencia Normalizada)
- NIR:** Near Infra Red (Infrarrojo cercano)
- OLI:** Operational Land Imager
- PAB:** Photosynthetically Active Biomass (Biomasa fotosintéticamente activa)
- PAR:** Photosynthetically Active Radiation (Radiación fotosintéticamente activa)
- PCA:** Principal Component Analysis (Análisis de Componentes Principales)

PWW: Pruning Wood Weight (Peso de madera de poda)

S: Yeast species richness (Riqueza de especies de levaduras)

SEBAL: Surface Energy Balance Algorithms for Land

SfM: Structure from motion

SS: Sample Site (Sitio de muestreo)

SSM: Site Specific management (Gestión específica del lugar)

SWIR: Short Wave Infrared (Infrarrojo de Onda Corta)

TIRS: Thermal InfraRed Sensor

TOA: Top of atmosphere (Parte alta de la atmósfera)

UAV: Unmanned Aerial Vehicle (Vehículo aéreo no tripulado)

UAVs: Unmanned Aerial Vehicles (Vehículos aéreos no tripulados)

UMD: Unidades de Manejo Diferenciado (Differentiated Management Units)

VNIR: Visible and Near Infrared (Visible e infrarrojo cercano)

VSP: Vertical Shoot Positioning (Emparrado en espaldera vertical)

Codificación UNESCO

Conforme a lo establecido en el Ministerio de Ciencia, Innovación y Universidades, el código UNESCO en el que mejor se ajusta la presente tesis doctoral es:

3103.01 Producción de cultivos

ORCID: <https://orcid.org/0000-0001-9004-2877>

ResearchGate: <https://www.researchgate.net/profile/Sergio-Velez-6>

ÍNDICE GENERAL

<u>RESUMEN</u>	<u>13</u>
<u>ABSTRACT</u>	<u>17</u>
<u>HIPÓTESIS Y OBJETIVOS</u>	<u>21</u>
<u>INTRODUCCIÓN</u>	<u>27</u>
<u>1. EL SECTOR VITIVINÍCOLA</u>	<u>27</u>
<u>2. TELEDETECCIÓN</u>	<u>31</u>
<u>3. REFERENCIAS</u>	<u>81</u>
<u>CAPÍTULO I. AGRONOMIC CLASSIFICATION BETWEEN VINEYARDS ('VERDEJO') USING NDVI AND SENTINEL-2 AND EVALUATION OF THEIR WINES.</u>	<u>101</u>
<u>CAPÍTULO II. EFFECT OF MISSING VINES ON TOTAL LEAF AREA DETERMINED BY NDVI CALCULATED FROM SENTINEL SATELLITE DATA: PROGRESSIVE VINE REMOVAL EXPERIMENTS".</u>	<u>111</u>
<u>CAPÍTULO III. ESTIMATION OF VINEYARD LEAF AREA (LAI) BY PROJECTED SHADOWS OBTAINED FROM UAV IMAGERY.</u>	<u>127</u>
<u>CAPÍTULO IV. SENTINEL-2 SATELLITE IMAGERY FOR AGRONOMIC AND QUALITY VARIABILITY ASSESSMENT OF PISTACHIO (PISTACIA VERA L.).</u>	<u>153</u>
<u>CAPÍTULO V. POTENTIAL OF FUNCTIONAL ANALYSIS APPLIED TO SENTINEL-2 TIME-SERIES TO ASSESS RELEVANT AGRONOMIC PARAMETERS AT THE WITHIN-FIELD LEVEL IN VITICULTURE.</u>	<u>169</u>
<u>CAPÍTULO VI. VITIS: BIOLOGY AND SPECIES. CHAPTER 10. REMOTE SENSING: IN THE DIGITAL VITICULTURE ERA.</u>	<u>197</u>

<u>CAPÍTULO VII. SPATIO-TEMPORAL ANALYSIS OF SATELLITE IMAGERY (NDVI) TO IDENTIFY <i>TERROIR</i> AND VINEYARD YEAST DIFFERENCES ACCORDING TO APPELLATION OF ORIGIN (AOP) AND BIOGEOGRAPHIC ORIGIN.</u>	<u>229</u>
<u>RESULTADOS Y DISCUSIÓN</u>	<u>249</u>
<u>1. RESULTADOS GENERALES</u>	<u>251</u>
<u>2. RESULTADOS Y DISCUSIÓN DEL CAPÍTULO I</u>	<u>255</u>
<u>3. RESULTADOS Y DISCUSIÓN DEL CAPÍTULO II</u>	<u>257</u>
<u>4. RESULTADOS Y DISCUSIÓN DEL CAPÍTULO III</u>	<u>259</u>
<u>5. RESULTADOS Y DISCUSIÓN DEL CAPÍTULO IV</u>	<u>267</u>
<u>6. RESULTADOS Y DISCUSIÓN DEL CAPÍTULO V</u>	<u>269</u>
<u>7. RESULTADOS Y DISCUSIÓN DEL CAPÍTULO VI</u>	<u>274</u>
<u>8. RESULTADOS Y DISCUSIÓN DEL CAPÍTULO VII</u>	<u>274</u>
<u>9. REFERENCIAS</u>	<u>276</u>
<u>CONCLUSIONES</u>	<u>283</u>
<u>CONCLUSIONS</u>	<u>287</u>



RESUMEN

RESUMEN

Según la ESA (Agencia Espacial Europea), la teledetección es una forma de recoger y analizar datos para obtener información sobre un objeto, sin que el instrumento utilizado para ello esté en contacto directo con el mismo. Esta herramienta ha demostrado su utilidad en un amplio abanico de campos, incluida la agricultura, ámbito en el que se ha generalizado el uso de imágenes multiespectrales, y podría convertirse en una importante herramienta no sólo para gestionar el cultivo, sino también en la lucha contra el cambio climático. Esta información puede utilizarse sola o combinada con otros datos para obtener mejores resultados, aportando información útil sobre el estado del viñedo. Cuatro elementos son esenciales en la teledetección: una plataforma, un objeto a medir, un sensor y la forma de utilizar y almacenar la información obtenida. En la actualidad, existen varias plataformas para obtener información: satélites, drones, aviones, vehículos terrestres, etc. De tal manera que, dependiendo de la plataforma y del sensor, se obtendrán datos con diferentes características de resolución espacial, temporal, espectral y radiométrica y, por tanto, el coste será diferente en función de la tecnología utilizada.

Las aplicaciones de la teledetección en la agricultura son una innovación reconocida y con un potencial cada vez mayor. Esta herramienta se puede emplear para diversos usos de forma muy diversa. Así, en agricultura, la información disponible suele ser tratada empleando índices de vegetación. De igual modo, se puede emplear una sola imagen en un momento determinado del ciclo fenológico (en viticultura suele ser el envero, que está relacionado con el máximo de vegetación) o también es posible emplear todas las imágenes disponibles y trabajar con series temporales. En viticultura, los estudios de investigación muestran que las técnicas de teledetección permiten evaluar la variabilidad del viñedo (*Vitis vinifera* L.) y controlar la calidad y producción de uva, además, esta herramienta se ha empleado exitosamente para estimar diversos parámetros críticos del viñedo, como el índice de área foliar (LAI).

En la presente tesis doctoral, se emplearon las imágenes obtenidas de los satélites Sentinel-2 para comprobar si tenían relación con los parámetros agronómicos y enológicos de varias parcelas situadas en la Denominación de Origen Rueda, Valladolid. Para ello se analizó una serie temporal de imágenes, confirmando que el estado fenológico de envero es un buen momento para el empleo de las imágenes. Se tomaron datos de campo en cada parcela y se mostró que las imágenes de satélite eran capaces de clasificar las parcelas en función de su desarrollo vegetativo, encontrando diferencias significativas en diversos parámetros agronómicos y de calidad de la uva. Adicionalmente, se realizó un ensayo similar en pistacho para comprobar su aplicabilidad, observando diferencias significativas en el rendimiento. Finalmente, se emplearon imágenes Landsat-8 en diversas parcelas de Galicia de las que se disponía de datos de campo relacionados con las poblaciones de levaduras para comprobar si la vegetación, identificada empleando en NDVI de las imágenes, estaba relacionada con la riqueza de especies de levaduras, encontrando diferencias significativas con respecto a las parcelas y el NDVI.

Por otra parte, se desarrolló un ensayo experimental en el que se arrancó un viñedo, marcando los píxeles del satélite sobre la superficie del viñedo y coordinando las labores con las pasadas de los satélites Sentinel-2, para comprobar el efecto de la reducción de vegetación sobre la información espectral captada por los satélites (a través del NDVI) en un cultivo como el viñedo, sometido a la problemática de los píxeles mixtos. Se midió minuciosamente en laboratorio la vegetación arrancada para comprobar la superficie exacta de vegetación extraída de la parcela, encontrando que para un viñedo en espaldera como el del estudio, cada 20% de reducción en la cantidad de vegetación supuso una reducción en el NDVI de alrededor del 6%. Adicionalmente, antes de los arranques, se tomaron ortofotografías con UAV y cámaras multiespectrales para desarrollar un método novedoso para estimar el área foliar del viñedo (LAI) empleando las sombras de las plantas proyectadas sobre el suelo del viñedo. Con este fin, se planeó la hora del vuelo con exactitud, para maximizar las sombras, posibilitando a los pilotos no sólo el empleo de un nuevo método de bajo coste con una precisión similar a métodos más costosos, sino también otorgando una mayor flexibilidad a la hora de realizar los trabajos, ya que con este nuevo método los pilotos no necesitan volar el dron al mediodía solar.

Finalmente, se realizaron dos estudios de campo exhaustivos en dos viñedos: uno en la DO Rueda y otro en la DO Ribera del Duero, en España. Se creó una malla de muestreo para tratar de captar la variabilidad espacial de los viñedos y se emplearon las imágenes de los satélites Sentinel-2 de todo un año para construir una serie temporal y aplicar un análisis funcional basado en componentes principales (f-PCA). Los resultados muestran que con dos componentes principales se explica la mayor parte de la variabilidad del viñedo y que, a partir de la tercera componente, la relación con los parámetros de campo no está clara. Por otra parte, se encontró que el empleo del f-PCA permitió alcanzar resultados mejores que simplemente una imagen de enero y cada componente principal fue capaz de explicar la variabilidad ocasionada por distintas variables del viñedo.

En la presente tesis doctoral: i) se cuantifica la relación entre la información espectral obtenida de las imágenes y los parámetros del viñedo, ii) se implementan herramientas para establecer unidades de manejo diferenciado en viñedo, incluyendo aquellas derivadas de imágenes Sentinel-2, iii) se verifica que las diferencias se trasladan a los vinos elaborados de esas unidades diferenciadas, iv) las herramientas empleadas permiten monitorizar de manera dinámica los viñedos, v) son herramientas basadas en teledetección, accesibles para los productores y de bajo coste y vi) aportan conocimiento práctico, que puede ser empleado por el sector. Además, se refuerzan los resultados a nivel global dado que los experimentos incluyeron diversos cultivares de vid, en diferentes localidades y situaciones de cultivo. La idea más relevante de la presente tesis doctoral es que el gran reto de esta "era digital en la viticultura" es disponer de profesionales con la suficiente formación para aprovechar las enormes oportunidades que brinda este tipo de tecnología y ofrecer soluciones prácticas a los agricultores y viticultores.

ABSTRACT

ABSTRACT

According to ESA (European Space Agency), remote sensing is a way of collecting and analysing data to obtain information about an object, without the instrument used to collect the data being in direct contact with said object. This tool has proven useful in a wide range of fields, including agriculture, where the use of multispectral imagery has become widespread and could become an important tool to manage vineyards and fight against climate change. Furthermore, these images can be used alone or combined with other data for better results, providing helpful information on the state of crops. Four elements are essential in remote sensing: a platform, a target object, a sensor, and a way to use and store the information obtained. Nowadays, there are several platforms for obtaining information, such as satellites, drones, aircraft, and ground vehicles. Thus, data will be obtained with different spatial, temporal, spectral and radiometric resolution characteristics depending on the platform and sensor. Consequently, the cost will be different depending on the technology used.

Remote sensing applications in agriculture are a recognised innovation with increasing potential. This tool can be used for various applications in a wide range of fields. In agriculture, the available information can be processed using vegetation indices. Similarly, it is possible to use a single image at a specific moment of the phenological cycle (usually veraison, which is related to the maximum amount of vegetation), or it is also possible to use all available images and work with time series.

In viticulture, research studies show that remote sensing techniques allow the assessment of vineyard (*Vitis vinifera* L.) variability and the control of grape quality and quantity. Remote sensing has been successfully used to estimate several vineyard parameters, such as leaf area index (LAI).

In this PhD thesis, Sentinel-2 satellite imagery was used to check if they were related to the agronomic and oenological parameters of several vineyards located in the Appellation of Origin Rueda, Valladolid. For this purpose, a time series of images was analysed, confirming that the phenological stage of veraison is a good moment for the use of the images. Field data was taken in each vineyard, and it was found that the satellite images were able to classify the vineyards according to their vegetative development, finding significant differences in several agronomic and quality parameters. In addition, a similar experiment was carried out on pistachio to check the applicability of the method, observing significant differences in yield. Finally, Landsat-8 images were used on several vineyards in Galicia. Field data related to yeast populations was compared using NDVI as an indicator of the amount of vineyard vegetation. As a result, significant differences were found concerning the plots and NDVI.

On the other hand, to study the effect of mixed pixels in vineyards, an experimental trial was carried out in a vineyard where vines were progressively removed. Thus, satellite pixels were

marked on the surface, and the removals were synchronized with the Sentinel-2 satellites imagery. The effect of the reduction of vegetation on the spectral information captured by the satellites was analysed (using NDVI). Then, the removed vegetation was carefully measured in the laboratory to check the exact leaf area, finding that for a trellised vineyard, every 20% reduction in the amount of vegetation meant a reduction of around 6% in NDVI. Additionally, before each vine removal, orthophotographs were taken with UAV and multispectral cameras to develop a novel method for estimating the leaf area of the vineyard (LAI) using the shadows of the plants projected on the ground. The flight time was carefully planned to maximise shadows, enabling pilots not only to use a new low-cost method with similar accuracy to other more expensive methods but also by providing flexibility when carrying out the work, as with this new method, pilots do not need to fly the drone in the solar midday.

Finally, two comprehensive field studies were conducted in separate vineyards: one in the DO Rueda and the other in the DO Ribera del Duero in Spain. A sampling grid was created to try to capture the spatial variability of the vineyards, and Sentinel-2 imagery taken over the course of one year was employed to construct a time series and apply a functional principal component analysis (f-PCA). The results show that the two principal components explain most of the variability in the vineyard, and that from the third component onwards, the relationship between the components and the field parameters is not clear. On the other hand, it was found that f-PCA allowed better results than solely a veraison image, and each principal component explained the variability caused by different variables in the vineyard.

In this doctoral thesis: i) the relationship between the spectral information obtained from the images and the vineyard parameters is quantified, ii) tools are implemented to establish differentiated vineyard management units, including those derived from Sentinel-2 images, iii) it is verified that the differences are transferred to the wines produced from these differentiated units, iv) the tools allow dynamic monitoring of the vineyards, v) they are remote sensing-based tools accessible to producers and low cost, and vi) they provide knowledge and present a useful product for the sector. The great challenge of this "digital era in viticulture" is to have professionals with sufficient training to take advantage of the immense opportunities of this technology and to offer practical solutions to farmers and winegrowers.

A photograph of a dirt road winding through a vineyard. The road is reddish-brown and leads into the distance, flanked by rows of green grapevines. In the background, there are dark green hills under a bright blue sky with scattered white clouds. A white rounded rectangle with a dashed border is centered in the upper half of the image, containing the text 'HIPÓTESIS Y OBJETIVOS' in bold, italicized black font.

HIPÓTESIS Y OBJETIVOS

HIPÓTESIS Y OBJETIVOS

La tesis tiene como objetivo global aportar conocimientos y herramientas tecnológicas para la caracterización de los viñedos (*Vitis vinifera* L.) según su heterogeneidad y, de este modo, mejorar la gestión, manejo del cultivo y aumentar la adaptabilidad del mismo a condiciones ambientales cambiantes, como las determinadas por el cambio climático. Para ello, se emplearán herramientas basadas en la teledetección, que permitan monitorizar de forma precisa y rápida el viñedo.

Para alcanzar el objetivo global, se establecen los siguientes objetivos específicos:

- Evaluar y cuantificar la relación entre la información espectral obtenida de las imágenes, empleando distintas plataformas y sensores, y los parámetros agronómicos y de calidad evaluados en campo (verdad terreno-datos reales).
- Estudiar la utilidad de las imágenes de satélite Sentinel-2, de acceso libre y gratuito, para delimitar unidades de manejo diferenciado en las zonas de estudio utilizando como base el índice de vegetación NDVI, comprobando la idoneidad de las imágenes obtenidas a partir de satélites para la estimación de parámetros agronómicos en viñedo.
- Facilitar herramientas para establecer UMD (Unidades de Manejo Diferenciado) en el viñedo que permitan la gestión diferencial. Estas unidades están determinadas por la tecnología disponible y los criterios del productor. Pueden ser desde una parcela completa a una planta como unidad.
- Elaborar vino, con el fin de completar el proceso productivo. Analizar su relación con las estimaciones obtenidas usando la teledetección, para comparar si esas diferencias se trasladan a los vinos elaborados de esas unidades diferenciadas, tanto analíticamente como a través del análisis sensorial mediante cata. Evaluar si se justifica el manejo diferenciado de parcelas desde las características organolépticas y analíticas del vino.
- Aportar flexibilidad en el manejo del cultivo, de modo que las herramientas permitan monitorizar de manera dinámica, en tiempo real o en un breve período de tiempo, el estado del viñedo.
- Desarrollar herramientas basadas en teledetección accesibles para los productores y de bajo o moderado coste, para que la implantación en el sector vitivinícola sea posible, aportando conocimiento útil para el sector.

The background of the slide is a pixelated image of a landscape. In the foreground, a wide, light-brown dirt path leads from the bottom center towards the middle ground. On either side of the path are rows of green grapevines, typical of a vineyard. In the background, there are dark green hills or trees under a bright blue sky filled with white, fluffy clouds. The overall style is reminiscent of low-resolution digital art or a pixelated screenshot.

INTRODUCCIÓN

ÍNDICE INTRODUCCIÓN

INTRODUCCIÓN	27
1. EL SECTOR VITIVINÍCOLA	27
1.1 EL SECTOR VITIVINÍCOLA EN EL MUNDO	27
1.2 EL SECTOR VITIVINÍCOLA EN ESPAÑA	28
1.3 EL SECTOR VITIVINÍCOLA EN CASTILLA Y LEÓN	29
2. TELEDETECCIÓN	31
2.1 TELEDETECCIÓN Y AGRICULTURA DE PRECISION	31
2.2 CONCEPTO E IMPORTANCIA DE LA TELEDETECCIÓN	33
2.3 VARIABILIDAD Y AUTOCORRELACIÓN ESPACIAL	34
2.4 RADIACIÓN ELECTROMAGNÉTICA	37
2.5 ELEMENTOS Y FLUJO DE TRABAJO DE TELEDETECCIÓN	41
2.6 SENSORES Y PLATAFORMAS	42
2.6.1 SATÉLITES	44
2.6.2 UAVs - UNMANNED AERIAL VEHICLES	51
2.7 ÁLGEBRA DE MAPAS E ÍNDICES DE VEGETACIÓN	54
2.7.1 NDVI (ÍNDICE DE VEGETACIÓN DE DIFERENCIA NORMALIZADA)	56
2.8 SERIES TEMPORALES DE IMÁGENES	58
2.9 ALGORITMOS DE CLASIFICACIÓN	63
2.10 PROBLEMA DE SOMBRAS Y PÍXELES MIXTOS EN LAS IMÁGENES DE VIÑEDO	66
2.11 SUPERFICIE FOLIAR Y LAI (LEAF AREA INDEX)	70
2.11.1 ESTIMACIÓN DEL LAI CON MÉTODOS DE TELEDETECCIÓN	73
2.12 TELEDETECCIÓN Y PARÁMETROS DE CALIDAD.	78
3. REFERENCIAS	81

INTRODUCCIÓN

1. El sector vitivinícola

1.1 El sector vitivinícola en el mundo

La viticultura y el cultivo de la viña (*Vitis vinifera* L.) es un sector muy importante a nivel mundial. No sólo es importante a nivel económico, sino también social y culturalmente, debido al empleo que genera y a la superficie plantada. Según el *Statistical Report on World Vitiviniculture* de La Organización Internacional de la Viña y el Vino (OIV, 2019), la superficie de viñedos destinados a la producción de uvas de vino, uvas de mesa o uvas pasas, en producción o en espera de producción fue de 7,4 millones de hectáreas en 2018. Además, de toda esa superficie, cinco países representan el 50% de las plantaciones de viñedo en el mundo (figura 1). Esta superficie, aunque ha descendido en los últimos 20 años, se mantiene en torno a los 7.5 millones de hectáreas.




Figura 1. Superficie de viñedo destinada a la producción de uva de vinificación, uva de mesa o uva pasificada, en producción o en espera de producción. (OIV, 2019).

Por otra parte, la producción total de uva (para vinificación, uva de mesa y pasificada) ha aumentado desde los 65 millones de toneladas en el año 2000 a los más de 75 millones de toneladas en el año 2018, principalmente empujada por un aumento en la producción de uva de mesa, ya que la producción de vino se encuentra en una situación estable desde el año 2000 de entre 260 y 290 millones de hectolitros.

Desde finales del siglo XX, la superficie mundial de viñedo se mantiene relativamente constante, con una cierta tendencia a la baja, al igual que la producción de vino. Su demanda ha crecido ligeramente, sobre todo por el aumento del consumo en Estados Unidos, Reino Unido y China. Según datos de la OIV (2019), en los países tradicionalmente productores de vino, el consumo se ha incrementado en España, Italia y Portugal desde el 2014, mientras que se mantiene estable en Francia, al igual que a nivel mundial. En este contexto, es de vital importancia para las bodegas obtener **ventajas competitivas a través de la innovación tecnológica**, que les permita competir en el mercado (Fernández et al., 2011). Máxime cuando en la viticultura mundial han existido durante el siglo pasado, especialmente marcado en su segunda mitad, dos enfoques en la actividad del sector vitivinícola: por un lado una actividad basada en un cultivo de tipo tradicional, tecnificado, ligado a siglos de historia y arraigado en su cultura social, cuyo exponente son los países productores de Europa, y otro enfoque más estrictamente técnico, competitivo y práctico en resolver las necesidades del cultivo, representado por los países de la viticultura del “Nuevo Mundo”, principalmente Australia, Argentina, Chile, Estados Unidos y Sudáfrica.

Por tanto, debido al gran peso del sector vitivinícola en el mundo, cualquier medida, mejora del manejo o desarrollo tecnológico destinado a mejorar la eficiencia en el cultivo del viñedo y adaptabilidad redundará en beneficios a nivel mundial no sólo económicos, sino también laborales y medioambientales.

1.2 El sector vitivinícola en España

El sector vitivinícola en España es muy importante. España es **el país con mayor superficie plantada** de viñedo del mundo, contando con un 13% de Superficie de viñedos destinados a la producción de uvas de vino, uvas de mesa o uvas pasas, en producción o en espera de producción, con algo más de 969.000 hectáreas.

En cuanto a producción, España ocupa el cuarto puesto, con 6,9 millones de toneladas de producción de uva, de las cuales el 96.0% se destina a elaborar vino. Se han elaborado entre 35 y 45 millones de hectolitros de vino al año, de media en los últimos años, siendo España el mayor exportador de vino del mundo, con un volumen de 21,1 millones de hectolitros. No obstante, en cuanto a facturación, sólo fue el tercero con 2,9 billones de €.

Por otra parte, el Ministerio de Agricultura, Pesca y Alimentación de España (MAPA, 2021), en su informe sobre las autorizaciones concedidas en España en 2020 y el potencial de producción vitícola, establece que el 96 % de la superficie de viñedo está bajo el amparo de alguna figura de calidad.

El cultivo del viñedo ha evolucionado en España en las últimas décadas, pero existe una fortísima competencia a todos los niveles, tanto nacional como internacional, existiendo varios países que están por delante en cuanto al uso de las nuevas tecnologías aplicadas a la viticultura.

De los dos enfoques en la actividad del sector vitivinícola citados anteriormente, España se encuentra dentro de una actividad basada en un cultivo de tipo tradicional y arraigado en su cultura social, en el que, en determinados supuestos comparados con los países del Nuevo Mundo, la implantación de nuevas tecnologías es compleja.

No obstante, la interconexión más profunda en las décadas finales del siglo XX del mercado vinícola mundial, de las empresas del sector, de la transmisión de las técnicas novedosas y de información, y de los avances de los investigadores, ha provocado que poco a poco se conecten cada tipo de las dos viticulturas y adquieran enfoques de la otra con el fin de ganar más mercado, generando así una competencia muy fuerte en la que se deben optimizar todos los aspectos del cultivo.

Adicionalmente, en los próximos años, el sector se enfrentará a uno de los retos actuales más importantes: el cambio climático. Con el uso adecuado de las nuevas herramientas tecnológicas incorporadas al mercado, será posible ajustar más los costes y producir según las aptitudes de las explotaciones y adecuarse mejor a los efectos generados por los cambios del clima. Además, estas tecnologías pueden mejorar la comprensión del cultivo para tratar de aumentar la calidad y otorgar un **valor añadido** que permita mejorar la imagen diferenciada de los vinos de España.

1.3 El sector vitivinícola en Castilla y León

Castilla y León está localizada en la mitad septentrional de la Meseta, una planicie elevada alejada del océano, situada en la parte central de la península ibérica. Está rodeada por diversas cordilleras montañosas y la mayor parte de la región se encuentra situada en altitudes superiores a los 500 metros, con una altitud media de en torno a los 800 metros. Estos factores, entre otros, originan combinaciones de temperaturas extremas y escasez de precipitaciones (en zonas de viñedo pueden ser de menos de 400 mm por año), lo que dificulta la actividad agrícola, el desarrollo de los cultivos y sus producciones. No obstante, también pueden afectar positivamente a la calidad de los cultivos que respondan positivamente a las variaciones extremas en los factores ambientales.

España tiene algo más de 505.000 km², siendo **Castilla y león la Comunidad Autónoma más extensa del país**, ya que cuenta con una superficie de algo más de 94.000 km². Además, Castilla y León es la **región más grande del conjunto de la Unión Europea**. Según la “Encuesta sobre Superficies y Rendimientos de Cultivos ESYRCE” del Ministerio de Agricultura, Pesca y Alimentación (MAPA, 2021), con datos para el 2020, la superficie de viñedo de uva de transformación en España fue de 949.565 hectáreas, un -0,34% menos que el año anterior. Castilla y León es la tercera comunidad de España respecto a superficie de cultivo, con 72.891 ha, aumentando un +4% con respecto al año anterior.

Al igual que la tecnología se ha implantado de forma diferente en los dos modelos productivos a nivel mundial, también es así con la calidad. El modelo de producción europeo está basado en gran medida en las **Denominaciones de Origen**, con controles de calidad exhaustivos, producciones limitadas y muy reguladas, mientras que en los nuevos países productores emergentes la producción está mucho más liberalizada (Vivas et al., 2013). Castilla y León, al encontrarse en España, se engloba dentro del primer modelo. Cuenta con **14 zonas reconocidas o amparadas por figuras de calidad (figura 2)**, incluyendo varias Denominaciones de Origen. Por ejemplo, Arribes, Bierzo, Ribera del Duero o Rueda. Estas dos últimas son de especial interés para la presente tesis doctoral, ya que parte de los trabajos se realizaron en viñedos pertenecientes a las mismas.




Figura 2. Figuras de calidad de vino en Castilla y León. (Modificado del atlas agroclimático del ITACyL).

Tal y como se recoge en la Ley 24/2003, de 10 de julio, de la Viña y del Vino, el objetivo de las Denominaciones de Origen es **asegurar la calidad y la procedencia** de las materias primas, estableciendo diversos controles. Cada Denominación de Origen tiene su normativa propia, más o menos exhaustiva, con el fin de controlar la calidad final de los vinos que se producen dentro de sus bordes. Esta calidad de la producción final está basada en factores tales como el estado sanitario de la planta y la uva, el desarrollo de la planta o su capacidad fotosintética (Hidalgo, 2006). Además, las DO tienen variedades diferenciadas y una tendencia a diversificar la oferta de vinos de las distintas zonas para facilitar su adaptación a la demanda del mercado. Por

tanto, es útil que tanto los productores como los organismos reguladores de las Denominaciones de Origen dispongan de herramientas basadas en las nuevas tecnologías, como la teledetección, para controlar todo este proceso y su calidad de forma rápida y precisa.

Por lo tanto, podría ser interesante desarrollar y utilizar herramientas que permitan no sólo mejorar la calidad de los productos, sino también aumentar la eficiencia, la productividad y la reducción de los insumos para que las explotaciones sean más competitivas y medioambientalmente sostenibles. En este contexto, la agricultura de precisión, incluyendo la teledetección, puede proporcionar a los viticultores y bodegueros una herramienta de toma de decisiones que puede dar información sobre todo el viñedo, además de ser asequible, fiable y rápida (Krishna, 2016). Todo ello, conduce a un **creciente interés por la agricultura de precisión**, incluyendo en el ámbito científico e investigador (Santesteban, 2019) y parece ser un área prometedora en la que actualmente se está avanzando de forma considerable. En la agricultura española también es interesante observar el aumento de la inversión en innovación tecnológica en comparación con otros sectores (INE, 2018).

2. Teledetección

2.1 Teledetección y agricultura de precisión

Según lo definido en las políticas de la Unión Europea, la **agricultura de precisión** es un concepto de **gestión agrícola basado en la observación, la medición y la respuesta a la variabilidad inter e intraparcelsaria del cultivo** (Zarco-Tejada et al., 2014). En la práctica, sus posibilidades de éxito están directamente relacionadas con la implementación de diversas tecnologías: desde las tecnologías a pie de campo, tales como sensores, plataformas, sistemas de posicionamiento global, maquinaria inteligente o robótica; hasta las herramientas de análisis como los **Sistemas de Información Geográfica (SIG)** y los sistemas de computación que se dispongan. A mayor conocimiento y grado de implementación de estas tecnologías, mayores serán las probabilidades de éxito en el manejo del cultivo.

La agricultura de precisión permite la aplicación de tratamientos y la realización de labores de forma localizada, incluso dividiendo una misma parcela en diferentes zonas. Esta es una clara ventaja con respecto al manejo tradicional en el que se realizan las labores de manera uniforme. De este modo, los fertilizantes y los plaguicidas sólo se utilizan donde y cuando son necesarios (Giles y Downey, 2003; Bongiovanni y Lowenberg-Deboer, 2004) y en las cantidades adecuadas para cada lugar, y por tanto aportando mejoras no sólo en costes sino también medioambientales, mejorando así la sostenibilidad de los procesos productivos agrícolas (Arnó et al., 2009).

Hace sólo unas décadas, los agricultores podían gestionar con precisión sus tierras de cultivo simplemente caminando sobre los campos, pero a medida que el tamaño de las explotaciones fue aumentando, esta tarea se hizo cada vez más difícil sin el uso de la tecnología (Balafoutis et al., 2017). En un mundo agrícola **cada vez más competitivo y desafiante**, es necesario contar con los instrumentos adecuados para llevar a cabo una gestión apropiada de los cultivos. Por ello, los agricultores necesitan nuevas herramientas tecnológicas que permitan no sólo mejorar la calidad de sus productos, sino también aumentar la eficiencia, la productividad y la reducción de insumos para que las explotaciones sean más competitivas. Para lograr este objetivo, el uso de la teledetección podría ser una herramienta clave, ya que permite obtener información de forma rápida, objetiva y no destructiva, de tal manera que se pueden realizar mediciones precisas del viñedo prácticamente en tiempo real (Krishna, 2016).

Las aplicaciones de la **teledetección son una innovación reconocida** y con un potencial cada vez mayor. Esta herramienta se puede emplear para diferentes usos en campos muy diversos. De este modo, se ha empleado en la evaluación de las inundaciones o de los flujos naturales de agua, la determinación de las áreas quemadas por los incendios o el avance de la desertificación (Sanyal y Lu, 2004; Joyce et al., 2009; Schnebele y Cervone, 2013; Li et al., 2018). También se emplea para analizar el ciclo del carbono en la Tierra, la cartografía de los bosques del mundo, la evaluación de los movimientos de los glaciares (Kääb et al., 2016), el rendimiento de los cultivos, los cambios en la atmósfera, la calidad del aire, el análisis del cambio climático (Yang et al., 2013), la actividad sísmica, la evaluación del impacto de la expansión urbana o el análisis de las catástrofes naturales (Seydi et al., 2021).

En agricultura también ha demostrado ser una herramienta muy útil, empleándose para predecir el rendimiento de las almendras (Zhang et al., 2019), para discriminar la calidad del nogal en función del vigor de los árboles (Martín et al., 2018) o para evaluar la dinámica de floración de las parcelas de almendros (Chen et al., 2019). También es clave en la optimización de procesos y labores agrícolas y como herramienta esencial en la toma de decisiones en muchos cultivos, tales como el trigo, la colza, el algodón, el maíz y especies leñosas (Feng et al., 2020; Lykhovyd, 2020; Mercier et al., 2020; Vilar et al., 2020; Yang et al., 2020). En viticultura, los estudios de investigación muestran que las técnicas de teledetección permiten evaluar la variabilidad del viñedo (*Vitis vinifera* L.) y controlar la calidad de la uva (Johnson et al., 2001; Lamb et al., 2008; Anastasiou et al., 2018; Capítulo I).

Por tanto, **la teledetección es una herramienta con posibilidades de empleo en todos los ámbitos de la agricultura**. Así, aunque la presente tesis está centrada en el empleo de la teledetección en viñedo, en el Capítulo IV se exploró la capacidad de la teledetección para comprobar su aplicabilidad en árboles de pistacho, debido a que, en los últimos años, el pistacho (*Pistacia vera* L.) se ha convertido en una de las especies más interesantes del sector de los frutos secos. La viabilidad de los cultivos de pistacho y su comportamiento agronómico en un lugar

determinado está condicionada por las condiciones edafoclimáticas del mismo (Ferguson et al., 2005). De este modo, las variaciones de temperatura en las diferentes localizaciones geográficas pueden influir en los procesos bioquímicos durante el desarrollo del fruto seco y pueden influir en las características nutricionales y organolépticas de los pistachos (Polari et al., 2019). Por ello, debido a las posibilidades de aplicación de la teledetección, en el Capítulo IV se empleó una metodología similar a la empleada en viñedo en el Capítulo I, utilizando la desviación típica como elemento para decidir qué imagen de la serie temporal seleccionar, ya que se buscó la mayor homogeneidad posible en la parcela para tomar su valor medio como referencia. El objetivo fue explorar la capacidad del NDVI obtenido de Sentinel-2 para evaluar las características agronómicas, fenológicas, de calidad nutricional y organolépticas del pistacho (*Pistacia vera* L.) en función del vigor (alto y bajo) durante la fase fenológica de llenado del fruto en tres parcelas de pistacho en 2018.

2.2 Concepto e importancia de la teledetección

La teledetección es una de las herramientas que podemos emplear en agricultura de precisión. Según la ESA (European Space Agency, 2015), **la teledetección es "una forma de recoger y analizar datos para obtener información sobre un objeto, sin contacto"**, y es reconocida por organizaciones internacionales (FAO, 2021) como una herramienta muy valiosa, capaz de aumentar las producciones, mejorar la calidad y ayudar en la adaptación al cambio climático. En el caso concreto de la península ibérica, los modelos predicen que habrá un aumento de la duración de las olas de calor, con un incremento del número de días al año, con una tendencia global positiva de 6,4 días/década. El aumento en la duración será de 15 días en la región mediterránea y un mínimo de 6 días en las regiones septentrionales y occidentales (Lorenzo et al., 2021). Por tanto, la teledetección es una herramienta que puede tener un alto impacto en la adaptación a las nuevas condiciones climáticas. Adicionalmente, como se ha indicado, ha demostrado su utilidad en un amplio abanico de campos, entre ellos la agricultura, en la que el uso de imágenes multiespectrales (que contienen información espectral dividida en bandas según varias longitudes de onda) se ha generalizado, y podría llegar a tener un papel **importante** no sólo por su **capacidad para mitigar los impactos del cambio climático, sino también para facilitar la mejora en la eficiencia de los procesos agrícolas**. Las imágenes multiespectrales, pueden utilizarse solas o combinadas con otros datos para obtener mejores resultados, dando información útil sobre el estado del cultivo.

El potencial de la teledetección se basa en su versatilidad, que permite desarrollar otros instrumentos útiles, tanto a pequeña escala como de uso masivo. Un ejemplo de este último tipo es la herramienta WaPOR, usada en todo el mundo y disponible en el portal de la FAO. WaPOR sirve para supervisar la productividad del agua mediante el acceso abierto a los datos derivados de la teledetección (https://wapor.apps.fao.org/home/WAPOR_2/2, accedido el 1/11/2021),

basada en una versión modificada del modelo ETLook descrito en Bastiaanssen et al. (2012). Es una prueba de que la mayor ventaja del uso de datos de teledetección es la capacidad de generar información espacial y temporal de forma rápida, objetiva y fiable. En las últimas tres décadas se ha avanzado mucho en el desarrollo de procedimientos analíticos y herramientas para procesar e interpretar los datos de teledetección espacial y combinarlos con las mediciones terrestres para las aplicaciones agrícolas.

Con respecto a la aplicación de la teledetección en España, durante las tres últimas décadas se ha avanzado de modo importante en aspectos enológicos (utilizando tecnología sobre todo para el control y la monitorización del proceso de elaboración). No obstante, el avance no ha llegado con tanta nitidez a la viticultura. El diagnóstico para lograr una mejor viticultura en España puede sintetizarse en varios puntos clave, considerando que se pueden aplicar avances técnicos para lograr una viticultura más eficiente, con la que se pueda producir en óptimas condiciones de calidad y cantidad, y recoger las mejores uvas posibles en su punto óptimo de madurez y sanidad (Del Rey, 2013).

En la presente tesis doctoral se empleó la teledetección, utilizando la aplicación de imágenes multiespectrales e indicadores clave monitorizados para la gestión eficiente de parcelas de viñedo, con el objetivo de aportar metodología y conocimiento específico para la **caracterización y la valoración continua de subparcelas** (Unidades de Manejo Diferenciado, UMD), utilizando diversas herramientas de viticultura de precisión que optimicen la gestión de las subparcelas durante el proceso de cultivo.

2.3 Variabilidad y autocorrelación espacial

La **variabilidad espacial** se produce cuando una variable que se mide en diferentes ubicaciones espaciales presenta **valores que difieren** entre ellas. La primera consideración acerca de esta variabilidad aparece en un trabajo de Mercer y Hall (1911) que estudiaron las variaciones en el rendimiento del cultivo en distintas parcelas, demostrando que la varianza entre parcelas disminuía a medida que el tamaño de la parcela aumentaba.

Esta variabilidad tiene importantes implicaciones para el desarrollo de protocolos de gestión precisos y específicos para cada lugar en cuanto al manejo del cultivo, por ejemplo, en cuanto a nutrientes y riego (Mueller y Sassenrath, 2015). Es bien conocido que la variación espacial dentro de una parcela de cultivo es muy significativa (Birrel et al., 1995), debida entre otras cosas a la variabilidad de los factores ambientales, incluyendo la meteorología (Hubbard, 1994) o el suelo (Corwin et al., 2012).

Cardina et al. (1997) establecen que es importante conocer esta variabilidad espacial, ya que condiciona elementos que afectan al cultivo, tales como las malas hierbas, que están afectados por esta variabilidad espacial y crecen en distintas zonas, de diferente tamaño, forma y

composición dentro de las parcelas. Por tanto, si se puede conocer esta variabilidad espacial, es posible evitar realizar tratamientos en función de la población media de malas hierbas, aplicando fitosanitarios de manera uniforme en todo el campo.

La **gestión específica del lugar** (SSM) intenta gestionar los parámetros que se ven afectados por la variabilidad espacial, tales como el suelo, las plagas o los cultivos, basándose en los cambios dentro de la parcela (Larson y Robert 1995). Su empleo se basa en la falta de eficiencia al gestionar estas variables de manera uniforme, por lo que **los sistemas de cultivo deben tener en cuenta las características del lugar**. Es una lógica similar a la empleada posteriormente por Santesteban et al. (2010) para definir UMD (Unidades de Manejo Diferenciado) en la gestión de viñedo.

La **variabilidad espacial en los viñedos es una cuestión crítica**, caracterizada por una fuerte estructura espacial que suele ser estable en el tiempo (Bramley y Lamb, 2003), y que se ve afectada por varios factores. Algunos de ellos son relativamente invariables a lo largo del tiempo y pueden manejarse mediante una gestión diferenciada del cultivo (Bramley y Hamilton, 2008). Aunque la agricultura de precisión puede mejorar los rendimientos, la ventaja más significativa es la reducción de las variaciones de rendimiento, lo que conduce a una mayor estabilidad y resistencia a los cambios climáticos (Yost et al., 2016).

Por tanto, evaluar y gestionar la variabilidad espacial en los sistemas agrícolas es una parte esencial, y la **teledetección es una herramienta clave en este proceso** (Pierce y Clay, 2007). Los viñedos, como cualquier cultivo, deben de estar sometidos a una gestión diferencial para actuar sobre la variabilidad, tanto si las parcelas son distintas como dentro de la propia parcela. En los Capítulos I, IV y VII se llevó a cabo un estudio acerca de la variabilidad de parcelas en distintas localizaciones, analizando las diferencias en parámetros agronómicos y de calidad de fruto, mientras que en los Capítulos III y V se analizó la variabilidad dentro de la propia parcela, a nivel de planta y en diferentes zonas de la parcela a nivel de sitios de muestreo (SS), respectivamente. Con esta información es posible establecer Unidades de Manejo Diferenciado para gestionar individualmente cada zona.

Por otra parte, otro concepto crítico es la **autocorrelación espacial**. La Primera Ley de Geografía de Tobler o principio de autocorrelación espacial establece que *“Todo está relacionado con todo, pero las cosas cercanas están más relacionadas que las lejanas”*. Es un concepto similar al de dependencia espacial que constituye la base de la geoestadística. La autocorrelación espacial permite medir el grado en que un objeto es similar a otro objeto cercano.

La **zonificación del viñedo** y creación de Unidades de Manejo Diferenciado **no tendría sentido si no existiese autocorrelación espacial**. Esto quiere decir que existen una dependencia espacial entre todas las variables que afectan al viñedo, tales como la climatología, la temperatura, la humedad, la edafología, etc. Los fenómenos naturales se distribuyen

espacialmente, de este modo, si llueve en un lugar, existe una mayor probabilidad de lluvia en una localización cercana que en una lejana.

Esta autocorrelación se tiene en cuenta en metodologías como el *Kriging*, un método geoestadístico de predicción que se basa en la información que aporta el variograma o **semivariograma**, es decir, la correlación espacial. El variograma permite analizar el comportamiento espacial de una variable sobre un área definida, reflejando la distancia máxima y la forma en que un punto tiene influencia sobre otro punto a diferentes distancias, mediante la fórmula siguiente:

$$\hat{z}(x_0) = \sum_{i=1}^N \lambda_i z(x_i)$$

donde $\hat{z}$ es el valor que queremos estimar en el punto x_0 , λ_i son los pesos y z son los valores conocidos en los puntos x_i .

Esta técnica se empleó en el Capítulo V para crear los mapas de cada variable y disponer de información visual adicional para analizar los resultados del análisis funcional y facilitar la interpretación agronómica (Figura 3).




Figura 3. Ejemplo de mapas empleando kriging para interpolar variables (Capítulo V).

Finalmente, es importante llevar a cabo un **muestreo representativo** de la parcela para disponer de un conjunto de datos de campo fiable. Con el fin de mapear eficientemente la variabilidad espacial teniendo en cuenta la autocorrelación espacial, consiguiendo una cobertura relativamente uniforme, los datos de campo se deben obtener realizando un **muestreo sistemático en forma de malla de muestreo**, bien con triángulos, bien mediante una cuadrícula rectangular (Webster y Oliver, 2007; figura 4).



Figura 4 – Sitios de muestreo empleando una malla de muestreo (Capítulo V).

Para la toma de datos de campo del Capítulo V, se tuvo en cuenta esta pauta, estableciendo una malla de sitios de muestreo (SS) distribuidos equitativamente en cada viñedo: 16 SS en el viñedo situado en la DO Rueda, con 10 plantas de vid por SS, y 98 SS en el viñedo situado en Ribera del Duero, con 3 plantas de vid por SS, en el que además se evaluaron puntos centrales, indicados en color rojo en la figura 4, para mediciones aún más exhaustivas y toma de muestras de suelo. El resultado fue un total de 160 vides y 294 vides muestreadas, respectivamente. El viñedo de Ribera del Duero era más grande, por lo que para conseguir una cobertura completa se incluyeron menos plantas por SS. Cada SS se georreferenció con un receptor RTK Triumph-2 (Javad, EE. UU.) conectado vía Bluetooth a un smartphone Android para acceder a las señales de corrección RTK locales.

2.4 Radiación electromagnética

La naturaleza de la radiación electromagnética se puede manifestar de dos formas diferentes (Hecht, 2017): como onda (Huygens, Maxwell), que asumen que la radiación viaja por el espacio a la velocidad de la luz con una longitud y frecuencia de onda determinadas, y es el

resultado de oscilaciones en dos campos de fuerzas ortogonales entre sí, eléctrico y magnético; y como partícula (Planck, Einstein), que asume que la energía viaja como un flujo de partículas, los fotones.

Desde la perspectiva de la mecánica cuántica, el fotón no tiene masa en reposo, no se desintegra espontáneamente en el vacío, no tiene carga eléctrica, y su energía E depende de la frecuencia a través de la relación establecida por Einstein:

$$E = h \nu$$

donde ν es la frecuencia de la onda electromagnética y h es la constante de Planck.

Además, empleando la relación entre la frecuencia y la longitud de onda:

$$E = h c / \lambda$$

donde c es la velocidad de la luz en el vacío y λ es la longitud de onda del fotón. Esta relación muestra que la energía del fotón es inversamente proporcional a su longitud de onda. Por tanto, un fotón de luz roja transportará menos energía que un fotón de luz azul (Keller, 2014).

La **radiación electromagnética que recibimos de un objeto depende de la energía absorbida, transmitida, reflejada y emitida por el mismo** (Sharma, 2006). Su espectro de emisión es el espectro de frecuencias de radiación electromagnética que emite, y está relacionado con su **espectro de absorción**, que afecta a la fracción de la radiación electromagnética incidente que absorbe dentro de un rango de frecuencias y, por tanto, la que refleja. Esta reflectividad mide la fracción de radiación incidente reflejada por una superficie. Depende, entre otros factores, de las propiedades del objeto y de su geometría, ya que afecta a los ángulos de reflexión de los rayos de luz sobre el objeto (Hecht, 2017). El albedo normalmente hace referencia a la reflectividad de la superficie terrestre. Asumiendo la superficie como lambertiana (superficie ideal que refleja la energía incidente desde una dirección igual en todas direcciones), la reflectividad ρ se puede definir como:

$$\rho(\lambda) = \frac{\pi L(\lambda)}{\mu_s E_s(\lambda)}$$

donde $L(\lambda)$ es la irradiancia espectral reflejada desde la superficie ($\text{Wm}^{-2} \text{sr}^{-1} \mu\text{m}^{-1}$); $\pi L(\lambda)$ es la radiancia espectral reflejada; $\mu_s = \cos\theta$, donde θ es el ángulo cenital solar; $E_s(\lambda)$ es la irradiancia espectral incidente proveniente del Sol ($\text{Wm}^{-2} \mu\text{m}^{-1}$) y $\mu_s E_s(\lambda)$ es la parte de la irradiancia espectral incidente que impacta en la superficie (Valiente et al., 1995).

En cuanto a la radiación electromagnética emitida, todo objeto cuya temperatura se encuentre por encima de cero Kelvin (0 K, -273,15 °C) comienza a irradiar energía en diferentes longitudes de onda, según la temperatura a la que se encuentra. La **Ley de Planck** establece la

radiación electromagnética emitida por un cuerpo negro en equilibrio térmico en una temperatura definida como:

$$M_{\lambda} = \frac{c_1}{\lambda^5 (e^{\frac{c_2}{\lambda T}} - 1)}$$

donde M_{λ} es el Flujo de radiación ($W^{-1} m^{-2}$), que es la cantidad de energía emitida en la longitud de onda correspondiente (λ) por cada metro cuadrado de superficie del objeto cada segundo. T es la temperatura (K) y c_1 y c_2 son constantes.

De la ley de Planck se deriva la **Ley de Stefan-Boltzmann**, que establece la radiación emitida por un objeto por unidad de superficie:

$$E = \varepsilon \sigma (T_e)^4$$

donde E es la potencia emisiva hemisférica total ($W^{-1} m^{-2}$), ε es la emisividad, una que describe la eficacia de un objeto para emitir radiación térmica, σ es la constante de Stefan-Boltzmann y T_e es la temperatura efectiva de la superficie (K).




Figura 5. Espectro electromagnético.

En el sistema solar, el **Sol es la principal fuente de energía electromagnética**. La radiación que recibe la Tierra tiene distintas longitudes de onda, aunque el ojo humano sólo puede percibir radiación en un determinado rango que se denomina **luz visible** (Figura 5). Este rango se encuentra aproximadamente entre los 0,4 y 0,7 micrómetros (Shankar, 2016), y el color que observamos en los objetos es función de este parámetro (Figura 6). Se pueden diferenciar tres bandas principales: azul (entre 0,4 y 0,5 micrómetros), verde (entre 0,5 y 0,6 micrómetros) y rojo (entre 0,6 y 0,7 micrómetros).

Adicionalmente, existen otras regiones del espectro electromagnético que no son visibles para el ojo humano, sin embargo, sí que **pueden ser percibidas por los distintos sensores** que se pueden emplear. De este modo, el infrarrojo se puede evaluar con sensores especiales, siendo el infrarrojo cercano (NIR) y el infrarrojo de onda corta (SWIR) de especial interés en agricultura, así como el infrarrojo de onda larga (LWIR), que permite evaluar la temperatura a la que están los objetos. Existen otras regiones interesantes, como las ondas de radio, que tienen longitudes de onda mayores de 1 mm, útiles en el empleo del radar y permiten interactuar con superficies para definir su estructura.




Figura 6. Reflexión de la luz y color en función de las propiedades del objeto.

Por tanto, el **color** y la radiación que reflectan o emiten los objetos son recibidos por los sensores, y **depende del espectro de absorción** de la radiación de los elementos que componen dicho objeto. En agricultura, el color y la radiación que reciben los sensores proviene de las plantas, y depende del espectro de absorción de la radiación de los pigmentos que las componen (Figura 7). La **clorofila** suele ser el pigmento más importante, y hace que las hojas sean verdes ya que absorbe la luz en las longitudes de onda del violeta y el azul principalmente (entre 420 y 480 nm) y también del rojo (entre 640 y 700 nm), por lo que la luz reflejada por las plantas es mayoritariamente verde (Evert y Eichhorn, 2013).

Además, Kumar y Silva (1973) descubrieron que, para un mismo tipo de cultivo, la reflectancia en el infrarrojo cercano ($\lambda = 700\text{-}1300\text{ nm}$) y en el rojo ($\lambda = 550\text{-}700\text{ nm}$) difiere según su estado. Como se ha indicado, el ojo humano sólo es capaz de ver la luz en el espectro visible, pero es posible captar información de otras zonas del espectro electromagnético mediante sensores montados en diversas plataformas, como vehículos aéreos no tripulados (UAV), aviones, satélites o incluso un trípode a pie de campo.




Figura 7. *Signatura espectral de la hoja (Hidalgo, 2006).*

2.5 Elementos y flujo de trabajo de teledetección

Para aplicar las técnicas de teledetección, son esenciales cuatro elementos (ESA, 2015):

1. Una **plataforma**, para transportar el instrumento;
2. El **objeto** que se va a observar;
3. Un instrumento o un **sensor**, para observar el objeto;

Y el último, y principal elemento de la teledetección:

4. Cómo se utiliza y almacena la **información** que se obtiene de los datos adquiridos.

Tal y como se establece en el Capítulo VI, una aproximación general al flujo de trabajo en teledetección podría ser (Figura 8):

1. **Obtención de la información:** Se puede adquirir empleando diferentes combinaciones de sensores y plataformas. Debido a sus características intrínsecas, la información del satélite depende directamente del sensor que transportan, no obstante, si se emplean otras plataformas, por ejemplo, UAVs, se puede intercambiar el sensor, empleando cámaras multiespectrales como las empleadas en el Capítulo III.
2. **Procesamiento de la información,** de forma local con ordenadores o servidores propios, o en la nube. Para ello se emplean algoritmos, índices de vegetación, etc.
3. **Interpretar los resultados:** Es decir, convertir los datos de teledetección en información útil para tomar decisiones.



Figura 8. Flujo de trabajo de teledetección.

Finalmente, la **interpretación** es muy importante, ya que muchos elementos influyen en las imágenes. Cuando se toma una imagen de un cultivo, se obtiene información sobre las superficies de todos los elementos de la imagen. Por lo tanto, la información depende de las características del cultivo que se analice, ya que **difiere en gran medida de unos cultivos a otros**. Por ejemplo, el trigo y la vid tienen ciclos fenológicos, crecimientos y desarrollos vegetativos diferentes. En el caso del viñedo, además, hay que tener en cuenta muchos factores, como la edad del viñedo, ya que es un cultivo **plurianual**, la separación entre filas y entre plantas, o la **influencia del suelo** debida a la falta de cobertura completa, entre otros. En el Capítulo II se analizó la influencia del suelo y la falta de vegetación, para complementar la literatura acerca de la influencia de los píxeles mixtos y la falta de vegetación en viñedo con imágenes de satélite.

2.6 Sensores y plataformas

Los sensores son los dispositivos que reciben y codifican la información de la superficie de los objetos o de la Tierra. Sus características, sus aplicaciones y la calidad de sus medidas dependen de múltiples factores, tales como la **resolución del instrumento, su calidad radiométrica, la profundidad del píxel**, etc. Se puede realizar una clasificación básica en función del modo en que utilizan la energía:

- Sensores **pasivos**: recogen la energía que proviene de los objetos. Ésta puede ser emitida por el propio objeto o reflejada, en cuyo caso proviene del Sol o de una fuente de energía externa (por ejemplo: focos o iluminación).
- Sensores **activos**: emiten energía hacia la superficie del objeto, ésta interacciona y regresa al instrumento para ser analizada. El radar sería un ejemplo de este tipo.

La plataforma es un objeto donde se acopla el sensor. Éstas pueden ser terrestres, y suelen estar acopladas en vehículos todoterreno, tractores o similares. La plataforma también puede ser aérea, normalmente aviones, pero últimamente se utilizan mayormente pequeños **vehículos aéreos no tripulados (UAV)**. Y, por último, la plataforma puede ser espacial, es decir, por **satélite**. Las plataformas aéreas más utilizadas para la obtención de imágenes son los satélites, los aviones y los vehículos aéreos no tripulados (UAV), que suelen estar asociados a una resolución espacial baja, media y alta, respectivamente. Para el desarrollo de esta tesis, se emplearon satélites (Capítulos I, II, IV, V y VII) y UAV (Capítulo III).

Las características de la plataforma, del sensor, y la combinación de ambos, tendrán como resultado una determinada resolución, que hace referencia a la capacidad de un sistema para **discriminar información espectral**. Principalmente, se pueden distinguir cuatro tipos de resolución: i) **espectral**, que indica en qué zonas del Espectro Electromagnético trabaja el sensor, ii) **radiométrica**, reflejando el nivel de sensibilidad a la intensidad de la radiación, iii) **temporal**, mostrando cada cuánto tiempo se pueden obtener imágenes y iv) **espacial**, relacionada con el nivel de detalle de las imágenes, usualmente en píxeles. Este último es al que comúnmente se hace referencia al emplear el término genérico “resolución”.

La elección de la plataforma y sensor con el que trabajar es una de las primeras decisiones que hay que tomar, y quizá la que más condicionará el trabajo posterior. Su elección dependerá del **objetivo del trabajo** y de las **características del viñedo**. Las imágenes de satélite no pueden obtener una resolución tan alta como las imágenes de UAV, pero hay que tener en cuenta que, si la finca es muy grande, o se van a estudiar varias fincas al mismo tiempo, las imágenes por satélite quizá sean mejor opción, ya que tienen menor coste en comparación con las imágenes de UAV o de vehículos robóticos terrestres (Krishna, 2016). Por otra parte, el uso de vehículos aéreos no tripulados o aeronaves implica una inversión inicial, así como disponer de personal cualificado capaz de configurar y pilotar estos dispositivos y realizar el posterior procesamiento de los datos obtenidos (Grenzdörffer et al., 2008). Sin embargo, los proveedores de imágenes por satélite ya sean gratuitas o no, proporcionan una imagen lista para trabajar. Todo ello aumenta los costes de unas tecnologías sobre otras e incluso se ha establecido un valor umbral: 5 hectáreas. Por encima de ese tamaño de escala la imagen tomada por satélite puede ser más conveniente (Matese et al., 2015). En todo caso, si es posible emplear varias fuentes de imágenes, **los vehículos aéreos no tripulados ofrecen un perfil diferente y complementario al de los satélites** (Emilien et al.,

2021) y la combinación de estas tecnologías puede ayudar en el proceso de toma de decisiones (Maes y Steppe, 2019).

2.6.1 Satélites

En la órbita terrestre, existen **infinidad de satélites** para todo tipo de usos: de comunicaciones, con fines militares, etc. Y también los que se pueden emplear para obtener información de la superficie de la Tierra. Esto se traduce en que este tipo de satélites orbitan junto a miles de satélites más (Figura 9).




Figura 9. Satélite Sentinel-2 orbitando la tierra sobre Europa, coincidiendo con el mediodía solar para evitar la incidencia de sombras y ruidos.

De este modo, numerosos satélites en órbita **generan continuamente imágenes de la superficie terrestre**, existiendo dos tipos de constelaciones de satélites, según la disponibilidad de sus imágenes:

- Imágenes de **pago**, proporcionadas por satélites como GeoEye o WorldView.
- Imágenes **gratuitas**, por ejemplo, Landsat o Sentinel, que se emplearon en esta tesis. Normalmente, tienen una menor resolución espacial que las imágenes de pago.

Algunas de las ventajas de los satélites con respecto a otras plataformas, son:

- Tienen un tiempo de **revisita regular**, que no depende de la intervención del usuario. Esta periodicidad depende de la resolución temporal del satélite, así como del número de satélites de la constelación, lo que permite analizar las imágenes más convenientes para trabajar (Capítulos I, II y IV) o crear series temporales precisas, como las empleadas en el Capítulo V;
- Permiten el acceso a **imágenes históricas**, lo que permitió realizar el trabajo expuesto en el Capítulo VII, ya que en un principio no estaba planificada la colaboración;
- Proporcionan imágenes, **aunque haya meteorología adversa** (excepto nubes).

También tienen otras ventajas, como que los sensores montados en satélites suelen tener una mejor resolución espectral y radiométrica debida a una mejor electrónica. También es posible obtener una gran imagen de toda la zona al mismo tiempo, por lo que se pueden **comparar los viñedos al mismo tiempo**, evitando errores que se pueden dar empleando otros sensores y plataformas, como en el caso de diferentes calibraciones de las fotografías y ensamblado de los mosaicos de imágenes de UAVs.

Además, es posible combinar la información de diferentes sensores montados en distintos satélites para mejorar la resolución espacial (Chang y Shoshany, 2016) y mejorar el co-registro de las imágenes empleando procesos automatizados (Stumpf et al., 2018). Incluso los datos ópticos pueden ser sustituidos por datos de microondas en presencia de nubosidad (Navarro et al., 2016).

Sin embargo, los satélites también tienen una serie de desventajas, como una **resolución espacial mucho menor** que otras plataformas, por lo que cada píxel contiene información sobre la vegetación y el suelo, generando problemas como los “**píxeles mixtos**” contemplados en el Capítulo II. También, el **porcentaje de nubosidad** supone un impedimento, pudiendo inutilizar las imágenes obtenidas.

Finalmente, es importante destacar que dentro de cada grupo hay muchos tipos de sensores y productos, ya que **no todas las cámaras, satélites o UAVs son iguales**. Por ejemplo, cuando optamos por utilizar imágenes de satélite, las resoluciones varían en función del sensor elegido, siendo un factor clave elegir una fuente de imágenes adecuada (Sertel et al., 2012).

En cuanto a los satélites de uso gratuito, los satélites **Landsat y Sentinel** pueden ser muy útiles y se han utilizado para aplicaciones tan dispares como la detección de movimientos previos a un desprendimiento (Lacroix et al., 2018), la medición del flujo de hielo y la cuantificación de las velocidades estacionales del mismo (Kääb et al., 2016), para evaluar la dinámica de floración de las parcelas de almendros (Chen et al., 2019) y para clasificar los viñedos según su vigor (Di Gennaro, 2019; Capítulo I). Zhang et al. (2018) han discutido las diferencias en la información recogida por el sensor MSI de Sentinel-2A y el sensor OLI de Landsat-8, observando que la

reflectancia de la superficie obtenida con el sensor MSI era mayor que la reflectancia de la superficie obtenida con OLI en casi todas las bandas, y que el NDVI de la superficie obtenido con MSI era mayor que el de la superficie obtenido con OLI. No obstante, Li y Roy (2017) indican que **es posible combinar imágenes de satélite de diferentes plataformas** (Sentinel-2A, Sentinel-2B y Landsat 8) para conseguir un intervalo medio de adquisición de imágenes inferior a 3 días, ya que el valor de MLST en todos estos casos es similar. Sea como fuere, ambas misiones de satélites pueden ser especialmente útiles debido a su carácter gratuito, a la accesibilidad de sus imágenes, a la **similitud de las bandas que emplean** (Figura 10) y a que las imágenes tienen una resolución moderada, con una resolución temporal aceptable. Además, estos satélites proporcionan información espectral en múltiples bandas que permiten el cálculo de diversos índices de vegetación, que son de gran interés para aplicaciones agrícolas y, en particular, las bandas que cubren el intervalo espectral rojo/infrarrojo cercano de 650nm a 900nm que permite el cálculo del NDVI, en el que se profundizará posteriormente.




Figura 10. Comparación de bandas Landsat-7, Landsat-8 y Sentinel-2. (USGS, 2021).

Sin embargo, una deficiencia de estos satélites de uso gratuito es su baja resolución espacial. Dado que muchos viñedos son superficies pequeñas (de 1 a 20 ha), una alternativa es utilizar imágenes de alta resolución espacial, para disminuir o evitar problemas como el de los píxeles mixtos (Fuentes et al., 2014), que se tratará más adelante. Además de la resolución espacial, hay que tener en cuenta la calidad de los sensores desde el punto de vista radiométrico, porque los índices de vegetación se construyen calculando los valores de reflectancia de la luz. Así, la calidad de un sensor debe definirse al menos atendiendo a su resolución espacial y a su resolución radiométrica. Vila et al. (2007) compararon dos sensores multiespectrales con diferente resolución espacial y sensibilidad radiométrica, uno satelital (QuickBird) y otro aéreo,

como estimadores de la biomasa del viñedo, utilizando NDVI y SR, dos índices que se explicarán más adelante. El trabajo se repitió en dos sistemas de conducción: parral (dosel horizontal) y espaldera (dosel vertical), debido a la dificultad de trabajar con árboles frutales, ya que no tienen superficies lambertianas perfectas y, por tanto, los resultados pueden estar influidos por la forma de las plantas y la relación entre el dosel y el suelo no cultivado. Se llegó a la conclusión de que las imágenes multiespectrales aéreas y de satélite de alta resolución son adecuadas para discriminar las zonas de viñedos con diferente producción de biomasa. Las imágenes de satélite fueron mejores por su mayor calidad radiométrica. En todo caso, aunque los datos de **Sentinel-2** tienen una resolución espacial inferior a la de otros satélites y a las tomadas con UAV, se sabe que son capaces de **detectar una variabilidad espacial relevante dentro del viñedo** en ausencia de hierba entre hileras y si la gestión individual de cada vid no es el objetivo (Sozzi et al., 2020; Di Gennaro et al., 2019).

En este contexto, **los satélites pueden utilizarse para varias aplicaciones y se han utilizado ampliamente en los estudios de los viñedos** para diversos usos, como el análisis de la variabilidad dentro del campo del estado hídrico del suelo y de las plantas (Borgogno-Mondino et al., 2018), la predicción de la cosecha (Sun et al., 2017), el análisis de la heterogeneidad espacial de la evapotranspiración (Knipper et al., 2019) o la clasificación de los campos de vid según su nivel de vigor (Di Gennaro et al., 2019).

2.6.1.1 Misión Landsat

Según la NASA (2021), la misión Landsat, una colaboración entre la NASA y el Servicio Geológico de Estados Unidos, representa el programa de obtención de imágenes de la Tierra más largo de la historia, desde el lanzamiento de Landsat-1 en 1972 hasta el más reciente Landsat-9, lanzado el 27 de septiembre de 2021. Es el **registro continuo más largo** de los cambios en la superficie de la Tierra vistos desde el espacio. Con el fin de reducir el tiempo de construcción y el riesgo de un vacío en las observaciones, Landsat 9 replica en gran medida a su predecesor Landsat 8. Al igual que Landsat 8, Landsat 9 cuenta con instrumentos científicos que ofrecen imágenes con una **resolución de 15, 30 y 100 metros**, dependiendo de la banda espectral, aunque Landsat 9 tiene un rango de intensidad más alto, con una resolución radiométrica de 14 bits frente a la resolución radiométrica de 12 bits de Landsat 8.

Los principales objetivos de la misión son recoger y archivar datos de imágenes térmicas y multiespectrales reflectantes de resolución moderada que ofrezcan una cobertura estacional de la masa terrestre mundial, ofreciendo datos consistentes entre todos los satélites y distribuyendo los productos de datos a los usuarios de forma no discriminatoria y sin coste alguno.

2.6.1.1.1 Landsat 8

El 11 de febrero de 2013 se lanzó el satélite Landsat 8, que proporciona mediciones de resolución moderada cada 16 días de las regiones terrestres y polares de la Tierra en el visible, el infrarrojo cercano, el infrarrojo de onda corta y el infrarrojo térmico. Las imágenes Landsat 8 sirven para estudiar el clima, el ciclo del carbono, los ecosistemas, el ciclo del agua, la biogeoquímica y la superficie e interior de la Tierra, y constituyen un recurso único para quienes trabajan en agricultura, geología, silvicultura, planificación regional, educación, cartografía e investigación del cambio global. Landsat 8 tiene **dos** instrumentos científicos: el Operational Land Imager (**OLI**) y el Thermal InfraRed Sensor (**TIRS**), que proporcionan una cobertura estacional de la masa terrestre mundial con una resolución espacial de 30 metros (visible, NIR, SWIR); 100 metros (térmica); y 15 metros (pancromática), en 11 bandas en total (tabla 1), y tienen una precisión cartográfica de hasta 12 m. Landsat 8 está planificado para tomar al menos 400 escenas diarias, aunque actualmente ha estado adquiriendo unas 725 imágenes al día. Una de las ventajas de emplear este satélite es que ofrece un catálogo de imágenes gratuitas y descargables desde 2013, permitiendo realizar trabajos con series históricas de imágenes, como el Capítulo VII.

Tabla 1. Resolución espacial y radiométrica de los satélites Landsat-8.

Banda	λ central (μm)	Resolución espacial (m)
1	0.43-0.45	30
2	0.45-0.51	30
3	0.53-0.59	30
4	0.64-0.67	30
5	0.85-0.88	30
6	1.57-1.65	30
7	2.11-2.29	30
8	0.50-0.68	15
9	1.36-1.38	30
10	10.6-11.19	100
11	11.50-12.51	100

2.6.1.2 Misión Sentinel - Programa Copernicus

La Agencia Espacial Europea (ESA, 2015) está desarrollando la familia de misiones Sentinel, que están diseñados específicamente para cumplir las necesidades operativas del programa Copernicus. Actualmente, los satélites Sentinel son muy importantes, debido a la utilidad que están demostrando en diversos ámbitos. Cada misión Sentinel se basa en una constelación de **dos satélites** para cumplir los requisitos de revisita y cobertura, proporcionando conjuntos de datos sólidos para los servicios del programa.

Copernicus es el programa de observación de la Tierra de la Unión Europea, coordinado y gestionado por la Comisión Europea en colaboración con la Agencia Espacial Europea. Proporciona información precisa, , periódica, completa y de fácil acceso de la superficie terrestre, con el fin de mejorar la gestión del medio ambiente, comprender y mitigar los efectos del cambio climático y garantizar la seguridad civil. De todos los satélites integrados en el programa Copernicus (Figura 11), los satélites **Sentinel-2 son especialmente útiles para agricultura**, debido a sus características.




Figura 11. Composición de la flota Sentinel (ESA, 2021).

2.6.1.2.1 Sentinel-2

Según el Manual de Usuario de Sentinel-2 (ESA, 2015), la misión comprende una constelación de dos satélites de órbita polar: **Sentinel-2A y Sentinel-2B**. La órbita de la misión Sentinel-2 es **síncrona al sol**. Este tipo de órbitas se utilizan para garantizar que el ángulo de la luz solar sobre la superficie de la Tierra se mantenga de forma constante. Los dos satélites ocupan la misma órbita, pero están separados por 180 grados (Figura 12). Además, el tiempo que tardan en completar la órbita es de 10 días, por lo que la resolución temporal de las imágenes es de **5 días** combinando los dos satélites. Montan el sensor **MSI**, que tiene 13 bandas espectrales, desde el visible y el infrarrojo cercano (VNIR) hasta el infrarrojo de onda corta (SWIR), ofreciendo resoluciones espaciales de **10, 20 y 60 metros** (Tabla 2).

Tabla 2. Resolución espacial y radiométrica de los satélites Sentinel-2.

Banda	λ central (nm)	Ancho de banda (nm)	Resolución espacial (m)
1	443	20	60
2	490	65	10
3	560	35	10
4	665	30	10
5	705	15	20
6	740	15	20
7	783	20	20
8	842	115	10
8a	865	20	20
9	945	20	60
10	1375	30	60
11	1610	90	20
12	2190	180	20

El primer satélite de la constelación se lanzó en junio de 2015 y el segundo en marzo de 2017. Los satélites Sentinel-2 están situados a 786 km sobre la superficie de la Tierra, con una

inclinación de la órbita de $98,62^\circ$ y la hora solar local media (MLST) en el nodo descendente es 10:30 (am). Este valor de MLST se eligió como un compromiso entre un nivel adecuado de iluminación solar y la minimización de la posible nubosidad.




Figura 12. Configuración orbital del doble satélite SENTINEL-2 (ESA, 2021).

Finalmente, antes de trabajar con imágenes de satélite se debe realizar una corrección para compensar los **efectos de la atmósfera** en las imágenes, debido a los fenómenos de dispersión de la luz indicados en puntos anteriores. Este proceso se denomina **corrección atmosférica**, e implica la conversión de los valores de reflectancia TOA (Top of atmosphere) en reflectancia superficial. La reflectancia TOA es la reflectancia bruta de la Tierra, medida desde el espacio, y es la suma de la luz reflejada por la superficie y la atmósfera. Por otro lado, la reflectancia de la superficie representa la reflectancia medida en la superficie. Si no es posible descargar las imágenes corregidas, se pueden convertir de **TOA a BOA** (Bottom of atmosphere) utilizando modelos físicos como **Sen2cor** para Sentinel-2.

2.6.2 UAVs - Unmanned Aerial Vehicles

Algunos autores consideran que la aplicabilidad de las imágenes satelitales o aéreas está limitada por las bajas frecuencias de revisita o las bajas resoluciones espaciales, incluso para imágenes de alta resolución (Nebiker et al., 2008). En este sentido, el uso de UAVs (también conocidos simplemente como "drones", en algunos países como España) permite la captura de **imágenes de muy alta resolución** con bajos costes operativos, ya sean de ala fija, helicópteros o multirrotores (Zhang y Kovacs, 2012). Los vehículos aéreos no tripulados permiten volar a

altitudes relativamente bajas, lo que repercute en la resolución espacial de los productos obtenidos (Figura 13).



Figura 13. Fotografía tomada con dron a baja altura (Capítulos II, III).

Los drones, según su sustentación, se clasifican en **ala fija**, con aerodinámica similar a la de un avión, que necesitan una velocidad mínima para el despegue; y los drones **multirrotor**, que se sustentan gracias al empleo de hélices incorporadas a cada brazo, pudiendo ser tricópteros (tres brazos), cuadricópteros (cuatro brazos), y así sucesivamente. (Figura 14). Los más habituales suelen tener una hélice por brazo, aunque también existen los coaxiales, que tienen varios motores por brazo. En el Capítulo III se empleó un dron cuadricóptero.

Los UAV son una buena forma de obtener información espacial de alta resolución. Así, el uso de UAV combinado con imágenes de alta resolución ha demostrado su utilidad debido a la capacidad de obtener una gran precisión espacial; sin embargo, existen ciertas **características que dificultan su uso**, como la falta de procedimientos estándar para estimar los índices de vegetación (Candiago et al., 2015). Además, aunque **su utilidad es indiscutible** debido a las ventajas que ofrecen, diversos son los obstáculos adicionales para utilizar las imágenes de los UAV. En primer lugar, inevitablemente se debe disponer de un aparato para volar o, en su defecto, contratar a una empresa que realice el vuelo y proporcione las imágenes. Después, es necesario calibrar y procesar la imagen para poder trabajar con ella. Usualmente, hay que construir el ortomosaico, por lo que suele conllevar más procesamiento que las imágenes descargadas de satélite. Y, además, en la mayoría de los países para volar un UAV se requiere personal cualificado con licencia, así como cumplir varios requisitos, lo que **aumenta el coste de la operación**

(Stöcker et al., 2017). También hay que tener en cuenta otros factores que influyen negativamente a las operaciones del UAV, como el **viento** (Nex et al., 2014).



Figura 14. Distintos tipos de drones multirrotores.

En todo caso, **las plataformas UAV se han utilizado ampliamente para el estudio y la exploración de los viñedos**, proporcionando una valiosa tecnología para estimar numerosos parámetros del viñedo. Así, empleando cámaras sencillas que proporcionan imágenes RGB, Poblete-Echeverría et al. (2017) consiguieron detectar y segmentar el dosel de la vid empleando reconocimiento de imagen. Empleando tecnología similar, Weiss y Baret (2017) construyeron nubes de puntos 3D derivadas de imágenes RGB para describir la macroestructura de los viñedos. También se han empleado sensores más avanzados, y de mayor coste, montados sobre UAV. Así, Matese et al. (2017) emplearon una cámara multiespectral para crear un modelo de altura del dosel del viñedo y Santesteban et al. (2017) emplearon imágenes térmicas de alta resolución obtenidas con UAV para estimar la variabilidad instantánea y estacional del estado hídrico de las plantas en un viñedo. También existe la posibilidad de montar **sensores incluso más avanzados**, como los hiperespectrales, para estimar la composición de las hojas del viñedo, por ejemplo, el contenido en carotenoides (Zarco-Tejada et al., 2013). Incluso se puede utilizar una **combinación de sensores**, como Caruso et al. (2017), que usaron una cámara RGB combinada con una cámara RGNIR para estimar parámetros tan complejos como la altura de la copa o el Índice de Área Foliar.

Por tanto, la principal ventaja de los UAVs es el **alto grado de detalle** que se puede obtener en las imágenes, así como la posibilidad de realizar el **vuelo en cualquier momento del día**. Ambas ventajas se aprovecharon en el Capítulo III, ya que se empleó un dron con cámara RGB+NIR para obtener imágenes de alta resolución, captando con un alto grado de detalle la geometría de las sombras. La misión se planificó por la tarde, por lo que este trabajo no habría sido posible sin la **flexibilidad que aporta** poder realizar la misión a cualquier hora.

2.7 Álgebra de mapas e índices de vegetación

En el ámbito de los Sistemas de Información Geográfica, el álgebra de mapas es el conjunto de herramientas de análisis o geoprocursos que permiten emplear **distintas capas** (distintas bandas) para obtener productos derivados que proporcionen información adicional. **Los índices de vegetación** son un ejemplo de combinaciones algebraicas diseñadas para **resaltar el contraste del vigor de la planta y sus propiedades**, como la biomasa del dosel, la radiación absorbida o el contenido de clorofila. Las imágenes multiespectrales se han utilizado ampliamente para estimar la biomasa de los viñedos y determinar su variabilidad espacial, causada por diferencias debidas a factores como la topografía, las características del suelo, la genética, la gestión del cultivo o el mesoclima. Estas estimaciones se realizan mediante índices de vegetación calculados a partir de las relaciones entre bandas de sectores específicos del espectro electromagnético (Pierce y Clay, 2007).

Existen multitud de índices de vegetación. En la literatura se pueden encontrar más de 500 (<https://www.indexdatabase.de/db/i.php>, accedido el 1/11/2021). Se pueden elegir en función del cultivo o de los objetivos que se quieran alcanzar. Algunos de los más utilizados se detallan en la tabla 3.

Sin embargo, **sólo algunos de estos índices son ampliamente empleados**, como el índice **NDVI**, que es **uno de los más utilizados** debido a sus buenos resultados y a la abundante literatura existente para aplicarlo a todo tipo de cultivos. Se trata de un indicador eficaz, capaz de **detectar la vegetación** de una zona y ofrecer un valor que **estima el estado de dicha vegetación**. Otro es el **SAVI** (Soil Adjusted Vegetation Index), que emplea las mismas bandas que el NDVI, pero intenta minimizar el efecto de la reflectancia del suelo en la imagen utilizando un factor L de ajuste, o el **EVI** (Enhanced Vegetation Index), que está diseñado para mejorar la sensibilidad en zonas con alta densidad de biomasa.

También existen índices más específicos, que son el resultado de la modificación o mejora de otros. Brown et al. (2000) usaron imágenes del satélite Landsat y modificaron el Simple Ratio Vegetation Index (Birth and McVey, 1968) para definir el Reduced Simple Ratio (RSR). Este índice utiliza adicionalmente la banda SWIR (infrarrojo de onda corta) para mejorar la predicción del área foliar. De este modo, Brown et al. (2000) establecen que la mejora del RSR con respecto al

SR es mayor cuanto menor es el LAI, ya que cuanto menor es este último mayor es la cantidad de suelo observada y el SR se ve afectado por la variación de las propiedades de reflectancia de los diferentes fondos.

Tabla 3. Índices de vegetación.

Índice	Referencia	Expresión matemática
NDVI	Normalised Difference Vegetation Index (Rouse et al., 1973)	$(nir-red)/(nir+red)$
SAVI	Soil Adjusted Vegetation Index (Huete, 1988)	$(nir-red)*(1+L)/(nir+red+L)$
CTVI	Corrected Transformed Vegetation Index (Perry et al., 1984)	$(NDVI+0.5)/\sqrt{abs(NDVI+0.5)}$
EVI	Enhanced Vegetation Index (Huete, 1999)	$G*((nir-red)/(nir+C1*red-C2*blue+Levi))$
EVI2	Two-band Enhanced Vegetation Index (Jiang et al., 2008)	$G*(nir-red)/(nir+2.4*red+1)$
GNDVI	Green Normalised Difference Vegetation Index (Gitelson and Merzlyak, 1998)	$(nir-green)/(nir+green)$
MSAVI	Modified Soil Adjusted Vegetation Index (Qi et al., 1994)	$nir+0.5-(0.5*\sqrt{(2*nir+1)^2-8*(nir-(2*red))})$
MSAVI2	Modified Soil Adjusted Vegetation Index (Qi et al., 1994)	$(2*(nir+1)-\sqrt{(2*nir+1)^2-8*(nir-red)})/2$
NRVI	Normalised Ratio Vegetation Index (Baret and Guyot 1991)	$(red/nir-1)/(red/nir+1)$
RVI	Ratio Vegetation Index (Birth and McVey, 1968)	red/nir
SR	Simple Ratio Vegetation Index (Birth and McVey, 1968)	nir/red
TVI	Transformed Vegetation Index (Deering et al., 1975)	$\sqrt{(nir-red)/(nir+red)+0.5}$
CLG	Green-band Chlorophyll Index (Gitelson et al., 2003)	$redEdge3/green-1$
CLRE	Red-edge-band Chlorophyll Index (Gitelson et al., 2003)	$redEdge3/redEdge1-1$
MCARI	Modified Chlorophyll Absorption Ratio Index (Daughtry et al., 2000)	$((redEdge1-red)-(redEdge1-green))*(redEdge1/red)$
MTCI	MERIS Terrestrial Chlorophyll Index (Dash and Curran, 2004)	$(redEdge2-redEdge1)/(redEdge1-red)$
SATVI	Soil Adjusted Total Vegetation Index (Marsett et al., 2006)	$(swiR^2-red)/(swiR^2+red+L)*(1+L)-(swir3/2)$
NDRE	Normalised Difference Red Edge Index (Barnes et al., 2000)	$(redEdge3-redEdge1)/(redEdge3+redEdge1)$
MTVI	Modified Triangular Vegetation Index (Haboudane, 2004)	$1.2*(1.2*(800nm-550nm)-2.5*(670nm-550nm))$

Haboudane (2004) empleó el MTVI, Modified Triangular Vegetation Index. Este índice modifica el TVI para mejorar las estimaciones del LAI al sustituir la longitud de onda de 750 nm por la de 800 nm, cuya reflectancia está influida por los cambios en las estructuras de las hojas y del dosel. Tiene una versión mejorada, el MTVI2, que es similar al MTVI, pero se considera un mejor predictor del LAI verde. Este índice es empleado en cultivos como el trigo para estimar el LAI debido a su baja saturación en valores altos de LAI (Gómez-Candón et al., 2021).

Cada índice tiene sus limitaciones, puesto que cada índice fue creado con unos criterios concretos y con objetivos diferentes. Por ejemplo, el **NDVI** no tiene en cuenta el efecto del suelo y, además, las **altas densidades de vegetación lo saturan**. En cambio, el índice SAVI considera el efecto del suelo mediante el factor L, que requiere una calibración. El EVI necesita la estimación de parámetros adicionales. Estos índices pueden combinarse para mejorar la comprensión del estado de los cultivos. La elección del índice de vegetación adecuado es clave, dado que las hojas tienen unas determinadas características para emplear la luz incidente aprovechable para la fotosíntesis, denominada radiación fotosintéticamente activa o PAR (Figura 15).




Figura 15. Reflexión, absorción y transmisión de la luz de una hoja tipo (Keller, 2015).

2.7.1 NDVI (Índice de Vegetación de Diferencia Normalizada)

Mención especial requiere el índice **NDVI (Normalized Difference Vegetation Index)**, que ha demostrado ser una herramienta útil en agricultura para diversas aplicaciones, tales como el seguimiento de las características de calidad de la uva de mesa (Anastasiou et al., 2018) o de

determinados cultivos en fase de crecimiento, para estimar los parámetros del dosel en varios cultivos hortícolas (Trout et al., 2008).

El Índice de Vegetación de Diferencia Normalizada (Rouse et al., 1973) se basa en el hecho de que las **plantas sanas muestran una alta reflectancia en el infrarrojo cercano (NIR) y una reflectancia en el rojo muy baja** (Figura 16; Lambers y Oliveira, 2019). Su ecuación, adaptada a las bandas de los satélites Sentinel-2, es la siguiente:

$$NDVI = \frac{(NIR - red)}{(NIR + red)} = \frac{(B8 - B4)}{(B8 + B4)}$$

Los valores posibles del NDVI oscilarán entre -1 y +1. Los valores negativos representarán zonas de agua o nieve, mientras que los valores próximos a 0 indicarán zonas rocosas o de suelo desnudo. Los valores positivos indicarán vegetación más frondosa cuanto más se acerquen a 1.




Figura 16. Reflectancia de la vegetación en función de su estado.

En **viticultura**, el **NDVI** se ha empleado para **multitud de aplicaciones**. Su utilidad se basa en su relación con la vegetación (Capítulo II). Se ha utilizado para controlar las características de **calidad de la uva** de mesa (Anastasiou et al., 2018), diversos parámetros relacionados con la aptitud de la cosecha (Ledderhof et al., 2016), y para diferenciar las variables de **madurez** de la uva (Martínez-Casasnovas et al., 2012). El NDVI también se ha relacionado con el **vigor** (Johnson et al., 2001) y otros parámetros medidos en campo, como el **LAI** (Leaf Area Index), obteniendo buenos resultados (Johnson, 2003; Johnson et al., 2003; Towers et al., 2019), e incluso es posible utilizar el NDVI para predecir el **rendimiento** de la uva (Sun et al., 2017). También ha sido útil para evaluar la variabilidad espacial del estado del agua dentro del viñedo (Baluja et al., 2012) y ha demostrado su utilidad para estimar la estructura foliar de la planta, la biomasa fotosintéticamente activa y el contenido de fenoles y el color de las uvas (Lamb et al., 2008). El NDVI está influenciado por las prácticas de viticultura, por ejemplo, el manejo del dosel

y el riego, por lo que es un indicador del correcto desarrollo de estas labores y, asimismo, estas prácticas deben ser consideradas a la hora de trabajar con este índice (Fountas et al., 2014).

Finalmente, multitud de autores han confirmado que es un índice útil para la diferenciación de **unidades de manejo en viñedo** (Johnson et al., 2001; Marínez-Casasnovas et al., 2012; Tagarakis et al., 2013; Santesteban et al., 2013a; Santesteban et al., 2013b; Urretavizcaya et al., 2015; Cancela et al., 2017; Capítulos I y V). Además, los patrones de NDVI dentro del campo son bastante estables entre temporadas (Kazmierski et al., 2011).

A lo largo de esta tesis, este índice también ha sido muy importante. En el Capítulo I, se empleó el NDVI calculado a partir de imágenes Sentinel-2 en la región de Castilla y León para comprobar si era capaz de discriminar diferentes viñedos, **separados hasta 3,5 km**, en función de su desarrollo vegetativo y, asimismo, observando que existían diferencias significativas en parámetros agronómicos y de calidad. Con este fin, también **se elaboró vino** en depósitos de acero inoxidable en la Estación Enológica de Rueda y se realizó una **cata triangular** entre consumidores para comprobar que, efectivamente, existían diferencias entre los vinos elaborados a partir de parcelas con diferencias significativas de NDVI.

También se aplicó de una forma similar en otros trabajos. Así, en el Capítulo VII se usó para discriminar distintas parcelas de viñedo en Galicia y comprobar que existían diferencias en el nivel de **riqueza de especies de levadura**. Por otra parte, en el Capítulo IV se empleó para evaluar la **variabilidad agronómica y de calidad del pistacho**.

En el Capítulo V se construyó una **serie temporal de imágenes** del viñedo calculando el NDVI para cada píxel y a continuación, las series temporales se transformaron mediante un análisis funcional para descomponer la información en las componentes principales y analizar su relación con los parámetros del viñedo.

2.8 Series temporales de imágenes

En viticultura, el empleo habitual de las imágenes es en momentos cercanos al envero, dado que numerosos autores han establecido que es un buen momento, corroborándolo en el Capítulo I. Mathews y Jensen (2013) establecen que el **envero es un momento óptimo** para la modelización, porque durante las fases anteriores el dosel es posible que no esté completamente desarrollado. En todo caso, a partir de este estado se estabiliza el desarrollo vegetativo (Creasy y Creasy, 2009). Además, en estudios que utilizan imágenes multiespectrales se ha demostrado que las observaciones de esta parte del periodo de crecimiento están altamente correlacionadas con el rendimiento final de la vid (Johnson et al., 2003; Hall et al., 2010). Sun et al. (2017) establecen que las predicciones sobre variabilidad de rendimiento basadas en NDVI deben hacerse antes del envero, y que deben limitarse al periodo de crecimiento de la vid, donde el LAI de la vid domina la señal de reflectancia de la superficie.

Sin embargo, el empleo de los índices de vegetación de forma aislada, como una imagen en enero, puede dar **resultados limitados**. En este contexto, se puede compensar con el análisis sencillo de series temporales (Capítulos I, II, IV, VII, Figura 17) o con métodos más complejos (Capítulo V). La disponibilidad de **series temporales** puede suponer una ventaja ya que permite considerar todas las imágenes adquiridas durante el periodo vegetativo y no limitarse a una imagen en una sola etapa. Utilizando imágenes de Sentinel-2 (Devaux et al., 2019) se ha demostrado que toda la serie temporal de NDVI a lo largo del periodo vegetativo puede aportar información relevante sobre el campo y su variabilidad espacial (por ejemplo, bloques con diferentes unidades de gestión y desarrollo vegetativo). Sin embargo, es difícil analizar la relación potencial con parámetros agronómicos relevantes considerando todas las fechas disponibles de Sentinel-2 debido a la alta dimensión de los datos temporales. Además, suelen estar muy correlacionados y no son continuos (definidos por las fechas de adquisición del satélite).




Figura 17. Valores de NDVI de una parcela calculados en distintos momentos del año (Capítulo I).

Existen **diversos métodos para analizar las series temporales**, descomponer la estacionalidad y capturar la información temporal, por ejemplo, el Modelo autorregresivo integrado de media móvil, ARIMA (Box et al., 2015) o los modelos de suavizamiento exponencial, ETS (Hyndman et al., 2008). Sin embargo, en este trabajo se utilizó el método de **Análisis de Componentes Principales**, PCA porque: i) el estudio se llevó a cabo en un sólo año, lo que significa que no se pueden extraer patrones estacionales repetidos, sino solo una tendencia principal durante la temporada de verano, ii) el objetivo es un producto fácil de interpretar, y iii) el paradigma funcional combinado con la reducción de la dimensionalidad no paramétrica permite manejar el ruido de manera eficiente. Un PCA clásico tendría problemas con los datos temporales autocorrelacionados, como las series temporales de Sentinel-2. Por lo tanto, se

empleó un marco que manejara la descomposición de las series temporales de forma eficiente y que, al mismo tiempo, proporcionara operaciones básicas de suavizado al conjunto de datos sin ruido. Por lo tanto, se realizó un Análisis Funcional no supervisado de Componentes Principales (**f-PCA**), que es la adaptación directa del PCA a los datos funcionales (Figura 18).




Figura 18 - Descomposición visual de las curvas de NDVI como suma ponderada de las 3 componentes principales funcionales (columnas). La fila superior representa los componentes modulados por las puntuaciones. La fila inferior representa la reconstrucción de la serie temporal utilizando diferentes combinaciones de componentes. La descomposición de una serie temporal de ejemplo (píxel dentro del viñedo) se detalla mediante las curvas rojas.

Para ello, las series temporales discretas en bruto se transformaron mediante un análisis funcional (Jolliffe, 2002):

$$Y_i(t) = X_i(t) + \varepsilon_i(t)$$

donde X son los datos discretos originales, Y es una representación funcional continua y suavizada de los datos, $\varepsilon_i(t)$ son los residuos no explicados por la representación funcional, i es una muestra (serie temporal para un determinado píxel), y t es el tiempo.

A continuación, se eligió un **enfoque no paramétrico** (Ferraty et al., 2006) para obtener la representación funcional de los datos. Se prefirió este enfoque al paramétrico, propuesto por Ramsay et al., (2005), porque es más fácil de resolver e interpretar, ya que sólo implica la elección de un núcleo (suavizado gaussiano) con un parámetro de ancho de banda:

$$M_{ab} = \frac{1}{w} K \left(\frac{t_a - t_b}{w} \right)$$

La matriz M, cuyos elementos son los pesos entre los puntos (a y b muestra las filas y columnas de la matriz) en la serie temporal, a continuación, se emplea para calcular los datos suavizados:

$$Y = M.X$$

Y finalmente, **se redujo la dimensionalidad de los datos**, pasando de la alta dimensión a un puñado de componentes informativos que puedan estar relacionados con los fenómenos espaciales del viñedo. Para ello, se realizó el Análisis funcional de Componentes Principales (Cardot et al., 1999), que es la, sin supervisión. El objetivo principal del f-PCA es llevar la descomposición clásica de componentes (PCA) a las series temporales semicontinuas, y su principio es **descomponer los datos funcionales como una suma ponderada** de funciones base ortonormales finitas, también llamadas **componentes principales**. Cada muestra (evolución del NDVI a lo largo del año para un píxel) puede expresarse entonces como un conjunto de puntuaciones para cada componente principal:

$$C_i(t) = \sum_{k=1}^K S_{ik} \xi_k$$

donde S_{ik} es la puntuación de la muestra i para el componente principal k y ξ_k es la función de componente principal (que puede expresarse a su vez como un conjunto de bases funcionales). Nótese que $C_i(t)$ trata de descomponer los datos funcionales de $Y_i(t)$ definidos de antemano, nunca son iguales porque el número de componentes elegidos no puede ser mayor que la dimensionalidad de los datos funcionales, y **nunca explicará toda la varianza de los datos**. La elección del número de componentes depende de la varianza explicada (como en el caso del PCA clásico). El análisis funcional (Ramsay et al., 2005) se ha propuesto para abordar estas cuestiones resumiendo toda la forma de la curva de los datos medidos no continuos. Su objetivo es proponer una representación continua y suave de los datos que puedan modelar pequeñas curvas o funciones locales. Aunque esa representación puede hacer que los datos sean teóricamente infinitamente dimensionales, puede considerar eficazmente diferentes dinámicas temporales a diferentes escalas, siendo al mismo tiempo relativamente robusta al ruido (Febrero-Bande et al., 2008). La representación funcional puede surgir de forma natural en dominios de investigación como la espectroscopia, en la que ya se dispone de datos casi continuos. Así, el **análisis funcional pretende acercar los métodos indirectos de observación del espectro, como las imágenes de satélite, a métodos más precisos, como la espectroscopia**, con mejor resolución espectral, pero sin resolución espacial.

Los recientes avances en los últimos 20 años han aumentado el uso de datos funcionales para la visualización (Shang et al., 2010), la eliminación de valores atípicos (Febrero-Bande et al.,

2008), la regresión (Goldsmith et al., 2011) o la clasificación (Leng et al., 2006). Los datos funcionales también pueden derivarse fácilmente para describir las pendientes y localizar los puntos de inflexión, y las series temporales se modelan a menudo con fines de predicción (Shang et al., 2010). El Capítulo V se centra en su uso para **extraer información relevante de las series temporales de NDVI a nivel de parcela**, que puede interpretarse conjuntamente con las observaciones y mediciones de campo. Más concretamente, se centra en el uso de técnicas de reducción de la dimensionalidad lineal, como el análisis de componentes principales (PCA, Figura 19) y los mínimos cuadrados parciales (PLS), aplicados a los datos funcionales para descomponer las curvas de NDVI en una suma ponderada de varios componentes. Esa descomposición puede utilizarse entonces para crear varios mapas complementarios que describan **diferentes dinámicas espaciales en el viñedo**. Los mapas obtenidos de la reducción de la dimensionalidad contienen la puntuación de cada componente y cada píxel del viñedo.



Figura 19 - Comparación entre el mapa NDVI de envero clásico y los tres primeros componentes del PCA (Capítulo V).

En el Capítulo V se abordó la problemática de la variabilidad espacial del viñedo desde un enfoque multitemporal. El objetivo fue i) probar el interés de considerar toda la serie temporal

del NDVI para estimar los parámetros agronómicos de interés a nivel de parcela, ii) mostrar cómo los métodos clásicos de análisis multivariante (reducción de dimensión) basados en el análisis funcional son relevantes para dar cuenta de la gestión del ruido entre imágenes y la estimación de las variables agronómicas simultáneamente, y iii) finalmente discutir la aplicabilidad del enfoque considerando una aplicación real.

2.9 Algoritmos de clasificación

Uno de los objetivos fundamentales de la teledetección es la clasificación del área de estudio en distintos tipos de suelos, vegetación, cultivos, etc. Se pueden emplear algoritmos de clasificación tanto sobre las imágenes en bruto como sobre productos derivados, tales como los índices de vegetación. Estos algoritmos permiten **segmentar la imagen en diversas clases**.

Tradicionalmente, los métodos de clasificación se dividen en dos grupos: **clasificación no supervisada y supervisada**, de acuerdo con la forma en que son obtenidas las estadísticas de entrenamiento. En los métodos no supervisados, el algoritmo clasifica automáticamente grupos de valores homogéneos dentro de la imagen, **sin entrenamiento previo** por parte del usuario. Los métodos supervisados requieren que el usuario identifique las distintas clases con **muestras de entrenamiento** (Bonaccorso, 2018).

La clasificación supervisada suele conllevar un mayor trabajo inicial, para preparar el conjunto de datos de entrenamiento del algoritmo, no obstante, ofrece **resultados más precisos** acorde a los objetivos del estudio. La clasificación no supervisada inicialmente permite una **automatización mayor y requiere un menor trabajo inicial**, pero el usuario debe realizar una mayor labor posteriormente al analizar los resultados. No obstante, el algoritmo clasifica **libremente**, pudiendo resaltar fenómenos y descubrir patrones en los que el usuario no habría reparado previamente, por lo que puede ser útil como para realizar un estudio exploratorio de los datos (Hackeling, 2014).

En **viñedo**, se han empleado este tipo de algoritmos para segmentar la información en **distintas clases**. Poblete-Echeverría et al. (2017) probaron la eficiencia de cuatro métodos de clasificación: índices espectrales, K-means, Red Neuronal Artificial (ANN) y Random Forest, para la detección de copas de vid utilizando imágenes RGB de muy alta resolución montadas en un UAV de bajo coste (Figura 20), demostrando que es posible realizar una segmentación del dosel foliar de las plantas. En particular, los métodos de índice espectral RGB (Richardson et al., 2007) complementados con el método Otsu (Otsu, 1979; Huang et al., 2011) de detección de umbrales tuvieron una precisión y estabilidad elevadas para diferentes momentos del ciclo del cultivo. Estos métodos permiten obtener información sobre la fracción de cobertura y, aplicados en distintos momentos temporales, **permiten controlar la evolución del viñedo**.




Figura 20. Ejemplo de métodos de clasificación para la segmentación de imágenes de viñedo.
Adaptado de Poblete- Echeverría et al. (2017).

De forma similar a Poblete- Echeverría et al. (2017), en el Capítulo III se emplearon diversos algoritmos de clasificación para **segmentar la imagen del viñedo y extraer las sombras**, siguiendo el flujo de trabajo descrito en la figura 21. Las sombras en las imágenes son un verdadero problema a la hora de estimar parámetros del cultivo, tal y como se discutirá en el punto siguiente, no obstante, en el Capítulo III precisamente se aprovecharon estas sombras para estimar el LAI, como se describirá más adelante.

Para la realización de la presente tesis, se emplearon algoritmos de clasificación para segmentar las imágenes y establecer diferentes clases.

La clasificación de K-means es un método de aprendizaje automático no supervisado que clasifica los objetos de datos de entrada en múltiples clases **basadas en su distancia inherente entre sí**, de forma **iterativa**, dividiendo así el conjunto de datos de entrada en **k clústeres** o conjuntos previamente definidos por el usuario (Hung et al., 2005). Sea $N = \{x_1, \dots, x_n\}$ el conjunto de n objetos a agrupar, donde $x_i \in R^d$ para $i = 1, \dots, n$, con número de dimensiones $d \geq 1$. Además, con número entero $k \geq 2$ y $K = \{1, \dots, k\}$. Para una partición k , $P = \{G(1), \dots, G(k)\}$ de N , con μ_j como centroide del clúster $G(j)$, para $j \in K$ y $M = \{\mu_1, \dots, \mu_k\}$ y $W = \{w_{11}, \dots, w_{ij}\}$. Por tanto, el problema de clasificación puede formularse como un **problema de optimización**, descrito por:

$$P: \text{minimizar } z(W, M) = \sum_{i=1}^n \sum_{j=1}^k w_{ij} d(x_i, \mu_j)$$

$$\text{sueto a } \sum_{j=1}^k w_{ij} = 1, \text{ para } i = 1, \dots, n,$$

$$w_{ij} = 0 \text{ o } 1, \text{ para } i = 1, \dots, n, y j = 1, \dots, k,$$

donde $w_{ij} = 1$ implica que el objeto x_i pertenece al clúster $G(j)$, y $d(x_i, \mu_j)$ indica la distancia euclidiana entre x_i y μ_j para $i = 1, \dots, n$ y $j = 1, \dots, k$ (Pérez-Ortega et al., 2020).




Figura 21. Flujo de trabajo para la estimación del LAI.

La versión estándar del algoritmo consta de cuatro pasos: 1) se generan **aleatoriamente** centroides (k puntos) en el espacio, 2) se asigna cada punto a su **centroide más cercano**, según la distancia a todos los centroides, 3) se calculan **nuevos centroides** utilizando el valor medio de los objetos que pertenecen a cada clúster, y 4) se **repite el proceso** desde el paso 2 hasta que se alcanza el **equilibrio** (es decir, cuando el número de puntos se mantiene estable dentro de cada clúster).

En los Capítulos I y IV se emplearon $k = 3$ y $k = 2$ como número de clases. En el Capítulo III, se exploró el efecto del número de clases en la clasificación, variando los valores desde $k = 2$ hasta $k = 6$.

Adicionalmente, en el Capítulo III, también se empleó Random Forest, segmentando la imagen en 4 clases diferentes: vegetación, suelo, sombra y vegetación sombreada.

Random Forest es un método de aprendizaje automático supervisado que utiliza un árbol de decisión para la clasificación y la predicción. El algoritmo ajusta numerosos árboles de clasificación a un conjunto de datos y luego combina las predicciones de todos los árboles. Cada árbol puede calcularse por separado de otros árboles, porque **cada árbol se construye de forma independiente utilizando una muestra** empleando el método de remuestreo *bootstrap* (Efron, 1979) del conjunto de datos (Kuhn, 2008). El algoritmo Random Forest funciona en cuatro pasos: 1) se seleccionan muchas **muestras bootstrap** de los datos, 2) se ajusta un **árbol de clasificación** a cada muestra *bootstrap*, 3) cada árbol se utiliza para **predecir** las observaciones fuera de bolsa, y 4) la clase predicha de una observación se calcula por **mayoría de votos** de las predicciones fuera de bolsa para esa observación (Cutler et al., 2007). Las observaciones del conjunto de datos original que no aparecen en una muestra *bootstrap* son las observaciones fuera de bolsa. En el Capítulo III, el número de árboles se fijó en 500, y el conjunto de entrenamiento se dividió en cuatro clases: suelo, sombras, vegetación de sombra y vegetación.

2.10 Problema de sombras y píxeles mixtos en las imágenes de viñedo

Como se ha indicado, las imágenes obtenidas con teledetección pueden clasificarse en dos grupos (Hall et al., 2008) según su resolución espacial: (i) imágenes de **baja resolución espacial**, en las que la mayoría de los píxeles contienen información de reflectancia de las vides y del espacio entre hileras de viñedo, y (ii) imágenes de **alta resolución espacial**, en las que la mayoría de los píxeles contienen información sólo de las vides o sólo del espacio entre hileras. Por lo tanto, cuando se utilizan imágenes de baja resolución, el valor del NDVI del píxel es un **indicador de la cantidad de vegetación** (superficie del dosel) más que el NDVI del dosel de las vides (valor puro sin la influencia del fondo).

En este contexto, la principal limitación de Sentinel-2 es que la resolución espacial y la información dentro del bloque no pueden ser precisas en el caso de bloques pequeños o con

bordes complejos (Devaux et al., 2019). Este es un problema extendido a todas las imágenes de satélite, ya que dentro de un píxel de viñedo hay **plantas, suelo y sombras**, que influyen en el cálculo correcto de los coeficientes del cultivo (Johnson y Scholasch, 2005). Cuanto mayor sea el tamaño del píxel, mayor será el problema de los píxeles mixtos (Figura 22), ya que es una problemática **inherente** al viñedo debido a su naturaleza (Lamb et al., 2001; Hall et al., 2008).




Figura 22. Representación de las diferentes resoluciones de píxeles obtenidas a baja (0,5 m² por píxel) y alta resolución (2 m² por píxel) de las bandas del infrarrojo cercano del satélite WorldView-2 para (a) cepas vigorosas y (b) cepas menos vigorosas. (Fuentes et al., 2014).

Fuentes et al. (2014), indican que, en viñedo, empleando un tamaño de píxel de 0,5 m² es posible encontrar píxeles con un 100% de vegetación, sin embargo, con 2m² sólo habrá píxeles mixtos de vegetación y suelo. Por tanto, empleando satélites con alta resolución tales como el Worldview-2, con una resolución de 0,5 a 2 m², sería posible atajar este problema. Sin embargo, si en lugar de imágenes Worldview-2, se emplean imágenes Sentinel-2, el problema será **mucho mayor**, ya que, en lugar de una resolución de hasta 2m², Sentinel-2 tendrá una resolución de 100m², por lo que todos los píxeles estarán mezclados y contendrán varias plantas, así como suelo y sombras. Este es un **problema tremendamente significativo, ya que los suelos tienen una gran influencia en el cálculo del NDVI** (Montandon y Small, 2008) y los valores medios del NDVI de las vides pueden ser hasta 3 veces mayores que los valores medios del NDVI del suelo puro (Poblete-Echeverría et al., 2009). Incluso algunos autores (Hall et al., 2011) han establecido que los píxeles con un NDVI inferior a 0,6 deben eliminarse porque no se deben considerar vegetación,

aunque esto sería aplicable en imágenes de alta resolución, no en imágenes de satélite, ya que en el viñedo difícilmente alcanza esos valores (Capítulo II). Sin embargo, otros autores, han encontrado complicaciones al emplear imágenes de alta resolución en viñedos con vegetación en el suelo, proponiendo un remuestreo de las imágenes de 3x3 píxeles (disminuyendo la resolución), con el fin de eliminar el efecto de la vegetación de fondo (Ledderhof et al., 2016)

Como se ha indicado, un enfoque típico en **Viticultura de Precisión** para el seguimiento de la vegetación es la medición de la información espectral emitida y reflejada directamente por la vegetación. En estos enfoques, las **sombras** se tratan frecuentemente **como información no deseable** (Ma et al., 2008; Zhang y Chen, 2010; Wu y Bauer, 2013; Aboutaleb et al., 2018), y **suelen eliminarse** de los conjuntos de datos (Poblete-Echeverría et al., 2017; Jiang et al., 2018). Los esfuerzos van enfocados en su mayoría a reducir su efecto. Las sombras del suelo (figura 23), las hojas y el dosel, el terreno, las nubes y el hardware de los instrumentos afectan a las mediciones de campo del LAI y a la modelización (Fang et al., 2019).



Figura 23. detalle de las sombras en viñedo.

El efecto de las sombras depende de la escala y tiende a aumentar con el incremento de la resolución espacial (Damm et al., 2015). Se pueden observar algunos inconvenientes cuando las imágenes no se adquieren cerca del **mediodía solar**, debido a que las partes sombreadas y las iluminadas por el sol de las hojas tienen diferentes valores de reflectancia. Además, las zonas

sombreadas pueden generar datos ruidosos, que afectan significativamente a la estimación de los parámetros de la vegetación (Zhang et al., 2015). Las sombras están influenciadas principalmente por la distancia entre las plantas y las filas, pero también por las características inherentes de las plantas (Prichard et al., 2004). Así, para una misma iluminación, más vegetación implicará más sombra, un factor importante ya que los píxeles sombreados tienen baja reflectancia y modifican los valores que se esperarían si sólo hubiera vegetación y suelo. Varios autores han tratado de resolver este problema, intentando corregir el sombreado en imágenes de UAV y de satélite (Wang et al., 2008; Zhang y Chen, 2010; Wu y Bauer, 2013; Ma et al., 2008; Aboutalebi et al., 2018). La influencia de las sombras y la iluminación ha sido estudiada y se ha simulado empleando diversos tipos de modelos (Gascon et al., 2004; Wang et al., 2013) y diversos autores han demostrado que es posible estimar la fracción de sombra a partir de LiDAR (Hilker et al., 2011) o de imágenes de satélite utilizando el análisis de mezcla espectral (Hu et al., 2004).



Figura 24. Detalle del trabajo realizado para la consecución del Capítulo II.

Teniendo en cuenta la característica inherente de los píxeles mixtos de las imágenes Sentinel-2 y a la falta de información en viñedos, en el Capítulo II se realizó un estudio para analizar el **efecto de la reducción de vegetación en las imágenes de satélite** (Figura 24), mediante el análisis de la **evolución del NDVI**. Para ello, se realizaron dos experimentos relacionados: i) una simulación en condiciones de control (experimento en invernadero) y ii) un experimento de campo en el que se aplicó un protocolo de **extracción progresiva de vegetación**,

midiendo en laboratorio la cantidad de vegetación eliminada, con el fin de comprender la relación entre la vegetación contenida en un píxel y la información captada por el satélite.

En paralelo, se desarrolló el Capítulo III, en el que se realizaron vuelos por la tarde para maximizar las sombras de la vegetación sobre el suelo y emplearlas para estimar el LAI.

2.11 Superficie foliar y LAI (Leaf Area Index)

La superficie foliar producida por las vides (*Vitis vinifera* L.) es un **factor determinante** de la productividad, ya que las hojas son el principal lugar de fotosíntesis y transpiración de la planta. La arquitectura del dosel, distribución de la superficie foliar y su densidad, determinan la interceptación de la radiación solar (Hidalgo, 2006). Las hojas son órganos especializados en interceptar la radiación necesaria para realizar la fotosíntesis. Un dosel con insuficientes hojas activas sanas no puede producir suficiente azúcar para mantener todos los racimos para una maduración óptima, y no produce uvas con suficiente aroma/sabor, y/o compuestos fenólicos deseables (Reynolds, 2010). Por tanto, un aspecto importantísimo en viticultura es la monitorización de la vegetación y es crítico conocer la superficie foliar de la planta, ya que se requiere una **buena relación** entre la superficie foliar y el peso del fruto para que los racimos maduren completamente, afectando directamente al rendimiento (Keller, 2015; Jackson, 2020).

Una forma de evaluar la superficie foliar es el empleo del índice de área foliar, o **LAI** (Leaf Area Index), que es un **parámetro clave** que determina la **fotosíntesis, la respiración y la transpiración** de la vegetación (Gower et al., 1999) y está estrechamente relacionado con la asimilación de la radiación fotosintéticamente activa (Pessarakli, 2014). Es la variable más utilizada para caracterizar el desarrollo del follaje de la vid (Delrot et al., 2010; Sánchez-de-Miguel et al., 2011; Lambers y Oliveira, 2019).

El **índice de área foliar** se define como el **desarrollo vegetativo de un cultivo por unidad de superficie de terreno** (Watson, 1947). Es una variable biofísica importante en los modelos de hidrología, climatología y crecimiento de los cultivos. El seguimiento rápido del LAI es fundamental en la agricultura de precisión moderna. La teledetección por satélite, aérea y con UAV se ha convertido en una técnica popular para el seguimiento del LAI de los cultivos (Yao et al., 2017).

En **viticultura, el LAI es un indicador clave**, no sólo porque indica el desarrollo vegetativo de la planta, sino porque el área foliar se correlaciona directamente con otros parámetros críticos como la **transpiración, el desarrollo radicular o la capacidad fotosintética, limitando el rendimiento de la planta** (Keller, 2015). Controlarlo es crítico, puesto que la producción fotosintética del viñedo aumenta con el LAI hasta un máximo en el que la densidad de vegetación limita el número de hojas expuestas a radiación directa (Reynier, 1995), produciendo una acumulación de las hojas en las capas exteriores y limitando la actividad

de las hojas interiores al no disponer de una iluminación mínima (Sánchez, 2007). Además, el LAI está relacionado con la transpiración del dosel y el uso del agua, influyendo en las decisiones de riego (Netzer et al., 2008; Munitz et al., 2019). Está influenciado por factores de manejo y ambientales, como el riego, el aporte de nutrientes y los sistemas de formación (Oliveira y Santos, 1995) y, adicionalmente, el ajuste de la superficie foliar no solo reduce las necesidades de agua de la vid en el momento en que se realice, sino que también condiciona el desarrollo vegetativo posterior y, por tanto, reduce las necesidades de agua futuras, **mejorando la eficiencia en el uso de agua del cultivo** (Mirás-Avalos y Araujo, 2021).

Una forma de actuar sobre el área foliar es mediante el **manejo del dosel de la planta**. Ésta es una práctica agronómica importante que permite a los viticultores regular el microclima alrededor de los racimos y, en consecuencia, el estado sanitario de la fruta, el rendimiento y la calidad de las bayas. Los sistemas de formación evolucionaron para maximizar la cantidad de luz solar interceptada y su distribución dentro del dosel de la vid. Una evolución es el **emparrado en espaldera vertical (VSP)**. Este tipo de sistemas se emplean porque producen un aumento de la densidad del área foliar, produciendo **una única columna de vegetación** al limitar el volumen del dosel y **mejorando la exposición a la luz solar en su interior** al aumentar la cantidad de espacio disponible para la distribución del follaje. Además, los troncos y los sarmientos se disponen de forma que se evite la competencia por la luz entre las vides. Un emparrado adecuado puede hacer que se forme una zona de renovación, lo que garantiza la perpetuación de la forma de la planta y mantener el rendimiento en niveles óptimos. Todo ello redundará en un **mayor potencial productivo**, en la optimización de la relación entre la superficie foliar y el fruto, en una **mayor calidad** y en un **mejor control de las enfermedades**. Además, su disposición **facilita el movimiento del equipo de trabajo** a través del viñedo para realizar las tareas y permite una **mecanización del cultivo adecuada** (Reynolds y Heuvel, 2009).

En el Capítulo III se sacó partido de las sombras del viñedo, sumado a la **disposición de la vegetación en espaldera vertical**, con el objetivo de **desarrollar un nuevo método para estimar el área foliar empleando las sombras** como indicadores de la dimensión vertical de la vegetación, una dimensión difícilmente alcanzable para las técnicas tradicionales de ortofotografía aérea.

Por tanto, si el área foliar es un parámetro clave, ¿por qué no se calcula siempre en todos los viñedos? Una de las dificultades es que el área foliar **evoluciona a lo largo del año** (Orlando et al., 2016), así que habría que tomar numerosas medidas en la misma campaña para disponer de datos representativos de la parcela en cada estado fenológico. Otro de los grandes problemas es que, empleando **métodos tradicionales**, se deben emplear **mucho tiempo y recursos** en **cada** medición de LAI. En todo un día de trabajo solamente se podrían medir algunas plantas de una parcela de viñedo.

Los métodos para la medición del área foliar se pueden dividir en dos grandes grupos: directos e indirectos. Los métodos **directos** generalmente son destructivos, ya que necesitan todas las hojas de la planta (o una parte importante) para estimar el área total de hojas. También pueden ser no destructivos, midiendo directamente la superficie en campo. Por otra parte, los métodos **indirectos no son destructivos** y emplean el balance de radiación en el área de influencia o en las proximidades de la planta, estimando así el área foliar a partir de la distribución de la radiación bajo el dosel foliar (Jonckheere et al., 2004). Los métodos basados en teledetección no necesitan ser destructivos, ya que estiman los parámetros a partir de la luz proveniente del objeto. No obstante, para el desarrollo de los Capítulos II y III se midió de forma destructiva toda la superficie foliar del viñedo, empleando la aplicación *EasyLeafArea* (Easlon y Bloom, 2014) para determinar la superficie foliar real y validar el método (Figura 25), aprovechando que la finalidad del experimento del Capítulo II fue retirar la vegetación del viñedo.




Figura 25. Medición de la superficie foliar real retirada con EasyLeafArea (Capítulos II y III).

En cuanto a los métodos tradicionales para estimar el LAI, existen varias metodologías desarrolladas por diversos autores: el método **Carbonneau** (Carbonneau, 1976), el método **Point**

Quadrat adaptado (Smart y Robinson, 1991), el método de **Lopes y Pinto** (Lopes y Pinto, 2005), o midiendo parámetros específicos de la forma de la hoja (Williams y Martinson, 2003). Sin embargo, estos métodos son **poco eficientes**, ya que consumen mucho tiempo y, adicionalmente, son destructivos en algunos casos.

Para solucionar esta dificultad, se pueden emplear métodos basados en la **teledetección**.

2.11.1 Estimación del LAI con métodos de teledetección

Una opción más rápida para estimar el LAI es el uso de la tecnología de teledetección. Se pueden utilizar diferentes tecnologías, por ejemplo, espectrorradiómetros de campo (Wang et al., 2019), datos multiespectrales e hiperespectrales (Mananze et al., 2018; Capítulo III), imágenes de satélite (Meyer et al., 2019; Dube et al., 2019) e imágenes térmicas (Neinavaz et al., 2019). Estos métodos pueden **variar en precisión y complejidad** dependiendo de las metodologías y tecnologías utilizadas:

- En lo que respecta a las **imágenes de satélite**, se han comunicado diferentes resultados. Por ejemplo, Johnson et al. (2003) mostraron una correlación significativa entre el área foliar basada en imágenes y el área foliar basada en el suelo ($R^2 > 0,7$); sin embargo, Beerli et al. (2020) encontraron una relación débil entre la información satelital y el LAI ($R^2 > 0,3$). En otras plantas leñosas diferentes al viñedo, Stenberg et al. (2004) obtuvieron una correlación moderada ($R^2 > 0.5$) empleando imágenes Landsat y el RSR (Reduced Simple Ratio), mostrando que el RSR es mejor que el NDVI o el SR para estimar el LAI, ya que el RSR es más sensible a la variación de éste.
- Existen **herramientas específicas desarrolladas exclusivamente para la estimación indirecta del LAI**, basadas en la medición de la **extinción de la radiación** a través del follaje, como el Plant Canopy Analyzer (PCA, LAI-2000 y 2200, Li-Cor Inc., Lincoln, NE, USA). Johnson y Pierce (2004) han informado de una buena precisión utilizando el PCA en viticultura, pero incluso cuando esta herramienta se desarrolló específicamente para medir el LAI, no es fácil emplearla correctamente ya que existen diferentes protocolos para utilizarla (White et al., 2018).
- Los sensores de uso general, como las **cámaras RGB** convencionales, también han mostrado un gran potencial para medir el LAI mediante diversos métodos. Por ejemplo, Fuentes et al. (2014) utilizaron una cámara montada en un poste para adquirir imágenes digitales cenitales alrededor de la planta, y De Bei et al. (2016) desarrollaron una aplicación (*VitiCanopy*) para evaluar los parámetros de la arquitectura del dosel en los viñedos, utilizando imágenes orientadas hacia arriba. Diago et al. (2012) la situaron en un trípode

colocado en posición normal al dosel, a 2 m de la hilera y a 1,05 m por encima del suelo, obteniendo buenos resultados, informando de una alta precisión. Además, estos sensores pueden **montarse en UAVs, lo que amplía sus posibilidades**. Kalisperakis et al. (2015) utilizaron una cámara RGB estándar de bajo coste para estimar el LAI, alcanzando buenos resultados ($R^2 > 0,7$). No solo eso, sino que también utilizaron el UAV para montar un sensor de imágenes VNIR hiperespectral, mejorando los resultados ($R^2 > 0,8$).

- Los **sensores hiperespectrales y multiespectrales** suponen un avance respecto a las cámaras RGB. Utilizando imágenes aéreas multiespectrales, Hall et al. (2008) encontraron fuertes relaciones entre el área planimétrica del dosel y las mediciones en tierra del LAI en varios estadios fenológicos, mientras que no encontraron relaciones significativas entre el NDVI y el LAI. Towers et al. (2019) utilizaron un sensor multiespectral para capturar imágenes de vista nadir sobre el dosel, informando de una precisión muy diferente según se utilizaran o no los valores del suelo, mostrando que la reflexión de luz del suelo puede contribuir con más señal que la cobertura vegetal. De forma similar, pero capturando las imágenes desde un UAV, Comba et al. (2020) utilizaron una cámara multiespectral combinada con la creación de nubes de puntos y el modelado 3D utilizando SfM (Structure from Motion) para estimar el LAI, alcanzando buenos resultados ($R^2 > 0,8$). Mathews y Jensen (2013) capturaron imágenes en nadir en diferentes ángulos oblicuos, obteniendo una menor precisión ($R^2 > 0,5$) que Comba et al. (2020), mostrando que el aumento del número de ángulos/perspectivas diferentes con solapamiento contribuye a mejorar el producto SfM. Kalisperakis et al. (2015) informaron de una buena precisión ($R^2 > 0,8$) mediante la creación de un modelo 3D (figura 26) a través de triangulación utilizando imágenes aéreas RGB para generar una nube de puntos densa empleando algoritmos, lo que sugiere que, incluso utilizando los mismos sensores y la misma tecnología, diferentes métodos pueden mostrar diferentes precisiones.
- Un enfoque alternativo considera el uso de herramientas específicas que pueden capturar las **tres dimensiones** (3-D) del espacio. Por ejemplo, Arnó et al. (2013, figura 27) calcularon parámetros geométricos y estructurales utilizando un sistema **LiDAR** montado en un tractor para medir las vides en una dirección transversal a lo largo de las filas, informando de una alta precisión ($R^2 > 0,8$). Por otra parte, Patočka et al., (2020) crearon modelos utilizando el escaneo láser aerotransportado en bosques jóvenes de hayas, encontrando una correlación bastante alta ($R^2 > 0,8$), pero indicando que el rango de valores del LAI depende del método de estimación utilizado, revelando que estos modelos sólo son válidos a nivel regional o a nivel de la estructura forestal.



Figura 26. Modelo 3D del dosel foliar de viñedo (Kalisperakis et al., 2015).



Figura 27. LiDAR LMS-200, empleado en el estudio de Arnó et al. (2013).

Cada método tiene sus **ventajas y limitaciones**. Algunos de ellos son baratos de implementar, por ejemplo, las cámaras RGB (Fuentes et al., 2014; Diago et al., 2012), pero tienen

diferentes problemas, dependiendo del método. Diago et al. (2012) presentaron problemas al utilizar cámaras RGB en relación con la distancia al follaje remanente cuando el proceso de defoliación se realizó sobre doseles foliares muy densos. Del-Moral-Martínez et al. (2016) informaron de que el LiDAR necesita una configuración muy precisa; de lo contrario, puede generar valores de LAI incorrectos en vides con un desarrollo foliar deficiente, computando zonas con un dosel con un porcentaje considerable de huecos como zonas de área de pared foliar efectiva. Mathews y Jensen (2013) informaron de que el enfoque SfM necesita más tiempo que otras misiones con vehículos aéreos no tripulados debido al mayor número de imágenes, ángulos o solapamientos. Además, **algunas metodologías tienen un mayor coste que otras**, debido a las tecnologías implicadas. Así, las cámaras multiespectrales (Towers et al., 2019; Comba et al., 2020), hiperespectrales (Kalisperakis et al., 2015) o el LiDAR (Arnó et al., 2013), son mucho más caras que simples cámaras RGB.

Para la mayoría de estos métodos, generalmente se encuentran fuertes correlaciones con el LAI ($R^2 > 0,7$), y un aspecto clave de la mayoría de ellos es el requisito de medir los datos **alrededor del mediodía para minimizar el efecto de las sombras** en el viñedo. En este sentido, el desarrollo de nuevos métodos que complementen las técnicas actuales, amplíen las áreas objetivo y permitan extender el trabajo a otros periodos del día podría ser muy beneficioso para la aplicación de estas técnicas en la práctica.

Llegados a este punto, teniendo en cuenta los estudios anteriormente expuestos para estimar el LAI, así como la utilización de algoritmos de segmentación de las imágenes para aprovechar las sombras tomadas por la tarde en viñedo, se realizó una conjunción de todas estas ideas para desarrollar el método expuesto en el Capítulo III. En éste, se propuso un enfoque novedoso para estimar el LAI, empleando las sombras. **El área foliar de la planta está correlacionada con la luz interceptada**, y puede estimarse midiendo su sombra (Baeza et al., 2010). Por lo tanto, se podría estudiar la sombra proyectada por cada planta en el suelo del viñedo. En el trabajo realizado, se estimó el LAI utilizando las sombras de las plantas capturadas mediante imágenes de UAV, desarrollando un nuevo método, compatible con los métodos anteriores, estimando de una **forma rápida, no destructiva y precisa el área foliar**.

Se empleó un UAV por **dos características críticas** del trabajo: i) emplear imágenes multiespectrales **precisas y de alta resolución**, para evaluar correctamente la forma de las sombras de la vid, y ii) la posibilidad de elegir el **momento del vuelo**. La misión se planificó en función de la elevación del sol (figura 28), el periodo del año y el tamaño deseado de las sombras (dependiente de la altura de la planta).

Otros autores han formulado hipótesis teóricas sobre el uso de las sombras como medida indirecta de la superficie foliar y de las características del dosel (Zheng et al., 2009) o incluso han sugerido la posibilidad de utilizar la teledetección óptica cerca del mediodía solar para supervisar y cartografiar la superficie sombreada del viñedo (Johnson y Scholasch, 2005). Sin embargo, hasta

donde sabemos, en el **Capítulo III se presenta el primer estudio que desarrolla y evalúa un protocolo de campo para medir el área foliar de la vid utilizando el área de sombra en condiciones reales**. Este estudio aprovecha los avances en las tecnologías de captura de imágenes y de vehículos aéreos no tripulados, combinando los conocimientos previos en viticultura con los métodos de teledetección y aprendizaje automático.




Figura 28. Planificación del vuelo para maximizar las sombras (Capítulo III).

Otras aplicaciones de la teledetección en el viñedo relacionadas con el área foliar se corresponden con el cálculo de las necesidades de agua, que son un factor clave en la agricultura. Éstas se suelen estimar a partir de la evapotranspiración del cultivo (ETc), cuya adecuada cuantificación permite el desarrollo de estrategias de riego, mejorando la eficiencia en el uso del agua y aumentando la producción (Ferreyra et al., 1985; Baruch y Fisher, 1991; Millar, 1993). Los métodos tradicionales para estimar este parámetro se basan en mediciones directas con instrumentos sofisticados, como los lisímetros (Payero e Irmak, 2008), las microestaciones meteorológicas de covarianza de Foucault (Parent y Anctil, 2012; Poblete-Echeverría y Ortega-Farias, 2013), la relación de Bowen (Crago y Brutsaert, 1996); o en métodos empíricos, como el FAO-56 (Allen et al., 1998). Aunque todos estos métodos pueden ser precisos, es difícil extrapolarlos a nivel de parcela o a niveles regionales, ya que no tienen en cuenta el efecto de la variabilidad espacio-temporal del suelo, del clima o del cultivo sobre la evapotranspiración (Allen et al., 2011). Para solucionarlo, se pueden utilizar métodos físico-matemáticos para estimar la evapotranspiración mediante sensores remotos. Uno de los primeros métodos desarrollados y aplicados a escala mundial fue SEBAL (Surface Energy Balance Algorithms for Land) (Bastiaanssen et al., 1998). Este modelo estima la evapotranspiración a partir de la ecuación del balance energético de la superficie. Para calibrar el método, se utilizan 2 píxeles seleccionados en la imagen (píxeles de anclaje), en condiciones de máxima y mínima evapotranspiración, ajustando

una relación lineal entre la temperatura de la superficie y la diferencia entre la temperatura de la superficie y la temperatura del aire. Sobre esta base, Allen et al. (2007) desarrollaron el modelo METRIC (Mapping EvapoTranspiration at high Resolution with Internalized Calibration), que estima la ET_c como un residuo de la ecuación de balance energético, utilizando datos de imágenes de satélite y de una estación meteorológica situada en la zona de estudio.

2.12 Teledetección y parámetros de calidad.

El desarrollo vegetativo está directamente relacionado con la calidad de la cosecha, ya que afecta a su estado sanitario, insolación de la baya, optimización de la relación entre la superficie foliar y el fruto y a un mejor control de las enfermedades y facilita las labores de inspección (Reynolds y Heuvel, 2009). Por otra parte, como ya se ha indicado, la FAO (2021) establece que la teledetección es una herramienta capaz no sólo de aumentar las producciones, sino también de **mejorar la calidad de las cosechas**. Se considera que se puede aplicar para lograr una viticultura más eficiente, con la que se pueda producir en óptimas condiciones y en cantidad suficiente, y recoger las mejores uvas posibles en su punto óptimo de madurez y sanidad (Del Rey, 2013).

Los estudios de investigación en viticultura muestran que las técnicas de teledetección permiten evaluar la **variabilidad del viñedo y controlar la madurez de la uva** (Johnson et al., 2001; Capítulo I). De este modo, en el 2002, Hall y Lamb indicaron el potencial del empleo de teledetección e índices de vegetación para estimar no sólo el rendimiento de la uva, sino también la calidad. Ledderhof et al. (2016) correlacionaron el NDVI obtenido de imágenes aéreas de alta resolución en un viñedo cv. Pinot noir con los antocianos totales, el contenido de arcilla del suelo, el pH de las bayas, los sólidos solubles, el tamaño de la vid, el color y el contenido de arena del suelo, la humedad del suelo y el contenido de arcilla y limo del suelo. De igual modo, en el Capítulo V, se analizó la correlación entre las componentes principales derivadas de una serie temporal de imágenes Sentinel-2 del año 2018 y diversas variables que afectan al cultivo (Keller, 2015; Jackson, 2020). Por otra parte, Lamb et al. (2008) emplearon la teledetección para predecir los fenoles y el color de la uva en la vendimia en un viñedo cv. Cabernet Sauvignon, confirmando años más tarde que el NDVI también se relaciona con la biomasa fotosintéticamente activa (PAB), además de con los fenoles totales y el color (Lamb et al., 2008). También se ha empleado la teledetección para diferenciar variables de madurez de la uva (Martínez-Casasnovas et al., 2012) y para controlar las características de calidad en las uvas de mesa (Anastasiou et al., 2018).

En el Capítulo I se analizó la relación del NDVI del satélite con la cantidad de sólidos solubles totales, los azúcares, el pH, el ácido tartárico y málico y la acidez total, y el potasio en el mosto. Estos parámetros de calidad son los típicamente analizados en viñedo (Hidalgo, 2006; Keller, 2015; Jackson, 2020). Del mismo modo, en el Capítulo IV se analiza la relación del NDVI con **diversos parámetros de calidad del pistacho**; y en el Capítulo V se exploró la correlación

entre diversos parámetros del suelo y de calidad, incluyendo la acidez total, y las componentes del f-PCA derivado de la serie temporal Sentinel-2.

Adicionalmente a los parámetros típicos de calidad, en el Capítulo VII, se exploró un paso más allá, explorando la relación entre las **imágenes de satélite Landsat y datos de campo relacionados con las levaduras** en viñedos de distintas DOs en Galicia (Figura 29), entendiendo que la DO está ligada al **terroir**. La base del sistema galo de DO es el concepto de *terroir* (terruño, en español), que es un término francés que describe cómo el medio ambiente, las prácticas agrícolas, las características de los cultivos y los elementos culturales de un lugar afectan a la producción de uva y de vino, combinados de una manera específica que no puede reproducirse en ningún otro lugar. Este sistema presupone que **la tierra en la que se cultiva la uva**, el hábitat de la planta **confiere una calidad única y específica** a ese lugar de cultivo (Robinson, 2006) y es uno de los **conceptos centrales asociados al vino y su calidad**, que confiere a los vinos su complejidad (Hall y Mitchell, 2008). El *terroir* influye en las características cromáticas de los vinos y afecta claramente a la composición fenólica (Cosme et al., 2020). Además, la cata confirma, sin duda, estas diferencias dependiendo de la naturaleza del terruño (Seguin, 1986). El *terroir* también afecta a la **diversidad de las levaduras al vincularlas a una zona geográfica** (Barata et al., 2012; Bokulich et al., 2014).



Figura 29. Localización de las imágenes Landsat y de los viñedos comerciales en Galicia (España). (Capítulo VII).

Por ello, en el Capítulo VII se exploró el uso potencial de las imágenes multiespectrales de satélite para detectar diferencias en el *terroir* y la población de levaduras debido a la DO según las variaciones del NDVI, estudiando i) si las imágenes de satélite pueden establecer diferencias en el *terroir*, ii) la relación entre el NDVI y la riqueza de especies de levaduras, iii) la estabilidad

temporal a lo largo de los años entre el NDVI, el *terroir* y las levaduras. Son pocos los estudios que han desarrollado y relacionado el concepto de *terroir* microbiano o de levadura con otras disciplinas, ya que este concepto es controvertido porque todavía no está claro cómo contribuyen los microbios al *terroir* (Alexandre, 2020).

3. Referencias

- Aboutaleb, M., Torres-Rua, A. F., McKee, M., Kustas, W., Nieto, H., & Coopmans, C. (2018). Behavior of vegetation/soil indices in shaded and sunlit pixels and evaluation of different shadow compensation methods using UAV high-resolution imagery over vineyards. *Proc. SPIE 10664, Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping III*, 1066407. <https://doi.org/10.1117/12.2305883>
- Alexandre, H. (2020). Wine Yeast Terroir: Separating the Wheat from the Chaff—for an Open Debate. *Microorganisms*, 8(5), 787. <https://doi.org/10.3390/microorganisms8050787>
- Allen, R. G., Pereira, L. S., Howell, T. A., & Jensen, M. E. (2011). Evapotranspiration information reporting: I. Factors governing measurement accuracy. *Agricultural Water Management*, 98(6), 899–920. <https://doi.org/10.1016/j.agwat.2010.12.015>
- Allen, R. G., Tasumi, M., & Trezza, R. (2007). Satellite-Based Energy Balance for Mapping Evapotranspiration with Internalized Calibration (METRIC)—Model. *Journal of Irrigation and Drainage Engineering*, 133(4), 380–394. [https://doi.org/10.1061/\(asce\)0733-9437\(2007\)133:4\(380\)](https://doi.org/10.1061/(asce)0733-9437(2007)133:4(380))
- Allen, R.G., Pereira, L.S., Raes, D. & Smith, M. (1998). Crop evapotranspiration - Guidelines for computing crop water requirements. *FAO, Vol. 56*.
- Anastasiou, E., Balafoutis, A., Darra, N., Psiroukis, V., Biniari, A., Xanthopoulos, G., & Fountas, S. (2018). Satellite and Proximal Sensing to Estimate the Yield and Quality of Table Grapes. *Agriculture*, 8(7), 94. <https://doi.org/10.3390/agriculture8070094>
- Arnó, J., Escolà, A., Vallès, J. M., Llorens, J., Sanz, R., Masip, J., Palacín, J., & Rosell-Polo, J. R. (2013). Leaf area index estimation in vineyards using a ground-based LiDAR scanner. *Precision Agriculture*, 14(3), 290–306. <https://doi.org/10.1007/s11119-012-9295-0>
- Arnó, J., Martínez-Casasnovas, J. A., Ribes Dasi, M., & Rosell, J. R. (2009). Review. Precision viticulture. Research topics, challenges and opportunities in site-specific vineyard management. *Spanish Journal of Agricultural Research*, 7(4), 779. <https://doi.org/10.5424/sjar/2009074-1092>
- Baeza, P., Sánchez-De-Miguel, P., & Lissarrague, J. R. (2010). Radiation Balance in Vineyards. *Methodologies and Results in Grapevine Research*, 21–29. https://doi.org/10.1007/978-90-481-9283-0_2
- Balafoutis, A. T., Beck, B., Fountas, S., Tsiropoulos, Z., Vangeyte, J., van der Wal, T., Soto-Embodas, I., Gómez-Barbero, M., & Pedersen, S. M. (2017). Smart Farming Technologies – Description, Taxonomy and Economic Impact. *Progress in Precision Agriculture*, 21–77. https://doi.org/10.1007/978-3-319-68715-5_2
- Baluja, J., Diago, M. P., Balda, P., Zorer, R., Meggio, F., Morales, F., & Tardaguila, J. (2012). Assessment of vineyard water status variability by thermal and multispectral imagery using an unmanned aerial vehicle (UAV). *Irrigation Science*, 30(6), 511–522. <https://doi.org/10.1007/s00271-012-0382-9>
- Barata, A., Malfeito-Ferreira, M., & Loureiro, V. (2012). The microbial ecology of wine grape berries. *International Journal of Food Microbiology*, 153(3), 243–259. <https://doi.org/10.1016/j.ijfoodmicro.2011.11.025>
- Baret, F., & Guyot, G. (1991). Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of Environment*, 35(2–3), 161–173. <https://doi.org/10.1016/0034->

4257(91)90009-u

- Barnes, E.M., Clarke, T.R., Richards, S.E., Colaizzi, P.D., Haberland, J., Kostrzewski, M., Waller, P.M., Choi, C.Y., Riley, E., Thompson, T.L., Lascano, R.J., Li, H., Moran, M.S., Robert, P.C., Rust, R.H., & Larson, W.E. (2000). Coincident detection of crop water stress, nitrogen status and canopy density using ground-based multispectral data. In *Proceedings of the 5th International Conference on Precision Agriculture and other resource management* July 16-19, 2000, Bloomington, MN USA.
- Baruch, Z. & Fisher, M. (1991). Factores climáticos y de competencia que afectan el desarrollo de la planta en el establecimiento de una pastura. *Establecimiento Y Renovación de Pasturas*. CIAT. Cali, Colombia, 103–42.
- Bastiaanssen, W. G. M., Cheema, M. J. M., Immerzeel, W. W., Miltenburg, I. J., & Pelgrum, H. (2012). Surface energy balance and actual evapotranspiration of the transboundary Indus Basin estimated from satellite measurements and the ETLook model. *Water Resources Research*, 48, W11512. <https://doi.org/10.1029/2011WR010482>
- Bastiaanssen, W., Menenti, M., Feddes, R., & Holtslag, A. (1998). A remote sensing surface energy balance algorithm for land (SEBAL). 1. Formulation. *Journal of Hydrology*, 212-213, 198–212. [https://doi.org/10.1016/s0022-1694\(98\)00253-4](https://doi.org/10.1016/s0022-1694(98)00253-4)
- Beeri, O., Netzer, Y., Munitz, S., Mintz, D. F., Pelta, R., Shilo, T., Horesh, A., & Mey-tal, S. (2020). Kc and LAI Estimations Using Optical and SAR Remote Sensing Imagery for Vineyards Plots. *Remote Sensing*, 12(21), 3478. <https://doi.org/10.3390/rs12213478>
- Birrel, S.J., S.C. Borgelt, & K.A. Sudduth. (1995). Crop yield mapping: Comparison of yield monitors and mapping techniques. In *Proceedings of 2nd International Conference on Site-Specific Management for Agricultural Systems*. Madison WI: ASA-CSSA-SSSA.
- Birth, G. S., & McVey, G. R. (1968). Measuring the Color of Growing Turf with a Reflectance Spectrophotometer 1. *Agronomy Journal*, 60(6), 640–643. <https://doi.org/10.2134/agronj1968.00021962006000060016x>
- Bokulich, N. A., Thorngate, J. H., Richardson, P. M., & Mills, D. A. (2013). Microbial biogeography of wine grapes is conditioned by cultivar, vintage, and climate. *Proceedings of the National Academy of Sciences*, 111(1), E139-E148. <https://doi.org/10.1073/pnas.1317377110>
- Bonaccorso, G. (2018). *Machine learning algorithms: Popular algorithms for data science and machine learning*. Packt.
- Bongiovanni, R., & Lowenberg-Deboer, J. (2004). Precision Agriculture and Sustainability. *Precision Agriculture* 5, 359–387 <https://doi.org/10.1023/B:PRAG.0000040806.39604.aa>
- Borgogno-Mondino, E., Novello, V., Lessio, A., Tarricone, L., & de Palma, L. (2018). Intra-vineyard variability description through satellite-derived spectral indices as related to soil and vine water status. *Acta Horticulturae*, 1197, 59–68. <https://doi.org/10.17660/actahortic.2018.1197.8>
- Box G.E.P., Jenkins G.M., Reinsel G.C., & Ljung G.M. (2015). *Time Series Analysis: Forecasting and Control* (5th ed.). John Wiley and Sons Inc.

- Bramley R.G.V., & Hamilton R.P. (2008). Understanding variability in winegrape production systems. *Australian Journal of Grape and Wine Research*, 10(1), 32–45. <https://doi.org/10.1111/j.1755-0238.2004.tb00006.x>
- Bramley, R. & Lamb, D. (2003). Making sense of vineyard variability in Australia. In: Ortega, R. and Esser, A. (Eds) Precision Viticulture. *Proceedings of an international symposium held as part of the IX Congreso Latinoamericano de Viticultura y Enología*, Santiago, Chile. pp. 35-54.
- Brown, L. (2000). A Shortwave Infrared Modification to the Simple Ratio for LAI Retrieval in Boreal Forests: An Image and Model Analysis. *Remote Sensing of Environment*, 71(1), 16–25. [https://doi.org/10.1016/s0034-4257\(99\)00035-8](https://doi.org/10.1016/s0034-4257(99)00035-8)
- Cancela, J., Fandiño, M., Rey, B., Dafonte, J., & González, X. (2017). Discrimination of irrigation water management effects in pergola trellis system vineyards using a vegetation and soil index. *Agricultural Water Management*, 183, 70–77. <https://doi.org/10.1016/j.agwat.2016.11.003>
- Candiago, S., Remondino, F., de Giglio, M., Dubbini, M., & Gattelli, M. (2015). Evaluating Multispectral Images and Vegetation Indices for Precision Farming Applications from UAV Images. *Remote Sensing*, 7(4), 4026–4047. <https://doi.org/10.3390/rs70404026>
- Carbonneau, A. (1976). Principes et méthodes de mesure de la surface foliaire. Essai de caractérisation des types de feuilles dans le genre Vitis, Ann. Amélior. Plantes, vol.26, issue.2, pp.327-343.
- Cardina, J., Johnson, G., & Sparrow, D. (1997). The nature and consequence of weed spatial distribution. *Weed Science*, 45(3), 364-373. doi:10.1017/S0043174500092997
- Cardot, H., Ferraty, F., & Sarda, P. (1999). Functional linear model. *Statistics & Probability Letters*, 45(1), 11–22. [https://doi.org/10.1016/s0167-7152\(99\)00036-x](https://doi.org/10.1016/s0167-7152(99)00036-x)
- Caruso, G., Tozzini, L., Rallo, G., Primicerio, J., Moriondo, M., Palai, G. & Gucci, R. (2017). Estimating biophysical and geometrical parameters of grapevine canopies ('Sangiovese') by an unmanned aerial vehicle (UAV) and VIS-NIR cameras. *Vitis*, Vol 56, No 2. <https://doi.org/10.5073/vitis.2017.56.63-70>
- Chang, J., & Shoshany, M. (2016). Mediterranean shrublands biomass estimation using Sentinel-1 and Sentinel-2. *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Beijing, China, 10 July 2016, pp. 5300–5303. <https://doi.org/10.1109/igarss.2016.7730380>
- Chen, B., Jin, Y., & Brown, P. (2019). An enhanced bloom index for quantifying floral phenology using multi-scale remote sensing observations. *ISPRS Journal of Photogrammetry and Remote Sensing*, 156, 108–120. <https://doi.org/10.1016/j.isprsjprs.2019.08.006>
- Comba, L., Biglia, A., Ricauda Aimonino, D., Tortia, C., Mania, E., Guidoni, S., & Gay, P. (2020). Leaf Area Index evaluation in vineyards using 3D point clouds from UAV imagery. *Precision Agriculture*, 21(4), 881–896. <https://doi.org/10.1007/s11119-019-09699-x>
- Corwin, D.L., S.M. Lesch, & D.B. Lobell. (2012). Chapter 10: Laboratory and field measurements. In *Agricultural Salinity Assessment and Management* (2nd ed.). eds. K.K. Tanji and W. Wallender, 295–341. American Society of Civil Engineers. <https://doi.org/10.1061/9780784411698>
- Cosme, F., Vilela, A., Moreira, L., Moura, C., Enríquez, J. A. P., Filipe-Ribeiro, L., & Nunes, F. M. (2020). Terroir Effect on the Phenolic Composition and Chromatic Characteristics of Mencía/Jaen Monovarietal

- Wines: Bierzo D.O. (Spain) and Dão D.O. (Portugal). *Molecules*, 25(24), 6008. <https://doi.org/10.3390/molecules25246008>
- Crago, R., & Brutsaert, W. (1996). Daytime evaporation and the self-preservation of the evaporative fraction and the Bowen ratio. *Journal of Hydrology*, 178(1-4), 241-255. [https://doi.org/10.1016/0022-1694\(95\)02803-x](https://doi.org/10.1016/0022-1694(95)02803-x)
- Creasy, G.L. & Creasy, L.L. (2009). *Crop Production Science in Horticulture 16: Grapes*. CABI.
- Cutler, D. R., Edwards, T. C., Beard, K. H., Cutler, A., Hess, K. T., Gibson, J., & Lawler, J. J. (2007). Random Forests for classification in ecology. *Ecology*, 88(11), 2783-2792. <https://doi.org/10.1890/07-0539.1>
- Damm, A., Guanter, L., Verhoef, W., Schläpfer, D., Garbari, S., & Schaepman, M. E. (2015). Impact of varying irradiance on vegetation indices and chlorophyll fluorescence derived from spectroscopy data. *Remote Sensing of Environment*, 156, 202-215. <https://doi.org/10.1016/j.rse.2014.09.031>
- Dash, J., & Curran, P. J. (2004). The MERIS terrestrial chlorophyll index. *International Journal of Remote Sensing*, 25(23), 5403-5413. <https://doi.org/10.1080/0143116042000274015>
- Daughtry, C. (2000). Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. *Remote Sensing of Environment*, 74(2), 229-239. [https://doi.org/10.1016/s0034-4257\(00\)00113-9](https://doi.org/10.1016/s0034-4257(00)00113-9)
- De Bei, R., Fuentes, S., Gilliam, M., Tyerman, S., Edwards, E., Bianchini, N., Smith, J., & Collins, C. (2016). VitiCanopy: A Free Computer App to Estimate Canopy Vigor and Porosity for Grapevine. *Sensors*, 16(4), 585. <https://doi.org/10.3390/s16040585>
- Deering, D.W., Rouse, J.W., Haas, R.H., & J.A. Schell. (1975). Measuring "Forage Production" of Grazing Units from Landsat MSS Data, *Proceedings of the 10th International Symposium on Remote Sensing of Environment*, II:1169-1178.
- Del Rey, R. 2013. Hacia viticulturas más eficientes, diversas y orientadas al mercado. *Vida Rural* 364 (Año XX): 31-34.
- Del-Moral-Martínez, I., Rosell-Polo, J., Company, J., Sanz, R., Escolà, A., Masip, J., Martínez-Casasnovas, J., & Arnó, J. (2016). Mapping Vineyard Leaf Area Using Mobile Terrestrial Laser Scanners: Should Rows be Scanned On-the-Go or Discontinuously Sampled? *Sensors*, 16(1), 119. <https://doi.org/10.3390/s16010119>
- Delrot, S., Medrano, H., Or, E., Bavaresco, L., & Grando, S. (2010). *Methodologies and Results in Grapevine Research*. Springer. <https://doi.org/10.1007/978-90-481-9283-0>
- Devaux, N., Crestey, T., Leroux, C., & Tisseyre, B. (2019). Potential of Sentinel-2 satellite images to monitor vine fields grown at a territorial scale. *OENO One*, 53(1). <https://doi.org/10.20870/oenone.2019.53.1.2293>
- di Gennaro, S., Dainelli, R., Palliotti, A., Toscano, P., & Matese, A. (2019). Sentinel-2 Validation for Spatial Variability Assessment in Overhead Trellis System Viticulture Versus UAV and Agronomic Data. *Remote Sensing*, 11(21), 2573. <https://doi.org/10.3390/rs11212573>

- Diago, M. P., Correa, C., Millán, B., Barreiro, P., Valero, C., & Tardaguila, J. (2012). Grapevine Yield and Leaf Area Estimation Using Supervised Classification Methodology on RGB Images Taken under Field Conditions. *Sensors*, 12(12), 16988–17006. <https://doi.org/10.3390/s121216988>
- Dube, T., Pandit, S., Shoko, C., Ramoelo, A., Mazvimavi, D., & Dalu, T. (2019). Numerical Assessments of Leaf Area Index in Tropical Savanna Rangelands, South Africa Using Landsat 8 OLI Derived Metrics and In-Situ Measurements. *Remote Sensing*, 11(7), 829. <https://doi.org/10.3390/rs11070829>
- Easlon, H. M., & Bloom, A. J. (2014). Easy Leaf Area: Automated digital image analysis for rapid and accurate measurement of leaf area. *Applications in Plant Sciences*, 2(7), 1400033. <https://doi.org/10.3732/apps.1400033>
- Efron, B. (1979). Bootstrap Methods: Another Look at the Jackknife. *The Annals of Statistics*, 7(1). <https://doi.org/10.1214/aos/1176344552>
- Emilien, A.-V., Thomas, C., & Thomas, H. (2021). UAV & satellite synergies for optical remote sensing applications: A literature review. *Science of Remote Sensing*, 3, 100019. <https://doi.org/10.1016/j.srs.2021.100019>
- European Space Agency (ESA). *SENTINEL-2 User Handbook ESA Standard Document: 2015*. Accedido el 6/11/2021: https://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook.
- Evert R.F. & Eichhorn S.E. (2013). *Raven, Biology of plants*. Freeman and Company Worth Publishers.
- Fang, H., Baret, F., Plummer, S., & Schaepman-Strub, G. (2019). An Overview of Global Leaf Area Index (LAI): Methods, Products, Validation, and Applications. *Reviews of Geophysics*, 57(3), 739–799. <https://doi.org/10.1029/2018RG000608>
- FAO, Food and Agriculture Organization of the United Nations. (2021). *From Space to Farm: Characterization of Small Farms Using Remote Sensing Data*. Accedido el 11/11/2021: <http://www.fao.org/3/cb3777en/cb3777en.pdf>
- Febrero, M., Galeano, P., & González-Manteiga, W. (2008). Outlier detection in functional data by depth measures, with application to identify abnormal NOx levels. *Environmetrics*, 19(4), 331–345. <https://doi.org/10.1002/env.878>
- Feng, A., Zhou, J., Vories, E. D., Sudduth, K. A., & Zhang, M. (2020). Yield estimation in cotton using UAV-based multi-sensor imagery. *Biosystems Engineering*, 193, 101–114. <https://doi.org/10.1016/j.biosystemseng.2020.02.014>
- Ferguson, L., Polito, V. & Kallsen, C. (2005). The pistachio tree: botany and physiology and factors that affect yield. In *Pistachio Production Manual* (4th ed.). University of California, Davis.
- Fernández, M.V., Peña, I., & Sánchez, J.D.P. (2011). Factors of Competitiveness in the Wine Industry: an Analysis of Innovation Strategy. *International Journal of Economics and Management Engineering*, 5(6), 11. <https://doi.org/10.5281/zenodo.1076182>
- Ferraty, F., & Vieu, P. (2006). *Non-parametric functional data analysis, Springer Series in Statistics*. Springer.
- Ferreira, R., Sellés, G., & Tosso, J. (1985). Efecto de diferentes alturas de agua sobre el cultivo del pimiento. I. Influencia de los excesos de humedad. *Agricultura Técnica*, 45 (1):47–51.

- Fountas, S., Anastasiou, E., Balafoutis, A., Koundouras, S., Theoharis, S., & Theodorou, N. (2014). The influence of vine variety and vineyard management on the effectiveness of canopy sensors to predict winegrape yield and quality. In *Proceedings of the International Conference of Agricultural Engineering*, Zurich, Switzerland, 6–10 July 2014.
- Fuentes, S., Poblete-Echeverría, C., Ortega-Farias, S., Tyerman, S., & De Bei, R. (2014). Automated estimation of leaf area index from grapevine canopies using cover photography, video and computational analysis methods: New automated canopy vigour monitoring tool. *Australian Journal of Grape and Wine Research*, 20(3), 465–473. <https://doi.org/10.1111/ajgw.12098>
- Gascon, F., Gastellu-Etchegorry, J. P., Lefevre-Fonollosa, M. J., & Dufrene, E. (2004). Retrieval of forest biophysical variables by inverting a 3D radiative transfer model and using high and very high resolution imagery. *International Journal of Remote Sensing*, 25(24), 5601–5616
- Giles, D.K. & Downey, D. (2003). Quality Control Verification and Mapping for Chemical Application. *Precision Agriculture* 4, 103–124 <https://doi.org/10.1023/A:1021871207195>
- Gitelson, A. A., & Merzlyak, M. N. (1998). Remote sensing of chlorophyll concentration in higher plant leaves. *Advances in Space Research*, 22(5), 689–692. [https://doi.org/10.1016/s0273-1177\(97\)01133-2](https://doi.org/10.1016/s0273-1177(97)01133-2)
- Gitelson, A. A., Gritz, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, 160(3), 271–282. <https://doi.org/10.1078/0176-1617-00887>
- Goldsmith, J., Bobb, J., Crainiceanu, C. M., Caffo, B., & Reich, D. (2011). Penalized Functional Regression. *Journal of Computational and Graphical Statistics*. <https://doi.org/10.1198/jcgs.2010.10007>
- Gómez-Candón, D., Bellvert, J., & Royo, C. (2021). Performance of the Two-Source Energy Balance (TSEB) Model as a Tool for Monitoring the Response of Durum Wheat to Drought by High-Throughput Field Phenotyping. *Frontiers in Plant Science*, 12, 658357. <https://doi.org/10.3389/fpls.2021.658357>
- Gower, S. T., Kucharik, C. J., & Norman, J. M. (1999). Direct and Indirect Estimation of Leaf Area Index, fAPAR, and Net Primary Production of Terrestrial Ecosystems. *Remote Sensing of Environment*, 70(1), 29–51. [https://doi.org/10.1016/s0034-4257\(99\)00056-5](https://doi.org/10.1016/s0034-4257(99)00056-5)
- Grenzdörffer, G.J., Engel, A. & Teichert, B. (2008). The photogrammetric potential of low- cost UAVs in forestry and agriculture. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Vol. XXXVII. Part B1.
- Haboudane, D., Miller, J.R., Pattey E., Zarco-Tejada P.J. & Strachan I.B. (2004). Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing of Environment*, 90(3), 337–352. <https://doi.org/10.1016/j.rse.2003.12.013>
- Hackeling, G. (2014). *Mastering machine learning with scikit-learn: Apply effective learning algorithms to real-world problems using scikit-learn*. Packt.
- Hall, A., Lamb, D. W., Holzapfel, B. P., & Louis, J. P. (2010). Within-season temporal variation in correlations between vineyard canopy and winegrape composition and yield. *Precision Agriculture*, 12(1), 103–117. <https://doi.org/10.1007/s11119-010-9159-4>

- Hall, A., Lamb, D. W., Holzapfel, B. P., & Louis, J. P. (2010). Within-season temporal variation in correlations between vineyard canopy and winegrape composition and yield. *Precision Agriculture*, 12(1), 103–117. <https://doi.org/10.1007/s11119-010-9159-4>
- Hall, A., Lamb, D.W., Holzapfel, B., & Louis, J. (2002). Optical remote sensing applications in viticulture - a review. *Australian Journal of Grape and Wine Research*, 8(1), 36–47. <https://doi.org/10.1111/j.1755-0238.2002.tb00209.x>
- Hall, A., Louis, J., & Lamb, D. (2008). Low-resolution remotely sensed images of winegrape vineyards map spatial variability in planimetric canopy area instead of leaf area index. *Australian Journal of Grape and Wine Research*, 14(1), 9–17. <https://doi.org/10.1111/j.1755-0238.2008.00002.x>
- Hall, C.M. & Mitchell, R. (2008). *Wine Marketing: A Practical Guide* (1st ed). Elsevier.
- Hecht, E. (2017). *Optics* (5 ed). Pearson Education, Inc.
- Hidalgo, J. (2006). *La calidad del vino desde el viñedo*. Mundi-Prensa.
- Hilker, T., Coops, N. C., Hall, F. G., Nichol, C. J., Lyapustin, A. & Black, T. A. (2011). Inferring terrestrial photosynthetic light use efficiency of temperate ecosystems from space. *Journal of Geophysical Research*, 116, G03014. <https://doi.org/10.1029/2011JG001692>
- Hu, B., Miller, J. R., Chen, J. M., & Hollinger, A. (2004). Retrieval of the canopy leaf area index in the BOREAS flux tower sites using linear spectral mixture analysis. *Remote Sensing of Environment*, 89(2), 176–188.
- Huang, D.Y., Lin, T.W. & Hu, W.C. (2011). Automatic multilevel thresholding based on two-stage otsu's method with cluster determination by valley estimation. *International Journal of Innovative Computing, Information and Control*, 7 (10):5631–5644.
- Hubbard, K. (1994). Spatial variability of daily weather variables in the high plains of the USA. *Agricultural and Forest Meteorology*, 68(1–2), 29–41. [https://doi.org/10.1016/0168-1923\(94\)90067-1](https://doi.org/10.1016/0168-1923(94)90067-1)
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-x](https://doi.org/10.1016/0034-4257(88)90106-x)
- Huete, A.R., Justice, C., & van Leeuwen, W. (1999). *MODIS Vegetation Index (MOD13) Algorithm Theoretical Basis Document*. http://modis.gsfc.nasa.gov/data/atbd/atbd_mod13.pdf, 120p.
- Hung, M.-C., Wu, J., Chang, J.-H. & Yang, D.-L. (2005). *An Efficient K-Means Clustering Algorithm Using Simple Partitioning*. *Journal of Information Science and Engineering*, Vol. 21 No. 6, pp. 1157–1177.
- Hyndman, R., Koehler, A., Ord, K., & Snyder, R. (2008). Forecasting with Exponential Smoothing. *Springer Series in Statistics*. <https://doi.org/10.1007/978-3-540-71918-2>
- INE, Instituto Nacional de Estadística. (2018). *España en Cifras 2018*. INE.
- Jackson, R. (2020). *Wine Science: Principles and Applications*, 5th ed. Elsevier.
- Jiang, H., Wang, S., Cao, X., Yang, C., Zhang, Z., & Wang, X. (2018). A shadow- eliminated vegetation index (SEVI) for removal of self and cast shadow effects on vegetation in rugged terrains. *International Journal of Digital Earth*, 12(9), 1013–1029. <https://doi.org/10.1080/17538947.2018.1495770>

- Jiang, Z., Huete, A. R., Didan, K., & Miura, T. (2008). Development of a two-band enhanced vegetation index without a blue band. *Remote Sensing of Environment*, 112(10), 3833-3845. <https://doi.org/10.1016/j.rse.2008.06.006>
- Johnson, L. F. (2003). Temporal stability of an NDVI-LAI relationship in a Napa Valley vineyard. *Australian Journal of Grape and Wine Research*, 9(2), 96-101. <https://doi.org/10.1111/j.1755-0238.2003.tb00258.x>
- Johnson, L. F., & Pierce, L. L. (2004). Indirect Measurement of Leaf Area Index in California North Coast Vineyards. *HortScience*, 39(2), 236-238. <https://doi.org/10.21273/hortsci.39.2.236>
- Johnson, L., & Scholasch, T. (2005). Remote Sensing of Shaded Area in Vineyards. *HortTechnology*, 15(4), 859-863. <https://doi.org/10.21273/horttech.15.4.0859>
- Johnson, L., Roczen, D., Youkhana, S., Nemani, R., & Bosch, D. (2003). Mapping vineyard leaf area with multispectral satellite imagery. *Computers and Electronics in Agriculture*, 38(1), 33-44. [https://doi.org/10.1016/s0168-1699\(02\)00106-0](https://doi.org/10.1016/s0168-1699(02)00106-0)
- Johnson, L.F., Bosch, D.F., Williams, D.C., & Lobitz, B.M. (2001). Remote sensing of vineyard management zones: Implications for wine quality. *Applied Engineering in Agriculture*, 17(4). <https://doi.org/10.13031/2013.6454>
- Jolliffe, I.T. (2002). *Principal component analysis* (2nd ed.). Springer-Verlag.
- Jonckheere, I., Fleck, S., Nackaerts, K., Muys, B., Coppin, P., Weiss, M., & Baret, F. (2004). Review of methods for in situ leaf area index determination. *Agricultural and Forest Meteorology*, 121(1-2), 19-35. <https://doi.org/10.1016/j.agrformet.2003.08.027>
- Joyce, K. E., Belliss, S. E., Samsonov, S. V., McNeill, S. J., & Glassey, P. J. (2009). A review of the status of satellite remote sensing and image processing techniques for mapping natural hazards and disasters. *Progress in Physical Geography: Earth and Environment*, 33(2), 183-207. <https://doi.org/10.1177/0309133309339563>
- Kääb, A., Winsvold, S., Altena, B., Nuth, C., Nagler, T., & Wuite, J. (2016). Glacier Remote Sensing Using Sentinel-2. Part I: Radiometric and Geometric Performance, and Application to Ice Velocity. *Remote Sensing*, 8(7), 598. <https://doi.org/10.3390/rs8070598>
- Kalisperakis, I., Stentoumis, C., Grammatikopoulos, L., & Karantza, K. (2015). Leaf Area Index estimation in vineyards from UAV hyperspectral data, 2D image mosaics and 3D canopy surface models. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL-1/W4, 299-303. <https://doi.org/10.5194/isprsarchives-xl-1-w4-299-2015>
- Kazmierski, M., Glémas, P., Rousseau, J., & Tisseire, B. (2011). Temporal stability of within-field patterns of NDVI in non irrigated Mediterranean vineyards. *OENO One*, 45(2), 61. <https://doi.org/10.20870/oeno-one.2011.45.2.1488>
- Keller, M. (2015). *The Science of Grapevines: Anatomy and Physiology*. (2nd ed.). Elsevier/AP, Academic Press.
- Keller, O. (2014). *LIGHT: The Physics of the Photon*. CRC Press, Taylor & Francis Group.
- Knipper, K.R., Kustas, W.P., Anderson, M.C., Alsina, M.M., Hain, C.R., Alfieri, J.G., Prueger, J.H., Gao, F., McKee, L.G., & Sanchez, L.A. (2019). Using High-Spatiotemporal Thermal Satellite ET Retrievals for

- Operational Water Use and Stress Monitoring in a California Vineyard. *Remote Sensing*, 11(18), 2124. <https://doi.org/10.3390/rs11182124>
- Krishna, K.R. (2016). *Push button agriculture: Robotics, UAVs, satellite-guided soil and crop management*. Apple Academic Press, Inc. CRC Press, Taylor & Francis Group.
- Kuhn, M. (2008). Building Predictive Models in R Using the caret Package. *Journal of Statistical Software*, 28(5), 1–26. <https://doi.org/10.18637/jss.v028.i05>
- Lacroix, P., Bièvre, G., Pathier, E., Kniess, U., & Jongmans, D. (2018). Use of Sentinel-2 images for the detection of precursory motions before landslide failures. *Remote Sensing of Environment*, 215, 507–516. <https://doi.org/10.1016/j.rse.2018.03.042>
- Lamb, D. W., Weedon, M. M., & Bramley, R. G. V. (2008). Using remote sensing to predict grape phenolics and colour at harvest in a Cabernet Sauvignon vineyard: Timing observations against vine phenology and optimising image resolution. *Australian Journal of Grape and Wine Research*, 10(1), 46–54. <https://doi.org/10.1111/j.1755-0238.2004.tb00007.x>
- Lamb, D., Hall, A. & Louis, J. (2001) Airborne remote sensing of grapevines for canopy variability and productivity. *The Australian Grapegrower and Winemaker* 449a, 89–92.
- Lambers, H., & Oliveira, R. S. (2019). *Plant Physiological Ecology*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-29639-1>
- Larson, W.E., & P.C. Robert. (1995). Farming by soil. In *Soil Management for Sustainability*, eds. R. Lal and F.J. Pierce, 103–112. Soil and Water Conservation Society.
- Ledderhof, D., Brown, R., Reynolds, A., & Jollineau, M. (2016). Using remote sensing to understand Pinot noir vineyard variability in Ontario. *Canadian Journal of Plant Science*, 96(1), 89–108. <https://doi.org/10.1139/cjps-2015-0120>
- Leng, X., & Müller, H. G. (2006). Classification using functional data analysis for temporal gene expression data. *Bioinformatics*, 22(1), 68–76. <https://doi.org/10.1093/bioinformatics/bti742>
- Ley 24/2003, de 10 de julio, de la Viña y del Vino. (2003). Boletín Oficial del Estado núm. 165, de 11 de julio de 2003. Pags 27165 a 27179. <https://www.boe.es/boe/dias/2003/07/11/pdfs/A27165-27179.pdf>
- Li, J., & Roy, D. (2017). A Global Analysis of Sentinel-2A, Sentinel-2B and Landsat-8 Data Revisit Intervals and Implications for Terrestrial Monitoring. *Remote Sensing*, 9(9), 902. <https://doi.org/10.3390/rs9090902>
- Li, Y., Martinis, S., Plank, S., & Ludwig, R. (2018). An automatic change detection approach for rapid flood mapping in Sentinel-1 SAR data. *International Journal of Applied Earth Observation and Geoinformation*, 73, 123–135. <https://doi.org/10.1016/j.jag.2018.05.023>
- Lopes, C. & Pinto, P.A. (2005). Easy and Accurate Estimation of Grapevine Leaf Area with Simple Mathematical Models. *Vitis* 44 (2), 55–61. <https://doi.org/10.5073/vitis.2005.44.55-61>
- Lorenzo, N., Díaz-Poso, A., & Royé, D. (2021). Heatwave intensity on the Iberian Peninsula: Future climate projections. *Atmospheric Research*, 258, 105655. <https://doi.org/10.1016/j.atmosres.2021.105655>

- Lykhovyd, P. (2020). Sweet Corn Yield Simulation Using Normalized Difference Vegetation Index and Leaf Area Index. *Journal of Ecological Engineering*, 21(3), 228–236. <https://doi.org/10.12911/22998993/118274>
- Ma, H., Qin, Q., & Shen, X. (2008). Shadow Segmentation and Compensation in High Resolution Satellite Images. *IGARSS 2008 - 2008 IEEE International Geoscience and Remote Sensing Symposium*, Boston, MA, USA, 8–11 July 2008, pp. II-1036–II-1039. <https://doi.org/10.1109/igarss.2008.4779175>
- Maes, W. H., & Steppe, K. (2019). Perspectives for Remote Sensing with Unmanned Aerial Vehicles in Precision Agriculture. *Trends in Plant Science*, 24(2), 152–164. <https://doi.org/10.1016/j.tplants.2018.11.007>
- Mananze, S., Pôças, I., & Cunha, M. (2018). Retrieval of Maize Leaf Area Index Using Hyperspectral and Multispectral Data. *Remote Sensing*, 10(12), 1942. <https://doi.org/10.3390/rs10121942>
- Marsett, R. C., Qi, J., Heilman, P., Biedenbender, S. H., Carolyn Watson, M., Amer, S., Weltz, M., Goodrich, D., & Marsett, R. (2006). Remote Sensing for Grassland Management in the Arid Southwest. *Rangeland Ecology and Management*, 59(5), 530–540. <https://doi.org/10.2111/05-201r.1>
- Martín, H., Gutiérrez, M.A., Vacas, R., Rubio, J.A., & Barajas, E. (2018). Evaluación de diferentes índices espectrales obtenidos por imágenes de satélite para discriminar la calidad del fruto del nogal en Castilla y León. In *Proceedings of the III Symposium Nacional de Ingeniería Hortícola, I Symposium Ibérico de Ingeniería Hortícola SECH. Uso de Drones y Satélites en Agricultura*, Lugo, Spain, 21–23 February 2018.
- Martínez-Casasnovas, J. A., Agelet-Fernandez, J., Arno, J., & Ramos, M. C. (2012). Analysis of vineyard differential management zones and relation to vine development, grape maturity and quality. *Spanish Journal of Agricultural Research*, 10(2), 326. <https://doi.org/10.5424/sjar/2012102-370-11>
- Matese, A., di Gennaro, S. F., & Berton, A. (2016). Assessment of a canopy height model (CHM) in a vineyard using UAV-based multispectral imaging. *International Journal of Remote Sensing*, 38(8–10), 2150–2160. <https://doi.org/10.1080/01431161.2016.1226002>
- Matese, A., Toscano, P., di Gennaro, S., Genesio, L., Vaccari, F., Primicerio, J., Belli, C., Zaldei, A., Bianconi, R., & Gioli, B. (2015). Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture. *Remote Sensing*, 7(3), 2971–2990. <https://doi.org/10.3390/rs70302971>
- Mathews, A., & Jensen, J. (2013). Visualising and Quantifying Vineyard Canopy LAI Using an Unmanned Aerial Vehicle (UAV) Collected High Density Structure from Motion Point Cloud. *Remote Sensing*, 5(5), 2164–2183. <https://doi.org/10.3390/rs5052164>
- Mercer, W. B. and Hall, A. D. (1911) Experimental error of field trials. *Journal of Agricultural Science*, Cambridge, 4, 107–132.
- Mercier, A., Betbeder, J., Baudry, J., le Roux, V., Spicher, F., Lacoux, J., Roger, D., & Hubert-Moy, L. (2020). Evaluation of Sentinel-1 & 2 time series for predicting wheat and rapeseed phenological stages. *ISPRS Journal of Photogrammetry and Remote Sensing*, 163, 231–256. <https://doi.org/10.1016/j.isprsjprs.2020.03.009>

- Meyer, L. H., Heurich, M., Beudert, B., Premier, J., & Pflugmacher, D. (2019). Comparison of Landsat-8 and Sentinel-2 Data for Estimation of Leaf Area Index in Temperate Forests. *Remote Sensing*, 11(10), 1160. <https://doi.org/10.3390/rs11101160>
- Millar, A.A. (1993). *Manejo de Agua Y Producción Agrícola*. Instituto Interamericano de Cooperación para la Agricultura, IICA.
- Ministerio de Agricultura, Pesca y Alimentación de España, MAPA. (2021). *Informe sobre la aplicación del régimen de autorizaciones de nuevas plantaciones de viñedo en 2020 y potencial de producción vitícola en España a 31 de julio de 2020*. Accedido el 10/10/2021. https://www.mapa.gob.es/es/agricultura/temas/regulacion-de-los-mercados/informepotencialviticola2021_tcm30-561191.pdf
- Ministerio de Agricultura, Pesca y Alimentación, MAPA. (2020). *Encuesta sobre Superficies y Rendimientos de Cultivos ESYRCE*. Accedido el 10/10/2021. https://www.mapa.gob.es/es/estadistica/temas/estadisticas-agrarias/totalespanayccaa2020_tcm30-553610.pdf
- Mirás-Avalos, J., & Araujo, E. (2021). Optimization of Vineyard Water Management: Challenges, Strategies, and Perspectives. *Water*, 13(6), 746. <https://doi.org/10.3390/w13060746>
- Montandon, L., & Small, E. (2008). The impact of soil reflectance on the quantification of the green vegetation fraction from NDVI. *Remote Sensing of Environment*, 112(4), 1835–1845. <https://doi.org/10.1016/j.rse.2007.09.007>
- Mueller, T., & Sassenrath, G. F. (2015). *GIS Applications in Agriculture, Volume Four: Conservation Planning*. CRC PressTaylor & Francis Group.
- Munitz, S., Schwartz, A., & Netzer, Y. (2019). Water consumption, crop coefficient and leaf area relations of a *Vitis vinifera* cv. “Cabernet Sauvignon” vineyard. *Agricultural Water Management*, 219, 86–94. <https://doi.org/10.1016/j.agwat.2019.03.051>
- NASA. Landsat Science (2021). *LANDSAT 8*. Accedido el 12/11/2021. <https://landsat.gsfc.nasa.gov/landsat-8/landsat-8-overview>
- Navarro, A., Rolim, J., Miguel, I., Catalão, J., Silva, J., Painho, M., & Vekerdy, Z. (2016). Crop Monitoring Based on SPOT-5 Take-5 and Sentinel-1A Data for the Estimation of Crop Water Requirements. *Remote Sensing*, 8(6), 525. <https://doi.org/10.3390/rs8060525>
- Nebiker, S., Annen, A., Scherrer, M., & Oesch, D. (2008). A Light-weight multispectral sensor for micro Uav - opportunities for very high resolution airborne remote sensing. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XXXVII*, December:1193-1200.
- Neinavaz, E., Darvishzadeh, R., Skidmore, A., & Abdullah, H. (2019). Integration of Landsat-8 Thermal and Visible-Short Wave Infrared Data for Improving Prediction Accuracy of Forest Leaf Area Index. *Remote Sensing*, 11(4), 390. <https://doi.org/10.3390/rs11040390>
- Netzer, Y., Yao, C., Shenker, M., Bravdo, B. A., & Schwartz, A. (2008). Water use and the development of seasonal crop coefficients for Superior Seedless grapevines trained to an open-gable trellis system. *Irrigation Science*, 27(2), 109–120. <https://doi.org/10.1007/s00271-008-0124-1>
- Nex, F., & Remondino, F. (2013). UAV for 3D mapping applications: a review. *Applied Geomatics*, 6(1), 1–15.

<https://doi.org/10.1007/s12518-013-0120-x>

- OIV. International Organisation of Vine and Wine. (2019). *2019 Statistical Report on World Vitiviniculture*. Accedido el 10/10/2021: <https://www.oiv.int/public/medias/6782/oiv-2019-statistical-report-on-world-vitiviniculture.pdf>
- Oliveira, M. & Santos, M. (1995) A semi-empirical method to estimate canopy leaf area of vineyards. *American Journal of Enology and Viticulture* 46, 389–391.
- Orlando, F., Movedi, E., Coduto, D., Parisi, S., Brancadoro, L., Pagani, V., Guarneri, T., & Confalonieri, R. (2016). Estimating Leaf Area Index (LAI) in Vineyards Using the PocketLAI Smart-App. *Sensors*, 16(12), 2004. <https://doi.org/10.3390/s16122004>
- Otsu, N. (1979). A Threshold selection method from gray-level histograms. *IEEE Transactions on Systems Man, and Cybernetics*, 9:62-66.
- Parent, A. C., & Anctil, F. (2012). Quantifying evapotranspiration of a rainfed potato crop in South-eastern Canada using eddy covariance techniques. *Agricultural Water Management*, 113, 45–56. <https://doi.org/10.1016/j.agwat.2012.06.014>
- Patočka, Z., Novosadová, K., Haninec, P., Pokorný, R., Mikita, T., & Klimánek, M. (2020). Comparison of LiDAR-based Models for True Leaf Area Index and Effective Leaf Area Index Estimation in Young Beech Forests. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, 68(3), 559–566. <https://doi.org/10.11118/actaun202068030559>
- Payero, J.O., & Irmak, S. (2008). Construction, installation, and performance of two repacked weighing lysimeters. *Irrigation Science*, 26 (2):191-202.
- Pérez-Ortega, J., Nely Almanza-Ortega, N., Vega-Villalobos, A., Pazos-Rangel, R., Zavala-Díaz, C., & Martínez-Rebollar, A. (2020). *The K-Means Algorithm Evolution. Introduction to Data Science and Machine Learning*. IntechOpen. <https://doi.org/10.5772/intechopen.85447>
- Perry, C. R., Jr., & Lautenschlager, L. F. (1984). Functional equivalence of spectral vegetation indices. *Remote Sensing of Environment*, 14(1–3), 169–182. [https://doi.org/10.1016/0034-4257\(84\)90013-0](https://doi.org/10.1016/0034-4257(84)90013-0)
- Pessarakli, M. (2014). *Plant and crop physiology* (3rd ed). CRC Press, Taylor & Francis Group.
- Pierce, F. J., & Clay, D. (2007). *GIS applications in agriculture*. CRC Press.
- Poblete-Echeverría, C., & Ortega-Farías, S. (2013). Evaluation of single and dual crop coefficients over a drip-irrigated Merlot vineyard (*Vitis vinifera* L.) using combined measurements of sap flow sensors and an eddy covariance system. *Australian Journal of Grape and Wine Research*, 19(2), 249–260. <https://doi.org/10.1111/ajgw.12019>
- Poblete-Echeverría, C., Acevedo-Opazo, C., Ortega-Farías, S., Valdés-Gómez, H. & Nuñez, R. (2009). Study of NDVI spatial variability over a Merlot vineyard-plot in Maule Region using a hand held Spectroradiometer. In *Proceedings of the 8th Fruit, Nut and vegetable production engineering symposium FRUTIC*, Concepción, Chile, 5–9 January 2009, pp. 182–189.
- Poblete-Echeverría, C., Olmedo, G., Ingram, B., & Bardeen, M. (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), 268. <https://doi.org/10.3390/rs9030268>

- Polari, J. J., Zhang, L., Ferguson, L., Maness, N. O., & Wang, S. C. (2019). Impact of Microclimate on Fatty Acids and Volatile Terpenes in “Kerman” and “Golden Hills” Pistachio (*Pistacia vera*) Kernels. *Journal of Food Science*, 84(7), 1937–1942. <https://doi.org/10.1111/1750-3841.14654>
- Prichard, T., Hanson, B., Schwankl, L., Verdegaal, P., & Smith, R. (2004). *Deficit Irrigation of Quality Winegrapes Using Micro-Irrigation Techniques*. UC Davis. Accedido el 22/10/2021: <http://cesanluisobispo.ucdavis.edu/files/89518.pdf>
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48(2), 119–126. [https://doi.org/10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1)
- Ramsay, J. & Silverman, B. (2005). *Functional Data Analysis* (2nd Ed.). Springer. <https://doi.org/10.1007/b98888>
- Reynier A. (1995). *Manual de Viticultura*. Mundi-Prensa.
- Reynolds, A. G., & Heuvel, J. E. V. (2009). Influence of Grapevine Training Systems on Vine Growth and Fruit Composition: A Review. *American Journal of Enology and Viticulture*. September 2009 60:251-268.
- Reynolds, A.G. (2010). *Managing Wine Quality. Volume 1: Viticulture and wine quality*. Woodhead Publishing.
- Richardson, A. D., Jenkins, J. P., Braswell, B. H., Hollinger, D. Y., Ollinger, S. V., & Smith, M. L. (2007). Use of digital webcam images to track spring green-up in a deciduous broadleaf forest. *Oecologia*, 152(2), 323–334. <https://doi.org/10.1007/s00442-006-0657-z>
- Robinson, J. (2006). *The Oxford Companion to Wine*. Oxford University Press.
- Rouse, J.W., Jr., R.H. Haas, J.A. Schell, & D.W. Deering. (1973). Monitoring vegetation systems in the Great Plains with ERTS. *ERTS Symp. 3rd*, Washington, DC. 10-14 Dec. 1972. NASA SP-351. Vol. I:309-317.
- Sánchez P. (2007). Producción y distribución de fotoasimilados en la vid (*Vitis vinifera* L.) durante el periodo de maduración. Cambios en la respuesta fotosintética a la luz de las hojas por factores biológicos, ambientales y culturales. (Tesis de Doctorado, Universidad Politécnica de Madrid). Repositorio Institucional – Universidad Politécnica de Madrid.
- Sánchez-de-Miguel, P., Junquera, P., De la Fuente, M., Jimenez, L., Linares, R., Baeza, P., & Lissarrague, J. R. (2011). Estimation of vineyard leaf area by linear regression. *Spanish Journal of Agricultural Research*, 9(1), 202. <https://doi.org/10.5424/sjar/20110901-354-10>
- Santesteban, L. G. (2019). Precision viticulture and advanced analytics. A short review. *Food Chemistry*, 279, 58–62. <https://doi.org/10.1016/j.foodchem.2018.11.140>
- Santesteban, L. G., Guillaume, S., Royo, J. B., & Tisseyre, B. (2013a). Are precision agriculture tools and methods relevant at the whole-vineyard scale? *Precision Agriculture*, 14(1), 2–17. <https://doi.org/10.1007/s11119-012-9268-3>
- Santesteban, L. G., Miranda, C., Jiménez, C., Fuentemilla, M., Urretavizcaya, I., Tisseyre, B., & Guillaume, S. (2010). Evaluación del interés del índice NDVI para la delimitación de unidades de manejo diferenciado en una explotación vitícola Evaluation of the interest of NDVI to identify distinct management units in vineyards. *Revista Española de Teledetección*, nº 33. Pags 11-16.


- Santesteban, L., di Gennaro, S., Herrero-Langreo, A., Miranda, C., Royo, J., & Matese, A. (2017). High-resolution UAV-based thermal imaging to estimate the instantaneous and seasonal variability of plant water status within a vineyard. *Agricultural Water Management*, 183, 49–59. <https://doi.org/10.1016/j.agwat.2016.08.026>
- Santesteban, L.G., Urretavizcaya, I., Miranda, C., Garcia, A. & Royo, J.B. (2013b) Agronomic significance of the zones defined within vineyards early in the season using NDVI and fruit load information. In *Proceedings of the Precision Agriculture '13: Papers Presented at the 9th European Conference on Precision Agriculture*, Lleida, Catalonia, Spain, 7–11 July 2013.
- Sanyal, J., & Lu, X. X. (2004). Application of Remote Sensing in Flood Management with Special Reference to Monsoon Asia: A Review. *Natural Hazards*, 33(2), 283–301. <https://doi.org/10.1023/b:nhaz.0000037035.65105.95>
- Schnebele, E., & Cervone, G. (2013). Improving remote sensing flood assessment using volunteered geographical data. *Natural Hazards and Earth System Sciences*, 13(3), 669–677. <https://doi.org/10.5194/nhess-13-669-2013>
- Seguin, G. (1986). 'Terroirs' and pedology of wine growing. *Experientia*, 42(8), 861–873. <https://doi.org/10.1007/bf01941763>
- Sertel, E., Seker, D.Z., Yay, I., Ozelkan, E., Saglam, M., Boz, Y., & Gunduz, A. (2012). Vineyard mapping using remote sensing technologies. *FIG Working Week 2012*. Rome, (Italy).
- Seydi, S. T., Akhoondzadeh, M., Amani, M., & Mahdavi, S. (2021). Wildfire Damage Assessment over Australia Using Sentinel-2 Imagery and MODIS Land Cover Product within the Google Earth Engine Cloud Platform. *Remote Sensing*, 13(2), 220. <https://doi.org/10.3390/rs13020220>
- Shang HL, Hyndman RJ (2010). Rainbow: Rainbow Plots, Bagplots and Boxplots for Functional Data. R package version 2.3.4., <http://cran.r-project.org/package=rainbow>
- Shankar, R. (2016). *Fundamentals of physics. II: Electromagnetism, optics, and quantum mechanics*. Yale University Press.
- Sharma, K. K. (2006). *Optics: Principles and applications*. Academic Press.
- Smart, R. & Robinson, M. (1991). *Sunlight into wine*. Winetitles.
- Sozzi, M., Kayad, A., Marinello, F., Taylor, J., & Tisseyre, B. (2020). Comparing vineyard imagery acquired from Sentinel-2 and Unmanned Aerial Vehicle (UAV) platform. *OENO One*, 54(2), 189–197. <https://doi.org/10.20870/oeno-one.2020.54.1.2557>
- Stenberg, P., Rautiainen, M., Manninen, T., Voipio, P., & Smolander, H. (2004). Reduced simple ratio better than NDVI for estimating LAI in Finnish pine and spruce stands. *Silva Fennica*, 38(1). <https://doi.org/10.14214/sf.431>
- Stöcker, C., Bennett, R., Nex, F., Gerke, M., & Zevenbergen, J. (2017). Review of the Current State of UAV Regulations. *Remote Sensing*, 9(5), 459. <https://doi.org/10.3390/rs9050459>
- Stumpf, A., Michéa, D., & Malet, J. P. (2018). Improved Co-Registration of Sentinel-2 and Landsat-8 Imagery for Earth Surface Motion Measurements. *Remote Sensing*, 10(2), 160. <https://doi.org/10.3390/rs10020160>

- Sun, L., Gao, F., Anderson, M., Kustas, W., Alsina, M., Sanchez, L., Sams, B., McKee, L., Dulaney, W., White, W., Alfieri, J., Prueger, J., Melton, F., & Post, K. (2017). Daily Mapping of 30 m LAI and NDVI for Grape Yield Prediction in California Vineyards. *Remote Sensing*, 9(4), 317. <https://doi.org/10.3390/rs9040317>
- Tagarakis, A., Liakos, V., Fountas, S., Koundouras, S., & Gemtos, T. A. (2013). Management zones delineation using fuzzy clustering techniques in grapevines. *Precision Agriculture*, 14(1), 18–39. <https://doi.org/10.1007/s11119-012-9275-4>
- Towers, P. C., Strever, A., & Poblete-Echeverría, C. (2019). Comparison of Vegetation Indices for Leaf Area Index Estimation in Vertical Shoot Positioned Vine Canopies with and without Grenbiule Hail-Protection Netting. *Remote Sensing*, 11(9), 1073. <https://doi.org/10.3390/rs11091073>
- Trout, T. J., Johnson, L. F., & Gartung, J. (2008). Remote Sensing of Canopy Cover in Horticultural Crops. *HortScience*, 43(2), 333–337. <https://doi.org/10.21273/hortsci.43.2.333>
- Urretavizcaya, I., Miranda, C., Royo, J.B. & Santesteban, L.G. (2015). Within-vineyard zone delineation in an area with diversity of training systems and plant spacing using parameters of vegetative growth and crop load. In *Proceedings of the Precision Agriculture '15: Papers Presented at the 10th European Conference on Precision Agriculture*, Volcani Center, Rishon LeTsiyon, Israel, 12–16 July 2015.
- USGS, U.S. Geological Survey. (2021). USGS EROS Archive - Sentinel-2 - Comparison of Sentinel-2 and Landsat. Accedido el 12/11/2021. https://www.usgs.gov/centers/eros/science/usgs-eros-archive-sentinel-2-comparison-sentinel-2-and-landsat?qt-science_center_objects=0#qt-science_center_objects
- Valiente, J. A., Nunez, M., Lopez-Baeza, E., & Moreno, J. F. (1995). Narrow-band to broad-band conversion for Meteosat-visible channel and broad-band albedo using both AVHRR-1 and -2 channels. *International Journal of Remote Sensing*, 16(6), 1147–1166. <https://doi.org/10.1080/01431169508954468>
- Vila, H., Perez Peña, J., García, M., Vallone, R.C., Mastrantonio, L., Olmedo, G.F., Rodríguez, L., & Salcedo, C. (2007). Estimación de la biomasa en viñedos mediante imágenes satelitales y aéreas de Mendoza, Argentina. *Congreso Internacional de La AET. Teledetección Hacia Un Mejor Entendimiento de La Dinámica Global Y Regional*. Editado por Rivas, R., Grisotto, R. and Sacido, A. 51 to 58.
- Vilar, P., Morais, T. G., Rodrigues, N. R., Gama, I., Monteiro, M. L., Domingos, T., & Teixeira, R. F. M. (2020). Object-Based Classification Approaches for Multitemporal Identification and Monitoring of Pastures in Agroforestry Regions using Multispectral Unmanned Aerial Vehicle Products. *Remote Sensing*, 12(5), 814. <https://doi.org/10.3390/rs12050814>
- Vivas, C. & Sousa, A. (2013). La Globalización en el Sector del Vino: Nuevo Mundo, Viejo Mundo y Portugal. *XXVII AEDEM Annual Meeting*. Huelva, Spain.
- Wang, L., Chang, Q., Li, F., Yan, L., Huang, Y., Wang, Q., & Luo, L. (2019). Effects of Growth Stage Development on Paddy Rice Leaf Area Index Prediction Models. *Remote Sensing*, 11(3), 361. <https://doi.org/10.3390/rs11030361>
- Wang, Q. J., Tian, Q. J., Lin, Q. Z., Li, M. X., & Wang, L. M. (2008). An improved algorithm for shadow restoration of high spatial resolution imagery. *Remote Sensing of the Environment: 16th National Symposium on Remote Sensing of China. Beijing, China, 7–10 September 2007*, p. 71230D.

<https://doi.org/10.1117/12.816170>

- Wang, Q., Pang, Y., Li, Z., Chen, E., Sun, G., & Tan, B. (2013). Improvement and application of the conifer forest multiangular hybrid GORT model MGeoSAIL. *IEEE Transactions on Geoscience and Remote Sensing*. <https://doi.org/10.1109/TGRS.2012.2234466>
- Watson, D. J. (1947). Comparative Physiological Studies on the Growth of Field Crops: I. Variation in Net Assimilation Rate and Leaf Area between Species and Varieties, and within and between Years. *Annals of Botany*, 11(1), 41–76. <https://doi.org/10.1093/oxfordjournals.aob.a083148>
- Webster, R., & Oliver, M. A. (2007). *Geostatistics for Environmental Scientists*. John Wiley & Sons Ltd.
- Weiss, M., & Baret, F. (2017). Using 3D Point Clouds Derived from UAV RGB Imagery to Describe Vineyard 3D Macro-Structure. *Remote Sensing*, 9(2), 111. <https://doi.org/10.3390/rs9020111>
- White, W. A., Alsina, M. M., Nieto, H., McKee, L. G., Gao, F., & Kustas, W. P. (2018). Determining a robust indirect measurement of leaf area index in California vineyards for validating remote sensing-based retrievals. *Irrigation Science*, 37(3), 269–280. <https://doi.org/10.1007/s00271-018-0614-8>
- Williams, L., & Martinson, T. E. (2003). Nondestructive leaf area estimation of ‘Niagara’ and ‘DeChaunac’ grapevines. *Scientia Horticulturae*, 98(4), 493–498. [https://doi.org/10.1016/s0304-4238\(03\)00020-7](https://doi.org/10.1016/s0304-4238(03)00020-7)
- Wu, J., & Bauer, M. (2013). Evaluating the Effects of Shadow Detection on QuickBird Image Classification and Spectroradiometric Restoration. *Remote Sensing*, 5(9), 4450–4469. <https://doi.org/10.3390/rs5094450>
- Yang, J., Gong, P., Fu, R., Zhang, M., Chen, J., Liang, S., Xu, B., Shi, J., & Dickinson, R. (2013). The role of satellite remote sensing in climate change studies. *Nature Climate Change*, 3(10), 875–883. <https://doi.org/10.1038/nclimate1908>
- Yang, Y., Wu, T., Wang, S., & Li, H. (2020). Fractional evergreen forest cover mapping by MODIS time-series FEVC-CV methods at sub-pixel scales. *ISPRS Journal of Photogrammetry and Remote Sensing*, 163, 272–283. <https://doi.org/10.1016/j.isprsjprs.2020.03.012>
- Yao, X., Wang, N., Liu, Y., Cheng, T., Tian, Y., Chen, Q., & Zhu, Y. (2017). Estimation of Wheat LAI at Middle to High Levels Using Unmanned Aerial Vehicle Narrowband Multispectral Imagery. *Remote Sensing*, 9(12), 1304. <https://doi.org/10.3390/rs9121304>
- Yost, M. A., Kitchen, N. R., Sudduth, K. A., Sadler, E. J., Drummond, S. T., & Volkmann, M. R. (2016). Long-term impact of a precision agriculture system on grain crop production. *Precision Agriculture*, 18(5), 823–842. <https://doi.org/10.1007/s11119-016-9490-5>
- Zarco-Tejada, P., Guillén-Climent, M., Hernández-Clemente, R., Catalina, A., González, M., & Martín, P. (2013). Estimating leaf carotenoid content in vineyards using high resolution hyperspectral imagery acquired from an unmanned aerial vehicle (UAV). *Agricultural and Forest Meteorology*, 171–172, 281–294. <https://doi.org/10.1016/j.agrformet.2012.12.013>
- Zarco-Tejada, P., Hubbard, N. & Loudjani, P. (2014) Precision agriculture: an opportunity for EU farmers – potential support with the CAP 2014–2020. *Joint Research Centre (JRC) of the European Commission. Monitoring Agriculture ResourceS (MARS)*. Unit H04, Brussels, Belgium

- Zhang, C., & Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: a review. *Precision Agriculture*, 13(6), 693–712. <https://doi.org/10.1007/s11119-012-9274-5>
- Zhang, H. K., Roy, D. P., Yan, L., Li, Z., Huang, H., Vermote, E., Skakun, S., & Roger, J. C. (2018). Characterization of Sentinel-2A and Landsat-8 top of atmosphere, surface, and nadir BRDF adjusted reflectance and NDVI differences. *Remote Sensing of Environment*, 215, 482–494. <https://doi.org/10.1016/j.rse.2018.04.031>
- Zhang, L., Sun, X., Wu, T., & Zhang, H. (2015). An Analysis of Shadow Effects on Spectral Vegetation Indexes Using a Ground-Based Imaging Spectrometer. *IEEE Geoscience and Remote Sensing Letters*, 12(11), 2188–2192. <https://doi.org/10.1109/lgrs.2015.2450218>
- Zhang, Z., & Chen, F. (2010). A shadow processing method of high spatial resolution remote sensing image. *2010 3rd International Congress on Image and Signal Processing*. <https://doi.org/10.1109/cisp.2010.5646850>
- Zhang, Z., Jin, Y., Chen, B., & Brown, P. (2019). California Almond Yield Prediction at the Orchard Level With a Machine Learning Approach. *Frontiers in Plant Science*, 10. <https://doi.org/10.3389/fpls.2019.00809>
- Zheng, G., & Moskal, L. M. (2009). Retrieving Leaf Area Index (LAI) Using Remote Sensing: Theories, Methods and Sensors. *Sensors*, 9(4), 2719–2745. <https://doi.org/10.3390/s90402719>



CAPÍTULO I

CAPÍTULO I. Agronomic classification between vineyards ('Verdejo') using NDVI and Sentinel-2 and evaluation of their wines.

VITIS

Journal of Grapevine Research

"Agronomic classification between vineyards ('Verdejo') using NDVI and Sentinel-2 and evaluation of their wines." Vélez, S.; Rubio, J.A.; Andrés, M.I.; Barajas, E. (2019). Vitis – Journal of Grapevine Research. Vol. 58 nº 5 (Special Issue), 33–38
doi: 10.5073/vitis.2019.58.special-issue.33-38.

Agronomic classification between vineyards ('Verdejo') using NDVI and Sentinel-2 and evaluation of their wines

S. VÉLEZ, J. A. RUBIO, M. I. ANDRÉS and E. BARAJAS

Instituto Tecnológico Agrario de Castilla y León, Unidad de Cultivos Leñosos y Hortícolas, Valladolid, Spain

Summary

A classification between three vineyards belonging to the Appellation of Origin Rueda (Castilla y León, Spain) has been established in veraison to determine the productive capacities of each vineyard and to study their impact on the grape quality. Several open-access multispectral images obtained from the SENTINEL-2A satellite in the year 2016 were used to calculate the NDVI (Normalized Difference Vegetation Index), which provides information about the vigour of the vineyards. Eleven cloud-free images were assessed and based on the NDVI, three vigour levels were established: high vigour (0.356-0.458), medium vigour (0.285-0.355) and low vigour (0.166-0.284). A level of vigour was assigned to each vineyard according to the NDVI mean values of its pixels. Significant differences were found in the pruning wood weight and yield: high, medium and low vigour values were 2438, 1895 and 1487 kg·ha⁻¹ and 15984, 12990 and 10576 kg·ha⁻¹, respectively. The highest values of total acidity (6.04 g·L⁻¹) and tartaric acid (9.05 g·L⁻¹) have been obtained in low vigour, as well as the lowest values of pH (3.26), malic acid (0.42 g·L⁻¹) and potassium (1640 ppm). Finally, one wine per vigour was produced and a tasting was carried out to check if the differences between the vineyards were perceptible. According to the obtained results, the NDVI is a good indicator to classify vineyards, finding notable differences between the experimental treatments studied.

Key words: Sentinel-2; NDVI evolution; NDVI changes; vineyard; remote sensing; *Vitis vinifera* L.

Introduction

In the next decade, forecasts point to a deceleration in food demand, due mainly to a lower world population growth and a foreseeable continuous improvement of the sector productivity (OECD/FAO 2018). Since the end of the 20th century, the vineyard world surface remains stable, with a certain downward tendency, as well as the wine production. The wine demand has grown slightly, mainly due to the increase of consumption in the United States, United Kingdom and China. In the traditional wine-producing countries the

situation is diverse, with a stable consumption in Spain and Portugal, a slight decrease in France and an increase in Italy (OIV 2017), although since 2000 in Europe the consumption trend shows a decrease (OIV 2012), so exportation could be positioned as a core element in the account balances of the European wineries. In this context, it is very important for wineries to obtain competitive advantages through technological innovation that allows them to compete in the market (FERNÁNDEZ *et al.* 2011). In addition, there are two models worldwide: European production model, based largely on Appellations of Origin, with exhaustive quality controls, limited and highly regulated productions and the new emerging producing countries, whose production is much more liberalized (VIVAS *et al.* 2013).

Therefore, it could be interesting to develop and use tools that allow not only to improve the quality of the products but also to increase efficiency, productivity and input reduction in order to make farms more competitive. To achieve this goal, the use of remote sensing technology is crucial, since it allows to obtain information quickly, accurately, objectively and non-destructively, in such a way that accurate measurements of the grapevines can be taken almost in real time (KRISHNA 2016).

A practical application is the calculation of the NDVI (Normalized Difference Vegetation Index), which has proved to be a useful tool for monitoring table grape quality characteristics (ANASTASIOU *et al.* 2018) or certain crops in the growth stage, by monitoring canopy cover (TROUT *et al.* 2008). More specifically, in the vineyard it has been possible to estimate certain parameters (JOHNSON *et al.* 2001, MARTINEZ-CASASNOVAS *et al.* 2012). The NDVI has also been related to other parameters measured in the field, such as LAI, obtaining good results (JOHNSON 2003).

All of these considerations lead to an increasing interest in precision agriculture, at least in the scientific and research field (SANTESTEBAN 2019) and it seems to be a promising area in which currently there is a lot of progress. For example, the use of UAV and specific cameras to obtain high-resolution images of the vineyard allow the estimation of parameters as complex as the canopy height or the Leaf Area Index (CARUSO *et al.* 2017). In the Spanish agriculture is also interesting to see the increase of investment in technological innovation compared to other sectors (INE 2018). In the future, this interest is expected to spread among producers, but new methodologies have to be provided.

Correspondence to: DR. S. VÉLEZ, Instituto Tecnológico Agrario de Castilla y León, Unidad de Cultivos Leñosos y Hortícolas, 47002 Valladolid, Spain. E-mail: velmarse@itacyl.es

© The author(s).



This is an Open Access article distributed under the terms of the Creative Commons Attribution Share-Alike License (<http://creativecommons.org/licenses/by-sa/4.0/>).

The images for the calculation of Vegetation Indexes can be obtained from various sources, such as UAV, aircraft, satellites, proximal sensing, etc. Each one has its advantages and disadvantages. In this way, the use of UAV combined with high-resolution images has proven its usefulness due to the ability to obtain great spatial precision; however, there are certain characteristics that difficult its use, such as the lack of standard procedures to estimate vegetation indexes (CANDIAGO *et al.* 2015). Although the satellite images have lower resolution, they have certain advantages versus other sources: on the one hand, the satellite images have a certain periodicity that does not depend on the user intervention. This periodicity depends on the revisit time of the satellite and the number of satellites in the constellation. On the other hand, the satellite is dependent on cloud level, as well as UAV, but is not restricted or adversely influenced by other weather factors that affect negatively to UAV operations such as the wind (NEX *et al.* 2014). In addition, if the farm is large or the study area is a large expanse, the satellite imagery is the best choice because it is a low-cost method compared to UAVs and ground-based robotic vehicles (KRISHNA 2016). Another advantage is that a large image of the entire area is obtained at the same time. More specifically, the Sentinel-2 satellites have a resolution of 10 m in the red and near-infrared bands that could be enough to monitor a vineyard, especially if we consider that we have a temporal resolution of 10 d and even of 5 d from 7/3/2017. Since then, the Sentinel-2 constellation consists of two satellites. In addition, the images are free of charge and freely accessible (ESA 2015), so if its usefulness is proved, it could be a good tool for producers, especially for those who cannot afford to pay large fees or invest in major technological developments.

In addition to the above, it should be considered that the use of UAVs or aircraft implies an initial investment, as well as having qualified personnel capable of configuring and piloting these devices and performing subsequent processing of the data obtained (GRENZDÖRFFER *et al.* 2008). However, satellite imagery providers, whether free or not, provide a ready-to-work image. All of this increases the costs of some technologies over others and even a threshold value has been established: 5 hectares. A breakpoint is placed slightly above 5 ha, meaning that above such scale size the image taken by satellite may be more convenient (MATESE *et al.* 2015).

In any case, these technologies are complementary and their combination can help in the decision-making process (MAES *et al.* 2018), so a greater use of satellite images, either individually or combined with images from other sources, will lead to a greater understanding of the vineyard and the possibility of using new technologies to monitor its parameters.

The objective of this study was to assess whether the multispectral information obtained from the satellites of the Sentinel-2 constellation were sufficient to classify three commercial vineyards already implanted and in full production, belonging to the same winemaking group and located in the same area (but separated as far as 3.5 km) and to verify whether it was possible to establish a classification based on NDVI, as well as to study their relationship with agronomic and maturity parameters. For this purpose, the NDVI was calculated to assess if it is a reliable index to es-

timate the vigour, defined as Pruning Wood Weight (PWW). Its relationship with the parameters in the field was studied, in order to verify its validity in the vineyard and provide winegrowers and winemakers with a decision-making tool that does not require a large amount of data, as well as being free, reliable and fast.

Material and Methods

The experiments were carried out in 2016, in A.O. Rueda, in three commercial vineyards ('Verdejo', the most widely grown cultivar in A.O. Rueda, Spain).

The annual precipitation measured at the Tordesillas weather station (Valladolid) in 2016 was 466 mm. The accumulated precipitation between 1/4/2016 and 26/9/2016 was 142 mm. The vines are trained in vertical trellis and the pruning system is Guyot. Similar handling was carried out in all the vineyards (tillage, herbicides, etc.) to ensure healthy grapevines and weed-free soil, according to the A.O. Rueda protocol and legislation in force. Main phenological stages were (BAGGIOLINI 1952): leaves unfolded, E (5/3), flowering, I (18/6) and veraison, M (10/8). The harvest dates were 27/9/2016 and 3/10/2016. The harvest was made according to the level of SSC (Soluble Solids Content). The characteristics of the vineyards as well as types of soil (NAFRÍA *et al.* 2013) are described in Tab. 1. The vineyards are located at a similar altitude between 713 and 755 m.a.s.l. and at less than 3.5 km between them.

Satellite imagery: To perform the classification between vineyards, three levels of vigour were established based on the NDVI values calculated from the multispectral images. Free 2016 images were downloaded from the ESA's (European Space Agency) Copernicus project website. These images, obtained from the Sentinel-2A satellite, were corrected to a level-2A product with ESA's sen2cor algorithm and were filtered manually in order to obtain cloud-free products. As a Result, eleven images were assessed, evaluating each vineyard separately (Fig. 1). A level of vigour was assigned to each vineyard according to the NDVI mean values of its pixels (high, medium and low, Fig. 2). The image taken on 5/8/16 was chosen because the image was in the range of maximum mean NDVI values,




Fig. 1: Cloud-free NDVI 2016 images. High vigour vineyard.

Table 1

Characteristics of the vineyards

Vigour	Coordinates (ETRS89 UTM30N)	Type of soil (FAO, WRB)	Planting date
Low	X: 340584.8 Y: 4590813.9	Haplic Luvisol + Gleyic Luvisol	1984
Medium	X: 340858.98 Y: 4589683.83	Chromic Luvisol + Chromic Cambisol	1985
High	X: 339966.84 Y: 4593182.75	Albic Arenosol + Cambic Arenosol	2008
Vigour	Area (ha)	Orientation	row x vine spacing (m)
Low	2.14	N-S	3x3
Medium	2.25	E-W	3x3
High	25.85	NE-SW	3x1.5




Fig. 2: NDVI evolution and standard deviation (NDVI, sd) of each vineyard. High, medium and low vigour (top to bottom).

and the standard deviation (NDVI sd) was the lower in that range (Fig. 2). In addition, this image is very close to veraison, which was on 10/8/16, and others authors also found that at this phenological stage the NDVI correlates better with several parameters of the vineyard (LAMB *et al.* 2004, TAGARAKIS *et al.* 2013). It might be worth noting that there are higher NDVI values after the harvest, probably due to a lack of soil tillage and the effect of harvesting (the vegetation spread out of the vertical trellis).

The NDVI (Normalized Difference Vegetation Index) is an index that allows quantifying the amount of vegetation of an area, as well as its health. It relates the reflected radiation in the red and Near Infrared (NIR) bands of the electromagnetic spectrum. Its mathematical equation is the following:

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)}$$

The equation adapted from the bands provided by Sentinel-2 satellites is the following:

$$NDVI = \frac{(B8 - B4)}{(B8 + B4)}$$

In the last step, the image was processed using an unsupervised classification clustering method (k-means), organizing each vineyard in a level of vigour (Fig. 3). The vineyards were associated with Low Vigour (LV), Medium Vigour (MV) and High Vigour (HV) (Fig. 3). Within each vineyard, 40 vines spread across four different blocks (10 vines per block) were tagged for assessment. For processing, QGIS software version 2.18.13 and R version 3.5.3 were used.

Wine elaboration: Three types of wine were elaborated, one from each vigour, in stainless steel tanks of 35 L. The winemaking system was traditional of white wine: grapes receipt, crushed and de-stem, sulfiting by 5 g per hl, pressing and introducing in refrigeration camera for decantation. After two days, firstly the racking was carried out and secondly the sowing of yeasts *Saccharomyces cerevisiae* (ex rf. Bayanus) SB (EnartisFerm) at 16 °C for




Fig. 3: NDVI classification between vineyards. 3 vigour levels: low, medium and high (top to bottom).

fermentation. Nutrients were added to the sowing and the addition was repeated at densities of 1070 and 1020 g·L⁻¹. At the end of the fermentation, a sulfitation was made and the temperature was reduced to 5 °C. Finally, the wine was decanted and kept at 6 °C until bottling.

Tasting: After the wine elaboration, a consumer judging panel was established, submitting the judges to a triangular test in order to establish if the consumer was able to detect the difference between vigours, understanding that a positive result in the test implies that the differences between vigours are perceptible enough. The tests were carried out in a tasting room equipped with ten individual boxes, according to ISO 8589: 2007 and in compliance with ISO 4120: 2004 for the triangular test. To facilitate the development of the test and the decision of the consumer, two levels of vigour were chosen for comparison.

Results

Vegetative development and production: The data have been averaged per unit area in order to compare the different vineyards, since the planting density

of each vineyard was different. The use of Sentinel-2 satellite images implies that the real values of NDVI are not values of specific vines, but they include both crop, spontaneous flora and soil. Therefore, it is an indicator of vigour per unit area, that is, the vigour based on the 100 m², which is the size of the pixel.

Although the heterogeneity of the vineyards was high (they are arranged with different orientations, planting density, soils, etc.) the used methodology for calculation of NDVI levels has been able to correctly discriminate the vigour of the vineyards, defined as Pruning Wood Weight (PWW): high, medium and low NDVI values were 2438, 1895 and 1487 kg·ha⁻¹ respectively (PWW·ha⁻¹, Tab. 2). Thus, in the vineyards in which the NDVI values have been higher, the vigour has been higher, in contrast to the vineyards with lower NDVI values in which the vigour has been lower. Likewise, the high, medium and low-level values were 15984, 12990 and 10576 kg·ha⁻¹, respectively, with significant differences between levels ("Y", Tab. 2), so the NDVI has been a good indicator to estimate the yield because the higher the NDVI level, the higher the yield. These results are consistent with other author's results (ACEVEDO-OPAZO *et al.* 2008, SANTESTEBAN *et al.* 2009).

Table 2

Yield and vegetative development parameters. X·/ha, X/m², PWW, Pruning Wood Weight (kg·vine⁻¹); N °S, Number of Shoots per Vine; SW, Shoot Weight (g); RI, Ravaz Index; N °C, Number of Clusters/vine; GY, Grape Yield (kg·vine⁻¹); Y, Yield (kg·ha⁻¹); CW, Cluster Weight (g), BW, Berry Weight (g). Average per vigour. Levels of statistical significance (Sig.): ns, non-significant; *, $p < 0.05$; **, $p < 0.01$. Data with different letters indicate significant differences according to the LSD test

Vig.	PWW	PWW·ha ⁻¹	N °S	N °S/m ²
L	1.34 b	1487 c	32.1 a	3.57 b
M	1.71 a	1895 b	34.6 a	3.84 b
H	1.10 b	2438 a	23.9 b	5.32 a
Sig.	**	**	**	**
Vig.	SW	SW/m ²	RI	N °C
L	41.7	4.64 b	7.02	85.7 a
M	49.2	5.47 b	7.25	62.3 b
H	46.2	10.28 a	7.74	42.0 c
Sig.	ns	**	ns	**
Vig.	N °C/m ²	GY	Y	CW
L	9.53 a	9.52 b	10576 c	114 b
M	6.93 b	11.69 a	12990 b	189 a
H	9.34 a	7.19 c	15984 a	170 a
Sig.	**	**	**	**
Vig.	CW/m ²	BW	BW/m ²	
L	12.7 c	1.25 b	0.14 c	
M	21.0 b	1.81 a	0.20 b	
H	37.8 a	2.02 a	0.45 a	
Sig.	**	**	**	

Significant differences ($p < 0.01$) were also found in the rest of the evaluated agronomic parameters, except in the I. Ravaz, which indicates that the increase in the vegetative development was proportional to the yield, without implying an imbalance in the vineyard.

Maturity parameters: The harvest time for each vineyard was established based on the accumulation of SSC (23 °Brix). Therefore, there are no significant differences in SSC or in sugars. However, there is one week difference between the harvest dates. The low vigour vineyard reached the SSC level in 27/9/2016, while the medium

of the vineyards was made with the least possible amount of data in order to reduce costs and facilitate farmer's work. Therefore, although the vigour influences the final composition of the musts, the texture of the soil, as well as its chemical composition, is very important for the final qualitative composition of the grape (HIDALGO 2006).

Tasting: In order to facilitate the choice in the triangular test carried out by the consumer judging panel, two samples of wine were selected: high and low vigour, because the results of the production and maturity parameters were statistically significant and were the most distant from each other (Tabs 2 and 3).

The triangular test was carried out by 26 judges. Be-

Table 3

Maturity parameters. SSC, Soluble Solids Content (°Brix); Sugar (g·L⁻¹); pH; TA, Total Acidity (g of tartaric·L⁻¹); Mal. A, Malic Acid (g·L⁻¹); Tar. A, Tartaric Acid (g·L⁻¹); K, Potassium (ppm). Average per vigour. Levels of statistical significance (Sig.): ns, non-significant; *, $p < 0.05$; **, $p < 0.01$. Data with different letters indicate significant differences according to the LSD test

Vig.	SSC	Sugar	pH	TA
L	22.6	222	3.26 c	6.04 a
M	23.1	228	3.47 b	5.35 b
H	22.8	224	3.60 a	4.80 c
Sig.	ns	ns	**	**
Vig.	Mal. A.	Tar. A.	K	
L	0.42 b	9.05 a	1640 b	
M	1.51 a	8.25 b	2088 a	
H	1.45 a	7.50 c	2090 a	
Sig.	**	**	**	

and high vigour vineyards reached it in 3/10/2016. In terms of maturity, significant differences were also found with $p < 0.01$ in all the parameters evaluated (Tab. 3), except for SSC and sugars since this parameter was used as an indicator of the harvest time.

The highest values of total acidity (6.04 g·L⁻¹) and tartaric acid (9.05 g·L⁻¹) have been obtained in low vigour, as well as the lowest values of pH (3.26), malic acid (0.42 g·L⁻¹) and potassium (1640 ppm). The observed maturity parameters for medium vigour level were between the other two levels. Regarding malic acid levels, its differences (from 0.42 to 1.51 g·L⁻¹) may have occurred due to multiple factors, such as higher vegetative development, which usually implies greater shading of the cluster. This situation leads to a lower respiration rate and lower malic acid combustion (HIDALGO 2006). Other authors have also found a relationship between NDVI and certain maturity parameters (MARTINEZ-CASASNOVAS *et al.* 2012), although agronomic parameters and NDVI are generally much more related than maturity parameters (SANTESTEBAN *et al.* 2014).

Additionally, the planting density affects both the grape production and its quality. In addition, the huge heterogeneity among the vineyards should be considered (different planting density, soils, etc.). In this work, the classification

Table 4

Tasting. Triangle test. Levels of statistical significance (Sig.): ns, non-significant; *, $p < 0.05$; **, $p < 0.01$; ***, $p < 0.001$. Binomial distribution. ISO 4120:2004

Judges	Success	Sig.
26	23	***

tween them, 23 were able to discern which sample was different, therefore based on a binomial distribution it is observed that the difference between treatments was significant with $p < 0.001$ (Tab. 4).

Conclusions

The use of Sentinel-2 satellite images versus other sources were useful, because one single image covered all the vineyards at the same time, in the same atmospheric conditions (the vineyards were separated up to 3.5 km). Additionally, this procedure involves no costs (free images) and offers the possibility of consulting the images archive.

In this work, production and quality capacities have been classified 53 d before harvesting and based on a small amount of data: the satellite image. The vineyards have been classified based on NDVI: the greater the NDVI, the greater the PWW·ha⁻¹, and therefore the greater the vigour. The increase in vigour has also implied an increase in the other agronomic parameters evaluated, including the yield. It might be worth noting that in order to use this technique, proper vineyard management must be carried out (tillage, herbicides, etc.) to ensure a healthy vine crop and weed-free soil.

Regarding the tasting and maturity parameters, significant differences have also been found, although the relationship of these parameters with the NDVI is complex, since the process of grape maturation is a process in which a multitude of factors are involved and the NDVI is an index derived from the information obtained from the external surface of the crop, i.e. the canopy in its majority. For this reason, it would be desirable to incorporate additional information taken on the field to combine with the NDVI values. In this way, it is possible that more accurate results could be obtained. This observation has also been made by other authors (BORGOGNO-MONDINO *et al.* 2017).

In conclusion, the NDVI and the applied methodology have been good tools for the estimation of the vigour levels in veraison, classifying the vineyards successfully according to the vigour, estimating three different levels of pruning weight and grape production. In any case, further research is needed to verify the reliability of this technique, including research into the correlation between soil types and vineyard.

Acknowledgements

This work has been possible thanks to the financial support of Junta de Castilla y León, FEDER funds, INIA RTA2014-007-C02, FPI-INIA2016-017 project and Bodega CuatroRayas.

References

- ACEVEDO-OPAZO, C.; TISSEYRE, B.; GUILLAUME, S.; OJEDA, H.; 2008: The potential of high spatial resolution information to define within-vineyard zones related to vine water status. *Precis. Agric.* **9**, 285-302.
- ANASTASIOU, E.; BALAFOUTIS, A.; DARRA, N.; PSIROUKIS, V.; BINIARI, A.; XANTHOPOULOS, G.; FOUNTAS, S.; 2018: Satellite and proximal sensing to estimate the yield and quality of table grapes. *Agriculture* **8**, 94.
- BAGGIOLINI, M.; 1952: Les stades repères dans le développement annuel de la vigne et leur utilisation pratique. *Rev. Romande Agric. Vitic. Arboric.* **8**, 4-6.
- BORGOGNO-MONDINO, E.; LESSIO, A.; TARRICONE, L.; NOVELLO, V.; DE PALMA, L.; 2017: A comparison between multispectral aerial and satellite imagery in precision viticulture. *Precis. Agric.* **19**, 195-217.
- CANDIAGO, S.; REMONDINO, F.; DE GIGLIO, M.; DUBBINI, M.; GATELLI, M.; 2015: Evaluating multispectral images and vegetation indices for precision farming applications from UAV images. *Remote Sens.* **7**, 4026-4047.
- CARUSO, G.; TOZZINI, L.; RALLO, G.; PRIMICERIO, J.; MORIONDO, M.; PALAI, G.; GUCCI, R.; 2017: Estimating biophysical and geometrical parameters of grapevine canopies ('Sangiovese') by an unmanned aerial vehicle (UAV) and VIS-NIR cameras. *Vitis* **56**, 63-70.
- ESA (EUROPEAN SPACE AGENCY); 2015: SENTINEL-2 UserHandbook, 2015. ESA Standard Document.
- FERNÁNDEZ M. V.; PEÑA I.; SÁNCHEZ DE PABLO, J. D.; 2011: Factors of competitiveness in the wine industry: an analysis of innovation strategy. *Int. J. Soc. Behav. Edu. Econ. Busin. Indust. Engin.* **5**, Art. 6.
- GRENZDÖRFFER, G. J.; ENGEL, A.; TEICHERT, B.; 2008: The photogrammetric potential of low-cost UAVs in forestry and agriculture. *Int. Arch. Photogramm. Remote Sens. Spatial Inform. Sci. Vol. XXXVII. Part B1*.
- HIDALGO, J.; 2006: *La Calidad del Vino desde el Viñedo*. Ediciones Mundi-Prensa.
- INE (INSTITUTO NACIONAL DE ESTADÍSTICA); 2018: *España en Cifras 2018*.
- JOHNSON, L. F.; 2003: Temporal stability of an NDVI-LAI relationship in a Napa Valley vineyard. *Aust. J. Grape Wine Res.* **9**, 96-01.
- KRISHNA, K. R.; 2016: *Push Button Agriculture: Robotics, Drones, Satellite-Guided Soil and Crop Management*. Apple Academic Press, Inc. CRC Press, Taylor & Francis Group.
- JOHNSON, L. F.; BOSCH, D. F.; WILLIAMS, D. C.; LOBITZ, B. M.; 2001: Remote Sensing of vineyard management zones: implications for wine quality. *Appl. Engin. Agric.* **17**, 557-560.
- LAMB, D. W.; WEEDON, M. M.; BRAMLEY, R. G. V.; 2004: Using remote sensing to predict grape phenolics and colour at harvest in a Cabernet Sauvignon vineyard: Timing observations against vine phenology and optimising image resolution. *Aust. J. Grape Wine Res.* **10**, 46-54.
- MAES, W. H.; STEPPE, K.; 2018: Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. *Trends Plant Sci.* **24**, 152-164.
- MARTÍNEZ-CASASNOVAS, J. A.; AGELET-FERNÁNDEZ, J.; ARNO, J.; RAMOS, M. C.; 2012: Analysis of vineyard differential management zones and relation to vine development, grape maturity and quality. *Spanish J. Agric. Res.* **10**, 326-337.
- MATESE, A.; TOSCANO, P.; DI GENNARO, S.; GENESIO, L.; VACCARI, F.; PRIMICERIO, J.; BELLI, C.; ZALDEI, A.; BIANCONI, R.; GIOLI, B.; 2015: Inter-comparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture. *Remote Sens.* **7**, 2971-2990.
- NAFRÍA, D. A.; GARRIDO, N.; ÁLVAREZ, M. V.; CUBERO, D.; FERNÁNDEZ, M.; VILLARINO, I.; GUTIÉRREZ, A.; ABIA, I.; 2013: *Atlas Agroclimático de Castilla y León*. NIPO 281-13-008-5.
- NEX, F.; REMONDINO, F.; 2014: UAV for 3D mapping applications: a review. *Appl. Geomat.* **6**, 1-15.
- OECD/FAO; 2018: *OECD-FAO Agricultural Outlook 2018-2027*. OECD Publ., Paris/Food and Agriculture: Org. UN, Rome.
- OIV; 2017: *State of the Vitiviniculture World Market*. O. I. V. (Off. Int. Organ. Vine Wine), Paris, France.
- OIV; 2012: *Vine and Wine Outlook*. O I V (Off. Int. Vine Wine), Paris, France.
- SANTESTEBAN, L. G.; MIRANDA, C.; FUENTEMILLA, M.; TISSEYRE, B.; GUILLAUME, S.; ROYO, J. B.; 2009: Evaluación del interés del índice NDVI para la delimitación de Unidades de Manejo Diferenciado dentro de una explotación vitícola, 93-96. In: *Teledetección: agua y desarrollo sostenible*. XIII Congr. Asoc. Española Teledetección, 23-26 Sept. 2009. Calatayud, Spain.
- SANTESTEBAN, L. G.; URRETAVIZCAYA, I.; MIRANDA, C.; ROYO, J. B.; 2014: Delineación de unidades de manejo diferenciado (UMD) del viñedo e interpretación desde un punto de vista enológico. *Rev. Enol.* **144**.
- SANTESTEBAN, L. G.; 2019: Precision viticulture and advanced analytics. A short review. *Food Chem.* **279**, 58-62.
- TAGARAKIS, A.; LIAKOS, V.; FOUNTAS, S.; KOUNDOURAS, S.; GEMTOS, T. A.; 2013: Management zones delineation using fuzzy clustering techniques in grapevines. *Precis. Agric.* **14**, 18-39.
- TROUT, T. J.; JOHNSON, L. F.; GARTUNG, J.; 2008: Remote sensing of canopy cover in horticultural crops. *HortScience* **43**, 333-337.
- VIVAS, C.; SOUSA, A.; 2013: *La Globalización en el Sector del Vino: Nuevo Mundo, Viejo Mundo y Portugal*. XXVII AEDEM Annu. Meeting. Huelva, Spain.

Received September 12, 2019



CAPÍTULO II

CAPÍTULO II. Effect of Missing Vines on Total Leaf Area Determined by NDVI Calculated from Sentinel Satellite Data: Progressive Vine Removal Experiments”.



applied sciences

"Effect of Missing Vines on Total Leaf Area Determined by NDVI Calculated from Sentinel Satellite Data: Progressive Vine Removal Experiments". Vélez, S.; Barajas, E.;

Rubio, J.A.; Vacas, R.; Poblete-Echeverría, C. (2020). *Applied Sciences*, 10, 3612.

doi: <https://doi.org/10.3390/app10103612>.

Technical Note

Effect of Missing Vines on Total Leaf Area Determined by NDVI Calculated from Sentinel Satellite Data: Progressive Vine Removal Experiments

Sergio Vélez ^{1,*} , Enrique Barajas ¹, José Antonio Rubio ¹, Rubén Vacas ¹
and Carlos Poblete-Echeverría ^{2,*} 

¹ Instituto Tecnológico Agrario de Castilla y León (ITACyL), Unidad de Cultivos Leñosos y Hortícolas, 47071 Valladolid, Spain; bartolen@itacyl.es (E.B.); rubcanjo@itacyl.es (J.A.R.); ita-vacizqru@itacyl.es (R.V.)

² Department of Viticulture and Oenology, Faculty of AgriSciences, Stellenbosch University, Private Bag X1, Matieland 7602, South Africa

* Correspondence: velmarse@itacyl.es (S.V.); cpe@sun.ac.za (C.P.-E.)

Received: 24 April 2020; Accepted: 19 May 2020; Published: 23 May 2020



Featured Application: Sentinel-2 images were sensitive to change in the vegetation contained in the pixel. The reduction in the NDVI values was proportional to the reduction in the vegetation, following a linear relationship. The quantitative relationship obtained in this study is valuable since a vineyard, once established, generally loses grapevines each year due to diseases, abiotic stress, etc., so it is important to consider the effect of the missing vines in order to have a correct estimation of the vineyard vigour.

Abstract: Remote Sensing (RS) allows the estimation of some important vineyard parameters. There are several platforms for obtaining RS information. In this context, Sentinel satellites are a valuable tool for RS since they provide free and regular images of the earth's surface. However, several problems regarding the low-resolution of the imagery arise when using this technology, such as handling mixed pixels that include vegetation, soil and shadows. Under this condition, the Normalized Difference Vegetation Index (NDVI) value in a particular pixel is an indicator of the amount of vegetation (canopy area) rather than the NDVI from the canopy (as a vigour expression), but its reliability varies depending on several factors, such as the presence of mixed pixels or the effect of missing vines (a vineyard, once established, generally loses grapevines each year due to diseases, abiotic stress, etc.). In this study, a vine removal simulation (greenhouse experiment) and an actual vine removal (field experiment) were carried out. In the field experiment, the position of the Sentinel-2 pixels was marked using high-precision GPS. Controlled removal of vines from a block of cv. Cabernet Sauvignon was done in four steps. The removal of the vines was done during the summer of 2019, matching with the start of the maximum vegetative growth. The Total Leaf Area (TLA) of each pixel was calculated using destructive field measurements. The operations were planned to have two satellite images available between each removal step. As a result, a strong linear relationship ($R^2 = 0.986$ and $R^2 = 0.72$) was obtained between the TLA and NDVI reductions, which quantitatively indicates the effect of the missing vines on the NDVI values.

Keywords: total leaf area; mixed pixels; Cabernet Sauvignon; NDVI; Normalized Difference Vegetation Index; precision viticulture

1. Introduction

Remote sensing (RS) is a tool that allows information on distant objects to be obtained quickly and accurately [1]. A practical way to use remote sensing in viticulture is by using vegetation indices (VIs)

and its potential relies on their ability to estimate grape quality and yield using spectral information [2]. The VIs are algebraic combinations designed to highlight the contrast of plant vigour and its properties (e.g., canopy biomass, absorbed radiation, chlorophyll content). These indices are based on the fact that healthy plants show a high Near-Infrared (NIR) reflectance and very low red reflectance [3,4]. The Normalized Difference Vegetation Index (NDVI) [5] has proved to be a useful indicator of the status of the vineyard with several applications, such as for sub-block management [6–12] and estimating the leaf area index, (LAI and can correlate with certain parameters such as total anthocyanins, total phenols, soil moisture, clay and sand content, berry pH, soluble solids, vine size and yield components [13–15]. NDVI has also been useful for establishing a correlation between Photosynthetically Active Biomass (PAB) and total phenolics and colour [16], assessing the water status spatial variability within the vineyard [17] and monitoring quality characteristics in table grapes [18]. Furthermore, within-field NDVI patterns are quite stable between seasons [19].

In RS, a key parameter to choose is the platform on which the sensor is mounted. At present, unmanned aerial vehicle (UAV) platforms have been extensively used for studying and exploring vineyards [20–25]. In general, UAV offers the possibility to obtain high-resolution multispectral imagery, however, the benefit of the high resolution is restricted by some UAV limitations, such as stability on windy days/areas, as well as piloting capabilities and global navigation satellite system/inertial navigation system (GNSS/INA) quality [26,27]. Also, regulations established in most countries might be a problem for properly developing the capabilities of UAVs [28]. Another issue is the cost of each operation, and above a certain scale size, an image taken by satellite may be more convenient than others [29]. In this context, satellites can be used for several applications, for example, mapping vineyard plant and soil water status [30], harvest prediction [31] and to analyse the spatial heterogeneity in the evapotranspiration [32]. Modern image satellite analysis allows the combining of information from different sensors mounted on different satellites in order to improve spatial resolution [33,34], even in the presence of clouds [35], although it should be noted that not all sensors provide the same information. There are several satellites which are used to obtain spatial information and they can be divided into two main groups depending on the cost of the images: free-to-use satellites and paid satellites. Regarding free-to-use satellites, Landsat and Sentinel satellites can be very useful and they have been used for applications as disparate as detecting motions before a landslide [36], ice flow measurements and the quantification of seasonal ice velocities [37], to assess the bloom dynamics of almond orchards [38] and to classify vineyards according to their vigour [39,40]. Some authors [41] have discussed the differences in the information collected from the Sentinel-2A MSI sensor and the Landsat-8 OLI sensor. They found that the MSI surface reflectance was greater than the OLI surface reflectance in almost all bands and that the MSI surface NDVI was greater than the OLI surface NDVI. In this sense, Sentinel-2 satellites (Copernicus Project of the European Space Agency) can be particularly useful due to their free status and the relative ease of access to their web platform (<https://scihub.copernicus.eu/>). In addition, Sentinel-2 imagery has a spatial resolution of 10 m on the pixel side and a temporal resolution of 10 days; 5 days if we combine the images from the two existing satellites currently in the constellation. Sentinel-2 provides multiple bands from which to obtain information, including the Near-Infrared (NIR) and the Red, which allow the calculation of the NDVI [42].

Remotely sensed images can be classified into two groups [43] according to their spatial resolution: (i) low-spatial-resolution imagery, in which the majority of pixels contain reflectance information from the grapevines and the inter-row space, and (ii) high-spatial-resolution imagery, in which the majority of pixels contain information only from grapevines or only from inter-row space. Therefore, when using low-resolution imagery, the NDVI value of the pixel is an indicator of the amount of vegetation (canopy area) rather than the NDVI from the canopy of the vines (pure value without the influence of the background). In this context, the main limitation of Sentinel-2 is that the spatial resolution and within-block information could not be accurate in the case of small blocks or blocks with complex borders [44]. This is a widespread problem in satellite imagery because within a vineyard

pixel there are plants, soil and shadows, which influence the correct calculation of the coefficients of the crop [45]. More precisely, the NDVI obtained by the satellite and the LAI measured with a photographic ground-truth method can be related [46] and the images from the Worldview-2 satellite, with a resolution of 0.5 to 2 m², can be used to indicate that the amount of vegetation contained in a pixel varies according to its size. Therefore, with 0.5 m² it will be possible to find pixels with 100% vegetation, however, with 2m² there will only be mixed pixels of vegetation and soil. Instead of Worldview-2, Sentinel-2 can be used, but this will lead to a much greater problem, since, instead of a 2m² resolution, Sentinel-2 will have a resolution of 100m², so all the pixels will be mixed and will contain several plants as well as soil and shadows. It is important to note that soils have a great influence on the calculation of the NDVI [47] and that the average NDVI values for vines can be up to 3 times larger than the average NDVI values for pure soil [48]. Some authors [49] have established that pixels with an NDVI lower than 0.6 should be removed because they are not vegetation. Shadows are mainly influenced by the distance between plants and rows, but also by the characteristics of the plants [50]. Thus, in the same lighting, more vegetation will imply more shadow, an important factor since shaded pixels have low reflectance and modify the values we would expect if there were only vegetation and soil. Several authors have tried to solve this problem, trying to correct the shading in UAV and satellite images [51–55]. Additionally, NDVI can be greatly influenced by viticulture practices (e.g., canopy management and irrigation), so these practices should be considered [56].

Considering the inherent mixed-pixel characteristic of Sentinel-2 imagery in vineyards and the effect of missing vines (a vineyard, once established, generally loses grapevines each year due to diseases, abiotic stress, etc.), the objective of the present study was to analyse the effect of missing vines on mixed pixels using the NDVI as a reference index ($NDVI = (NIR - Red)/(NIR + Red)$). Our approach was to work with real measurements of vegetation reductions at pixel level evaluated by Sentinel-2 satellites, in order to understand the relationship between the vegetation contained in a pixel and the information captured by the satellite. To this end, two related experiments were performed: (i) a simulation under control conditions (greenhouse experiment) and (ii) a field experiment implementing a progressive vine removal protocol in four steps to check the sensitivity of the satellite images to the loss of vegetative mass within the study area.

2. Materials and Methods

2.1. Greenhouse Experiment

To test the concept of the NDVI reduction, a vine removal simulation was done under control conditions in a greenhouse using pot-grown cv. Cabernet Sauvignon grapevines (Department of Viticulture and Oenology, Stellenbosch University, South Africa). In order to carry out the progressive removal simulation, 12 one-year-old vines were selected and maintained in a greenhouse under natural light at 26 °C and 65% humidity.

The vines were located in two rows to simulate a Vertical Shoot Positioned (VSP) trellis system with a distance between rows of 55 cm and a distance between vines of 27.5 cm. Three random vines were removed each time until all vines in the simulated pixel area were removed.

A multispectral camera (Sequoia, Parrot SA, Paris, France) was used to capture images in each step of the removal simulation. The Sequoia camera has four 1.2-megapixel monochrome sensors which collect global shutter imagery along four discrete spectral bands: Green (550 nm), Red (660 nm), Red-Edge (735 nm) and Near-Infrared (NIR) (790 nm); a standard RGB camera and a sunshine sensor that continuously captures the light conditions in the same spectral bands as the multispectral sensor. The pipeline of the image analysis is shown in Figure 1. Since the satellite images are mixed pixels, a single pixel was simulated to encompass both the soil and plants.




Figure 1. Pipeline of (a) greenhouse image analysis (b) field experiment image analysis. NDVI: Normalized Difference Vegetation Index. TLA: Total Leaf Area.

2.2. Field Experiment

Subsequently, a large-scale field experiment was carried out on a vineyard (cv. Cabernet Sauvignon), located in Zamadueñas Estate (coordinates: 41.7013° N, 4.7088° W, Valladolid, Spain), belonging to the Agricultural Technology Institute of Castilla y León (ITACyL). The vineyard was trellis-trained, with a bilateral Royat cordon pruning system, with eight spurs per plant and two buds per thumb, with 2.2×1.2 m row and plant-spacing, respectively, and NE-SO orientation. The soil was kept free of weeds and any other element that could affect the NDVI [56]. The vineyard was not irrigated, although in previous years it had been irrigated. The accumulated rainfall from 1 January to 31 July 2019 was 133.12 mm.

During the months of June and July 2019, a progressive vine removal experiment was developed in four phases (Figure 2). Three Sentinel-2 pixels (10×10 m) were selected within the vineyard, with 38 grapevines inside each pixel. In each phase, a quarter of the vegetative mass of each pixel was eliminated and the last to be removed equated to the elimination of the remnant vegetation. Each grapevine was cut in the lower-middle part of the trunk (Figure 3a,b) and all the material was extracted from the vineyard. A GPS Triumph-2 JAVAD GNSS model with centimetre accuracy was used to mark the pixels in the field to ensure that the grapevines within the studied area (Figure 3c) were removed. The GPS TRIUMPH-2 (JAVAD GNSS INC, San Jose, CA, USA) has 216 channels of dual-frequency GPS and GLONASS and can connect via Bluetooth and WiFi to a mobile phone to access the local GNSS Reference Station Network. A work schedule was established in order to obtain two Sentinel-2 images between each removal, one for each satellite.




Figure 2. Schematic representation of the four-step vine removal implemented in the field experiment.

The dates of the removal of the vines were 28 June, 8 July, 19 July and 29 July 2019. The experiment was carried out at this specific time due to the proximity of veraison, since at this phenological stage the relationship between leaf area and NDVI is greater [41]. To calculate the Total Leaf Area (TLA), the area of each leaf of the removed plants was measured in the laboratory (Figure 3d) using Easy Leaf Area application [57]. Easy Leaf Area measures leaf area non-destructively, calculated automatically from green leaf and red scale areas. This procedure was performed each time the vines were removed.

Regarding the spatial information, free-cloud atmospherically corrected images were downloaded (between 11 June 2019 and 20 August 2019) from the European Space Agency (ESA) Copernicus Project website. NDVI was calculated for each step using a customized code in R v.3.6.2. (Figure 1b) from the Sentinel-2 satellite images corresponding to the T30TUM tile. Sentinel 2A and 2B were used in combination to minimize variations in sensors, satellite orbit, pixel misregistration, clouds and radiometry. Images corresponding to the two satellites were downloaded and the values of the available free-cloud images were averaged between each vine removal.

All image and data analyses were carried out using customized codes written in an R statistical program (version 3.6X, R Foundation for Statistical Computing (R Core Team 2019), <https://www.R-project.org/>, Vienna, Austria) and MATLAB (Version R2019b, The MathWorks Inc., <http://www.mathworks.com>, Natick, MA, USA). A *t*-test for independent samples was performed in R for the statistical comparison of each removal step.



Figure 3. (a) Removal of the vines; (b) Detail of the removed vines; (c) Marked pixels in the vineyard and (d) Example of the leaf area measurements using the Easy Leaf Area application.

3. Results

3.1. Greenhouse Experiment

The greenhouse simulation (Figure 4) showed a clear relationship ($R^2 = 0.986$) between the reduction of NDVI and TLA. The NDVI values are the simulated mixed pixel values. When the vines were removed from the simulated mixed pixel (around 2 m^2), the NDVI values decreased linearly until reaching the base soil values (defined in this case as $\text{NDVI} = 0.20$). The slope of the linear equation is 0.3 ($y = 0.3x$), so for each 20% of reduction in the TLA, the reduction in NDVI is around 6%.




Figure 4. (a) Example of the mask used to isolate the vines; (b) The relationship between them. Normalized Difference Vegetation Index (NDVI) reduction (%) and Total Leaf Area (TLA) reduction (%) as pixel-based.

3.2. Field Experiment

A reduction in the NDVI value is observed after each vine removal until it reaches the base soil values (NDVI values between 0.17 to 0.19), except in pixel 1 (Figure 5). The starting NDVI values, which correspond to the maximum vine cover, were 0.251, 0.321 and 0.306, for pixels 1, 2 and 3, respectively. In Figure 6a all values from all of the pixels from the dataset were used and a linear relationship was found between the reduction in NDVI and TLA ($R^2 = 0.72$) with a slope of 0.32 ($y = 0.3104x$), showing that for each 20% of reduction in the TLA, the NDVI is reduced by around 7%, similar to the greenhouse experiment result. Moreover, if the dataset is disaggregated by pixel (Figure 6b), the determination coefficients are 0.92, 0.68 and 0.99 for pixels 1, 2 and 3, respectively.




Figure 5. (a) Detail of the vine removal by phase. (b) TLA (m²) and NDVI values in each pixel.




Figure 6. Relationship between NDVI (%) and TLA reduction (%) (a) in all pixels (b) per pixel.

The p -values for the comparison of each pair of removal steps are shown in Table 1. As expected, all removal steps had significant differences in TLA. However, concerning NDVI, only a few pairs of treatments had significant differences and in no case between two consecutive steps, which indicate a low sensitivity of the index to small changes in the vegetation amount.

Table 1. p -values from the t -test comparison of Normalized Difference Vegetation Index (NDVI) and total leaf area (TLA) in the field experiment.

		TLA				
		Step0	Step1	Step2	Step3	Step4
NDVI	Step0		0.018	0.003	0.001	0.001
	Step1	0.396		0.002	0.001	0.001
	Step2	0.120	0.148		0.001	0.001
	Step3	0.039	0.045	0.113		0.002
	Step4	0.013	0.011	0.005	0.079	

Grey colour denotes p -values 0.05. Diagonal values were excluded and marked in black.

4. Discussion

This study has approached the mixed pixel effect in two different ways: a laboratory approach (greenhouse) and a full-scale approach with a field experiment. Two experiments presented consistent results, showing the same pattern of NDVI reduction. The gradual reduction in NDVI showed in Figure 5b is expected because the leaf area within the pixel is reduced and NDVI is sensitive to changes in the vegetation [15]. There is an inconsistency in the pixel 1 trend, probably because the vegetation of the adjacent vines was moved and therefore the horizontal leaf area exposed to the satellite increased, although it could also be due to a variation in the reflectivity collected by the Sentinel in that specific image, since, if an analysis is performed using the image of 6/7/2019 corresponding to the Sentinel-2B satellite, an increase in NDVI can be observed in all the pixels of the tile. The influence of humidity in the soil is disregarded [58] since there was no significant rainfall in the period.

In the field experiment, initial NDVI values were between 0.25 and 0.32 with final values between 0.17 and 0.19. The starting NDVI values correspond to the maximum vine cover and indicate a different level of vigour in the selected pixels (Figure 5b). The final NDVI values correspond to bare soil and are consistent with the results of other authors [47]. It has been observed that the reduction in the NDVI value is proportional to the loss of TLA, finding that in the greenhouse experiment and the field experiment the slopes of the regression line were very similar. Therefore, if the vegetation within the pixel is reduced by 20%, the NDVI will be reduced proportionally by 6–7%. This also indicates that, considering the components of a mixed pixel [46], the vegetation and the associated shade effect 30–35%, so the remaining value is being influenced by the soil. These results are similar to the values reported by other authors [48], which indicate that the effect of the soil can be up to 3 times that of the vegetation.

If the field dataset is disaggregated per pixel, the difference between pixels is clearly observed (Figure 6b). This could be due to differences in vigour within the vineyard, since the vigour of the vineyard is related to the NDVI values [39,40]. Another important aspect to consider is the orientation of the row regarding the position of the Sentinel-2 pixels. The orientation combined with the space between rows creates an irregular grid effect. Therefore, if the orientation is not perfectly aligned with the pixel position, the number of vines per pixel is irregular. In our case, this effect was clear, with values of 38, 37 and 39 vines for the pixels 1, 2 and 3, respectively.

The trend lines presented in the results have very high R^2 values, however, these lines were just made in order to observe the trend and to highlight the relationship that has been shown, not to establish a model, since they are strongly influenced by the extreme values (0% and 100% of reduction), and it would be desirable to have a greater amount of data to develop a model. It is also important to note that there may be misregistration of pixels, which are improved regularly by updating the Processing Baseline, so in future studies the algorithm might be ameliorated, allowing more accuracy in the process [59].

Looking at the results of the *t*-test, although the TLA was significantly reduced between each removal step, the differences in the NDVI were not significant until the amount of vegetation was reduced with two removal steps. For example, there are differences between the first and the last removal, and between the second and the last, but there is no difference between the third and the fourth. This indicates that, although the NDVI is affected by the reduction of TLA, it is not overly sensitive to small reductions in the vegetation amount.

5. Conclusions

In this study, a relationship between the Total Leaf Area (TLA) and the Normalized Difference Vegetation Index (NDVI) was developed to analyse the effect of missing vines on NDVI values at pixel level (10×10 m). This study has demonstrated that it is possible to estimate quantitatively the impact that the decrease in vegetation in a vineyard has on the NDVI values. Our results show that it is possible to use the NDVI calculated from the Sentinel-2 images to identify the change in the vegetation in the pixel. Furthermore, it is worth noting that the reduction in the NDVI values is proportional to

the reduction in the vegetation, following a linear relationship. The quantitative relationship obtained in this study is valuable since a vineyard, once established, generally loses grapevines each year due to diseases, abiotic stress, etc., so it is worth analysing the effect of the missing vines in order to have a clear understanding of the vineyard vigour.

The field experiment was conducted in a vineyard with a vertical trellis and this system has become a standard in today's viticulture. Moreover, in this work, the results of the two experiments are very similar, since the greenhouse experiment simulated the same row and plant distance as the field experiment, so the results obtained in this study could be used as a reference for vineyards with similar trellis characteristics (distance between rows and vines). However, it might be worthwhile to check whether this result can be extrapolated to other trellis systems or vineyards with different canopy or soil management practices, analysing the influence of the elimination of vegetation in vineyards with different soils and different characteristics. Further research would be desirable in this direction.

In further studies, it might be interesting to explore the possibility of removing a specific area of vines within a vineyard to calibrate the entire vineyard and use this technique to calibrate the background adjustment factor (L) of vegetation indexes such as SAVI, or even develop new indexes that take into account parameters related to the canopy, such as the influence of shadows or the linear meters of vertical trellis contained in each pixel.

Although the results are clear and promising, the limitations of this study should be considered due to the complexity and effort involved in an operation of this type in a vineyard. Operations on a larger scale are desirable in order to cover a greater number of pixels and vines to obtain more robust results covering different vineyard conditions.

Author Contributions: Conceptualization: S.V., E.B., J.A.R., C.P.-E.; methodology: S.V., E.B., J.A.R., C.P.-E., R.V.; Data acquisition: S.V., E.B., R.V., C.P.-E.; Data processing: S.V., E.B., R.V., C.P.-E.; Data analysis: S.V., E.B., C.P.-E.; resources: S.V., E.B., J.A.R., C.P.-E.; writing—original draft: S.V.; writing—review and editing: E.B., C.P.-E.; supervision: E.B., J.A.R., C.P.-E.; project administration: E.B., J.A.R.; funding acquisition: E.B., J.A.R. All authors have read and agreed to the published version of the manuscript.

Funding: This work has been possible thanks to the economic support of Junta de Castilla y León (Spain), Instituto Tecnológico Agrario de Castilla y León (ITACyL), the project INIA RTA2014-00077-C02, FPI-INIA2016-017 and FEDER funds.

Acknowledgments: We thank the staff of Viticulture for their cooperation in the vineyard operations.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Krishna, K.R. *Push Button Agriculture: Robotics, Drones, Satellite-Guided Soil and Crop Management*; Apple Academic Press: Oxfordshire, UK, 2016.
2. Hall, A.; Lamb, D.W.; Holzapfel, B.; Louis, J. Optical remote sensing applications in viticulture—A review. *Aust. J. Grape Wine Res.* **2002**, *8*, 36–47. [\[CrossRef\]](#)
3. Proffitt, A.P.B. *Precision Viticulture: A New Era in Vineyard Management and Wine Production*; Winetitles Pty Ltd.: Broadview, SA, Australia, 2006.
4. Bachmann, F.; Herbst, R.; Gebbers, R.; Hafner, V.V. Micro UAV Based Georeferenced Orthophoto Generation in VIS + NIR for Precision Agriculture. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.* **2013**, *XL-1/W2*, 11–16. [\[CrossRef\]](#)
5. Rouse, J.W., Jr.; Haas, R.H.; Schell, J.A.; Deering, D.W. Monitoring vegetation systems in the Great Plains with ERTS. In Proceedings of the Third ERTS Symposium, NASA SP-351 1. U.S., Government Printing Office, Washington, DC, USA, 10–14 December 1973; pp. 309–317.
6. Johnson, L.F.; Bosch, D.F.; Williams, D.C.; Lobitz, B.M. Remote sensing of vineyard management zones: Implications for wine quality. *Appl. Eng. Agric.* **2001**, *17*, 557–560. [\[CrossRef\]](#)
7. Tagarakis, A.; Liakos, V.; Fountas, S.; Koundouras, S.; Gemtos, T.A. Management zones delineation using fuzzy clustering techniques in grapevines. *Precis. Agric.* **2013**, *14*, 18–39. [\[CrossRef\]](#)

8. Martínez-Casasnovas, J.A.; Agelet-Fernandez, J.; Arno, J.; Ramos, M.C. Analysis of vineyard differential management zones and relation to vine development, grape maturity and quality. *Span. J. Agric. Res.* **2012**, *10*, 326. [\[CrossRef\]](#)
9. Santesteban, L.G.; Guillaume, S.; Royo, J.B.; Tisseyre, B. Are precision agriculture tools and methods relevant at the whole-vineyard scale? *Precis. Agric.* **2013**, *14*, 2–17. [\[CrossRef\]](#)
10. Santesteban, L.G.; Urretavizcaya, I.; Miranda, C.; Garcia, A.; Royo, J.B. Agronomic significance of the zones defined within vineyards early in the season using NDVI and fruit load information. In Proceedings of the Precision Agriculture '13: Papers Presented at the 9th European Conference on Precision Agriculture, Lleida, Catalonia, Spain, 7–11 July 2013; ISBN 978-90-8686-224-5.
11. Urretavizcaya, I.; Miranda, C.; Royo, J.B.; Santesteban, L.G. Within-vineyard zone delineation in an area with diversity of training systems and plant spacing using parameters of vegetative growth and crop load. In Proceedings of the Precision Agriculture '15: Papers Presented at the 10th European Conference on Precision Agriculture, Volcani Center, Rishon LeTsiyon, Israel, 12–16 July 2015; ISBN 978-90-8686-267-2.
12. Cancela, J.J.; Fandiño, M.; Rey, B.J.; Dafonte, J.; González, X.P. Discrimination of irrigation water management effects in pergola trellis system vineyards using a vegetation and soil index. *Agric. Water Manag.* **2017**, *183*, 70–77. [\[CrossRef\]](#)
13. Johnson, L.F. Temporal stability of an NDVI-LAI relationship in a Napa Valley vineyard. *Aust. J. Grape Wine Res.* **2003**, *9*, 96–101. [\[CrossRef\]](#)
14. Towers, P.C.; Strever, A.; Poblete-Echeverría, C. Comparison of Vegetation Indices for Leaf Area Index Estimation in Vertical Shoot Positioned Vine Canopies with and without Grenbiule Hail-Protection Netting. *Remote Sens.* **2019**, *11*, 1073. [\[CrossRef\]](#)
15. Ledderhof, D.; Brown, R.; Reynolds, A.; Jollineau, M. Using remote sensing to understand Pinot noir vineyard variability in Ontario. *Can. J. Plant Sci.* **2016**, *96*, 89–108. [\[CrossRef\]](#)
16. Lamb, D.W.; Weedon, M.M.; Bramley, R.G.V. Using remote sensing to predict grape phenolics and colour at harvest in a Cabernet Sauvignon vineyard: Timing observations against vine phenology and optimising image resolution. *Aust. J. Grape Wine Res.* **2008**, *10*, 46–54. [\[CrossRef\]](#)
17. Baluja, J.; Diago, M.P.; Balda, P.; Zorer, R.; Meggio, F.; Morales, F.; Tardaguila, J. Assessment of vineyard water status variability by thermal and multispectral imagery using an unmanned aerial vehicle (UAV). *Irrig. Sci.* **2012**, *30*, 511–522. [\[CrossRef\]](#)
18. Anastasiou, E.; Balafoutis, A.; Darra, N.; Psiroukis, V.; Biniari, A.; Xanthopoulos, G.; Fountas, S. Satellite and Proximal Sensing to Estimate the Yield and Quality of Table Grapes. *Agriculture* **2018**, *8*, 94. [\[CrossRef\]](#)
19. Kazmierski, M.; Glémas, P.; Rousseau, J.; Tisseyre, B. Temporal stability of within-field patterns of NDVI in non irrigated Mediterranean vineyards. *OENO One* **2011**, *45*, 61. [\[CrossRef\]](#)
20. Matese, A.; Di Gennaro, S.F.; Berton, A. Assessment of a canopy height model (CHM) in a vineyard using UAV-based multispectral imaging. *Int. J. Remote Sens.* **2017**, *38*, 2150–2160. [\[CrossRef\]](#)
21. Santesteban, L.G.; Di Gennaro, S.F.; Herrero-Langreo, A.; Miranda, C.; Royo, J.B.; Matese, A. High-resolution UAV-based thermal imaging to estimate the instantaneous and seasonal variability of plant water status within a vineyard. *Agr. Wat. Manag.* **2017**, *183*, 49–59. [\[CrossRef\]](#)
22. Weiss, M.; Baret, F. Using 3D Point Clouds Derived from UAV RGB Imagery to Describe Vineyard 3D Macro-Structure. *Remote Sens.* **2017**, *9*, 111. [\[CrossRef\]](#)
23. Mathews, A.; Jensen, J. Visualizing and Quantifying Vineyard Canopy LAI Using an Unmanned Aerial Vehicle (UAV) Collected High Density Structure from Motion Point Cloud. *Remote Sens.* **2013**, *5*, 2164–2183. [\[CrossRef\]](#)
24. Zarco-Tejada, P.J.; Guillén-Climent, M.L.; Hernández-Clemente, R.; Catalina, A.; González, M.R.; Martín, P. Estimating leaf carotenoid content in vineyards using high resolution hyperspectral imagery acquired from an unmanned aerial vehicle (UAV). *Agric. Forest Meteorol.* **2013**, *171–172*, 281–294. [\[CrossRef\]](#)
25. Poblete-Echeverría, C.; Olmedo, G.; Ingram, B.; Bardeen, M. 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 Sens.* **2017**, *9*, 268. [\[CrossRef\]](#)
26. Maes, W.H.; Steppe, K. Perspectives for Remote Sensing with Unmanned Aerial Vehicles in Precision Agriculture. *Trends Plant Sci.* **2019**, *24*, 152–164. [\[CrossRef\]](#) [\[PubMed\]](#)
27. Nex, F.; Remondino, F. UAV for 3D mapping applications: A review. *Appl. Geomat.* **2014**, *6*, 1–15. [\[CrossRef\]](#)

28. Stöcker, C.; Bennett, R.; Nex, F.; Gerke, M.; Zevenbergen, J. Review of the Current State of UAV Regulations. *Remote Sens.* **2017**, *9*, 459. [CrossRef]
29. Matese, A.; Toscano, P.; Di Gennaro, S.; Genesio, L.; Vaccari, F.; Primicerio, J.; Belli, C.; Zaldei, A.; Bianconi, R.; Gioli, B. Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture. *Remote Sens.* **2015**, *7*, 2971–2990. [CrossRef]
30. Borgogno-Mondino, E.; Novello, V.; Lessio, A.; Tarricone, L.; de Palma, L. Intra-vineyard variability description through satellite-derived spectral indices as related to soil and vine water status. *Acta Hortic.* **2018**, *1197*, 59–68. [CrossRef]
31. Sun, L.; Gao, F.; Anderson, M.C.; Kustas, W.P.; Alsina, M.M.; Sanchez, L.; Sams, B.; McKee, L.; Dulaney, W.; White, W.A.; et al. Daily Mapping of 30 m LAI and NDVI for Grape Yield Prediction in California Vineyards. *Remote Sens.* **2017**, *9*, 317. [CrossRef]
32. Knipper; Kustas; Anderson; Alsina; Hain; Alfieri; Prueger; Gao; McKee; Sanchez Using High-Spatiotemporal Thermal Satellite ET Retrievals for Operational Water Use and Stress Monitoring in a California Vineyard. *Remote Sens.* **2019**, *11*, 2124. [CrossRef]
33. Chang, J.; Shoshany, M. Mediterranean shrublands biomass estimation using Sentinel-1 and Sentinel-2. In Proceedings of the 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Beijing, China, 10 July 2016; pp. 5300–5303. [CrossRef]
34. Stumpf, A.; Michéa, D.; Malet, J.-P. Improved Co-Registration of Sentinel-2 and Landsat-8 Imagery for Earth Surface Motion Measurements. *Remote Sens.* **2018**, *10*, 160. [CrossRef]
35. Navarro, A.; Rolim, J.; Miguel, I.; Catalão, J.; Silva, J.; Painho, M.; Vekerdy, Z. Crop Monitoring Based on SPOT-5 Take-5 and Sentinel-1A Data for the Estimation of Crop Water Requirements. *Remote Sens.* **2016**, *8*, 525. [CrossRef]
36. Lacroix, P.; Bièvre, G.; Pathier, E.; Kniess, U.; Jongmans, D. Use of Sentinel-2 images for the detection of precursory motions before landslide failures. *Remote Sens. Environ.* **2018**, *215*, 507–516. [CrossRef]
37. Kääb, A.; Winsvold, S.; Altena, B.; Nuth, C.; Nagler, T.; Wuite, J. Glacier Remote Sensing Using Sentinel-2. Part I: Radiometric and Geometric Performance, and Application to Ice Velocity. *Remote Sens.* **2016**, *8*, 598. [CrossRef]
38. Chen, B.; Jin, Y.; Brown, P. An enhanced bloom index for quantifying floral phenology using multi-scale remote sensing observations. *ISPRS J. Photogramm. Remote Sens.* **2019**, *156*, 108–120. [CrossRef]
39. Vélez, S.; Rubio, J.A.; Andrés, M.I.; Barajas, E. Agronomic classification between vineyards ('Verdejo') using NDVI and Sentinel-2 and evaluation of their wines. *Vitis J. Grapevine Res.* **2019**, *58*, 33–38. [CrossRef]
40. Di Gennaro, S.F.; Dainelli, R.; Palliotti, A.; Toscano, P.; Matese, A. Sentinel-2 Validation for Spatial Variability Assessment in Overhead Trellis System Viticulture Versus UAV and Agronomic Data. *Remote Sens.* **2019**, *11*, 2573. [CrossRef]
41. Zhang, H.K.; Roy, D.P.; Yan, L.; Li, Z.; Huang, H.; Vermote, E.; Skakun, S.; Roger, J.-C. Characterization of Sentinel-2A and Landsat-8 top of atmosphere, surface, and nadir BRDF adjusted reflectance and NDVI differences. *Remote Sens. Environ.* **2018**, *215*, 482–494. [CrossRef]
42. European Space Agency (ESA). SENTINEL-2 User Handbook; ESA Standard Document: 2015; Available online: https://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook (accessed on 25 March 2020).
43. Hall, A.; Louis, J.P.; Lamb, D.W. Low-resolution remotely sensed images of winegrape vineyards map spatial variability in planimetric canopy area instead of leaf area index. *Aust. J. Grape Wine Res.* **2008**, *14*, 9–17. [CrossRef]
44. Devaux, N.; Crestey, T.; Leroux, C.; Tisseyre, B. Potential of Sentinel-2 satellite images to monitor vine fields grown at a territorial scale. *OENO One* **2019**, *53*. [CrossRef]
45. Johnson, L.; Scholasch, T. Remote Sensing of Shaded Area in Vineyards. *Horttech* **2005**, *15*, 859–863. [CrossRef]
46. Fuentes, S.; Poblete-Echeverría, C.; Ortega-Farías, S.; Tyerman, S.; De Bei, R. Automated estimation of leaf area index from grapevine canopies using cover photography, video and computational analysis methods: New automated canopy vigour monitoring tool. *Aust. J. Grape Wine Res.* **2014**, *20*, 465–473. [CrossRef]
47. Montandon, L.; Small, E. The impact of soil reflectance on the quantification of the green vegetation fraction from NDVI. *Remote Sens. Environ.* **2008**, *112*, 1835–1845. [CrossRef]
48. Poblete-Echeverría, C.; Acevedo-Opazo, C.; Ortega-Farías, S.; Valdés-Gómez, H.; Nuñez, R. Study of NDVI spatial variability over a Merlot vineyard-plot in Maule Region using a hand held Spectroradiometer. In Proceedings of the 8th Fruit, Nut, and Veg Prod Eng Symp FRUTIC, Concepción, Chile, 5–9 January 2009; pp. 182–189.

49. Hall, A.; Lamb, D.W.; Holzapfel, B.P.; Louis, J.P. Within-season temporal variation in correlations between vineyard canopy and winegrape composition and yield. *Precis. Agric.* **2011**, *12*, 103–117. [[CrossRef](#)]
50. Prichard, T.; Hanson, B.; Schwankl, L.; Verdegaal, P.; Smith, R. *Deficit Irrigation of Quality Winegrapes Using Micro-Irrigation Techniques*; UC Coop Extension, Dept. of LAWR. UC Davis, 2004; Available online: <http://cesanluisobispo.ucdavis.edu/files/89518.pdf> (accessed on 22 March 2020).
51. Wang, Q.J.; Tian, Q.J.; Lin, Q.Z.; Li, M.X.; Wang, L.M. An improved algorithm for shadow restoration of high spatial resolution imagery. In Proceedings of the Proc. SPIE 7123, Remote Sensing of the Environment: 16th National Symposium on Remote Sensing of China, Beijing, China, 7–10 September 2007; p. 71230D. [[CrossRef](#)]
52. Zhang, Z.; Chen, F. A shadow processing method of high spatial resolution remote sensing image. In Proceedings of the 2010 3rd International Congress on Image and Signal Processing, Yantai, China, 16–18 October 2010; pp. 816–820. [[CrossRef](#)]
53. Aboutaleb, M.; Torres-Rua, A.F.; McKee, M.; Kustas, W.; Nieto, H.; Coopmans, C. Behavior of vegetation/soil indices in shaded and sunlit pixels and evaluation of different shadow compensation methods using UAV high-resolution imagery over vineyards. In Proceedings of the Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping III, Orlando, FL, USA, 18–19 April 2018; Thomasson, J.A., McKee, M., Moorhead, R.J., Eds.; SPIE: Orlando, FL, USA, 2018; p. 6. [[CrossRef](#)]
54. Wu, J.; Bauer, M. Evaluating the Effects of Shadow Detection on QuickBird Image Classification and Spectroradiometric Restoration. *Remote Sens.* **2013**, *5*, 4450–4469. [[CrossRef](#)]
55. Ma, H.; Qin, Q.; Shen, X. Shadow Segmentation and Compensation in High Resolution Satellite Images. In Proceedings of the IGARSS 2008-2008 IEEE International Geoscience and Remote Sensing Symposium, Boston, MA, USA, 8–11 July 2008; pp. II-1036–II-1039. [[CrossRef](#)]
56. Fountas, S.; Anastasiou, E.; Balafoutis, A.; Koundouras, S.; Theoharis, S.; Theodorou, N. The influence of vine variety and vineyard management on the effectiveness of canopy sensors to predict winegrape yield and quality. In Proceedings of the International Conference of Agricultural Engineering, Zurich, Switzerland, 6–10 July 2014.
57. Easlon, H.M.; Bloom, A. Easy Leaf Area: Automated Digital Image Analysis for Rapid and Accurate Measurement of Leaf Area. *Apps Plant Sci.* **2014**, *2*, 1400033. [[CrossRef](#)] [[PubMed](#)]
58. Lobell, D.B.; Asner, G.P. Moisture Effects on Soil Reflectance. *Soil Sci. Soc. Am. J.* **2002**, *66*, 6. [[CrossRef](#)]
59. Yan, L.; Roy, D.P.; Li, Z.; Zhang, H.K.; Huang, H. Sentinel-2A multi-temporal misregistration characterization and an orbit-based sub-pixel registration methodology. *Remote Sens. Environ.* **2018**, *215*, 495–506. [[CrossRef](#)]



© 2020 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).



CAPÍTULO III

CAPÍTULO III. Estimation of Vineyard Leaf Area (LAI) by projected shadows obtained from UAV imagery.



“Estimation of Leaf Area Index in vineyards by analysing projected shadows using UAV imagery”. Vélez, S., Poblete-Echeverría, C., Rubio, J. A., vacas, R., & Barajas, E. (2021). OENO One, 55(4), 159–180. <https://doi.org/10.20870/oeno-one.2021.55.4.4639>

Estimation of Leaf Area Index in vineyards by analysing projected shadows using UAV imagery

 Sergio Vélez^{1*}, Carlos Poblete-Echeverría^{2*}, José Antonio Rubio¹, Rubén Vacas¹ and Enrique Barajas¹

¹ Instituto Tecnológico Agrario de Castilla y León (ITACyL), Unidad de Cultivos Leñosos y Hortícolas. Valladolid. España.

² South African Grape and Wine Research Institute (SAGWRI), Department of Viticulture and Oenology, Faculty of AgriSciences, Stellenbosch University, Private Bag X1, Matieland 7602, South Africa.

 *corresponding authors: velmarse@itacyl.es; cpe@sun.ac.za

 Associate editor: Cassandra Collins

ABSTRACT

A few decades ago, farmers could precisely monitor their croplands just by walking over the fields, but this task becomes more difficult as farm size increases. Precision viticulture can help better understand the vineyard and measure some key structural parameters, such as the Leaf Area Index (LAI). Remote Sensing is a typical approach to monitoring vegetation which measures the spectral information directly emitted and reflected from vegetation. This study explores a new method for estimating LAI which measures the projected shadows of plants using UAV (unmanned aerial vehicle) imagery. A flight mission over a vineyard was scheduled in the afternoon (15:30 to 16:00 solar time), which is the optimal time for the projection of vine shadows on the ground. Real LAI was measured destructively by removing all the vegetation from the area. Then, the projected shadows in the image were detected using machine learning methods (k-means and random forest) and analysed at pixel level using a customised R code. A strong linear relationship ($R^2 = 0.76$, $RMSE = 0.160 \text{ m}^2 \text{ m}^{-2}$ and $MAE = 0.139 \text{ m}^2 \text{ m}^{-2}$) was found between the shaded area and the LAI per vine. This is a quick and simple method, which is non-destructive and gives accurate results; moreover, flights can be scheduled during other periods of the day than solar noon, such as in the morning or afternoon, thus enabling pilots to extend their working day. Therefore, it may be a viable option for determining LAI in vineyards trained on Vertical Shoot Positioned (VSP) systems.

KEYWORDS

leaf area index, shadow detection, image analysis, precision agriculture, machine learning, spatial variability, random forest classification

INTRODUCTION

According to European Union policies (Zarco-Tejada *et al.*, 2014), Precision Agriculture is a farming management concept based on observing, measuring, and responding to inter- and intra-field variability in crops, and in which the spatial variability of vineyards plays a vital role. Vineyards are characterised by a strong spatial structure that is generally stable over time (Bramley and Lamb, 2003) and is affected by several factors, some of which are quite constant over time and can be dealt with through differentiated crop management (Bramley and Hamilton, 2004). Although Precision Agriculture can improve yields, the most significant advantage is the reduction of yield variations over time, which leads to more stability and resilience to a changing climate (Yost *et al.*, 2016). On the other hand, until a few decades ago, farmers could precisely monitor their croplands just by walking over the fields, but with increasing farm size this task is becoming more difficult without using technology (Balafoutis *et al.*, 2017). All of this has led to a growing interest in precision viticulture and further research efforts (Santesteban, 2019), but results can vary significantly depending on knowledge of the crop. Therefore, it is necessary to use methods that precisely define key variables to avoid any problems; for example, over-cropping, which will lead to a canopy with an insufficient amount of healthy active leaves which will not be able to produce enough sugar to obtain the desirable level of ripening in all clusters, resulting in grapes lacking in aroma/flavour and/or the desirable phenol compounds (Reynolds, 2010). Key variables to be defined include cluster, flower or berry number, which directly affect yield and ripening, and leaf area, which is an important variable to monitor, because the ripening of grape clusters depends on the leaf area/fruit weight ratio (Keller, 2015; Jackson, 2020). Leaves are organs specialised in intercepting radiation, which is necessary for photosynthesis. Leaf area is commonly measured using the Leaf Area Index, LAI (Lambers and Oliveira, 2019), which is closely related to photosynthetic active radiation assimilation (Pessarakli, 2014) and is defined as the vegetative development of a crop per unit area of land (Watson, 1947).

1. Leaf Area Index in viticulture

In viticulture, LAI is one of the most used parameters to represent canopy area (Delrot *et al.*, 2010); it is a key indicator, since leaf area directly correlates with other critical parameters, such as transpiration,

root development and photosynthetic capacity, thus limiting yield (Keller, 2015). Furthermore, LAI is related to canopy transpiration and water use, and can thus influence irrigation decisions (Netzer *et al.*, 2008; Munitz *et al.*, 2019), and it is affected by management and environmental factors, such as irrigation, nutrient management, and training systems (Oliveira and Santos, 1995).

2. Current Remote Sensing methods for estimating leaf area index

LAI can be measured using traditional methods, such as the Carbonneau method (Carbonneau, 1976), the adapted Point Quadrat (Smart and Robinson, 1991), the Lopes and Pinto method (Lopes and Pinto, 2005), or by measuring specific parameters related to leaf shape (Williams and Martinson, 2003). However, these methods are inefficient, time-consuming and, in some cases, destructive.

Remote Sensing is a quicker way of estimating LAI via; different technologies can be used, such as field spectroradiometers (Wang *et al.*, 2019), multispectral and hyperspectral data (Mananze *et al.*, 2018), satellite imagery (Meyer *et al.*, 2019; Dube *et al.*, 2019) and thermal imagery (Neinavaz *et al.*, 2019). These technologies can vary in accuracy and complexity:

- ▶ **i)** Different results have been reported for satellite imagery; for example, Johnson *et al.* (2003) showed a significant correlation between image-based leaf area and ground-based leaf area ($R^2 > 0.7$), while Beerli *et al.* (2020) found a weak relationship between satellite information and LAI ($R^2 > 0.3$).
- ▶ **ii)** Specific tools have been developed exclusively for indirect LAI estimation based on the measurement of radiation extinction through the foliage, such as the Plant Canopy Analyzer (PCA, LAI-2000 and 2200, Li-Cor Inc., Lincoln, NE, USA). Johnson and Pierce (2004) have reported high accuracy using PCA in viticulture, but even though this tool has been specifically developed to measure LAI, it is not easy to employ it correctly, since there are different protocols for its use (White *et al.*, 2018).
- ▶ **iii)** General-purpose sensors such as conventional RGB cameras have also shown great potential for measuring LAI using various methods. For example, Fuentes *et al.* (2014) used a camera mounted on a pole to acquire

downward-looking digital images from the middle of the plant, and De Bei *et al.* (2016) developed an app (VitiCanopy) to assess canopy architecture parameters in vineyards using upward-looking imagery. Diago *et al.* (2012) used an RGB camera mounted on a tripod set normal to the canopy plane, 2 m from the row axis and 1.05 m aboveground. Both authors used an RGB camera successfully, reporting high accuracy. Furthermore, these RGB cameras can be mounted on unmanned aerial vehicles (UAVs), thus increasing their possibilities improving the accuracy of the results. Kalisperakis *et al.* (2015) used a low-cost standard RGB camera to estimate LAI, obtaining good results ($R^2 > 0.7$), and they improved the results ($R^2 > 0.8$) by mounting a hyperspectral VNIR imaging sensor on a UAV.

► **iv)** Hyperspectral and multispectral sensors are an improvement on RGB cameras. Using multispectral airborne images, Hall *et al.* (2008) found close relationships between the planimetric canopy area and ground-based measurements of LAI at several phenological stages, whereas no significant relationships were found between NDVI and LAI. Towers *et al.* (2019) used a multispectral sensor to capture nadir-view images of the canopy, reporting varying accuracies depending on whether soil values were used or not, and showing that soil backscattering can contribute more to the signal than vegetation cover can. In a similar way, but capturing the images from a UAV, Comba *et al.* (2020) used a multispectral camera combined with point cloud creation and 3D modelling using SfM (Structure from Motion) to estimate LAI, obtaining good results ($R^2 > 0.8$). Mathews and Jensen (2013) captured images from nadir and varying oblique angles, obtaining less accurate results than Comba *et al.* (2020) ($R^2 > 0.5$), and showing that increasing the number of differing angles/perspectives with overlap improves the SfM product. Kalisperakis *et al.* (2015) reported good accuracy ($R^2 > 0.8$) by creating a 3D model via 3D triangulation; they used aerial RGB images to generate a dense point cloud by employing dense stereo and multi-image matching algorithms. Therefore, even when the same sensors and technology (RGB cameras) are used, different methods can result in different levels of accuracy.

► **v)** An alternative approach involves the use of specific tools that can capture the three dimensions (3-D) of the area. For example, Arnó *et al.* (2013) computed geometric and structural parameters using a tractor-mounted LiDAR system to measure vines (using TAI, tree area index) in a transverse direction along rows with high accuracy ($R^2 > 0.8$).

Each method has its advantages and limitations. Some are cheap to implement (e.g., RGB cameras (Fuentes *et al.*, 2014; Diago *et al.*, 2012)), but may have different drawbacks depending on the method; for example, Diago *et al.* (2012) had problems using RGB cameras in terms of distance to the remnant foliage when the defoliation process was performed over highly dense canopies. Del-Moral-Martínez *et al.* (2016) reported that LiDAR needs to be very precisely set up, otherwise it can generate incorrect LAI values for vines with poor leaf development, recording zones in the canopy containing a considerable percentage of gaps as effective leaf wall area. Mathews and Jensen (2013) reported that the SfM approach needs more time than other UAV missions due to the higher number of images, angles or overlap. In addition, some methods are more expensive than others due to the technologies involved, such as multispectral (Towers *et al.*, 2019; Comba *et al.*, 2020) and hyperspectral cameras (Kalisperakis *et al.*, 2015) or a tractor for mounting the LiDAR system on. Even a low-cost version of LiDAR (Arnó *et al.*, 2013) can still be much more expensive than a standard RGB camera.

For most of these methods, strong correlations with LAI can generally be found ($R^2 > 0.7$), and a key requirement of most of them is to measure data around midday to minimise the effects of shadowing between the vine rows. The development of new methods that will complement current techniques and help expand target areas and extend the work to other periods of the day could be very beneficial for the application of these techniques in practice.

3. Remote Sensing approach to shadows

In Precision Agriculture, Remote Sensing is typically used for monitoring vegetation by measuring the spectral information directly emitted and reflected from the vegetation; each band is analysed separately, or indices are calculated, such as NDVI (Rouse *et al.*, 1973), which is related to vineyard vegetation (Vélez *et al.*, 2020b). In these approaches, shadows are frequently treated as non-desirable information (Ma *et al.*, 2008;

Zhang and Chen, 2010; Wu and Bauer, 2013; Aboutaleb *et al.*, 2018) and are usually removed from datasets (Poblete-Echeverría *et al.*, 2017; Jiang *et al.*, 2018). Nevertheless, some problems can arise when the images are not obtained close to solar noon, as a result of the shaded and sunlit parts of leaves having different reflectance values. In addition, shaded areas can generate noisy data, which significantly affect the estimation of vegetation parameters (Zhang *et al.*, 2015).

4. Proposed approach

The leaf area of the plant is correlated with intercepted light and can be estimated by measuring its shadow (Baeza *et al.*, 2010). Therefore, a newer and less time-consuming approach to estimating LAI could be the study of the shaded soil area within the vineyard using UAVs. Each plant projects its own shadow and image analysis can be used to measure the lateral leaf area of the vines in the shaded inter-row space.

UAV platforms have been extensively used for studying and exploring vineyards, offering valuable technology for estimating numerous vineyard parameters (e.g.; Mathews and Jensen, 2013; Zarco-Tejada *et al.*, 2013; Matese *et al.*, 2016; Santesteban *et al.*, 2017; Weiss and Baret, 2017; Poblete-Echeverría *et al.*, 2017). In general, UAV offers the possibility of obtaining precise and high-resolution multispectral imagery, which is critical for measuring the shape of the vine shadows correctly. Furthermore, it allows the time of the flight to be chosen (Vélez *et al.*, 2020a), which was a crucial factor in this study as the flight needed to be scheduled according to sun elevation, period of the year and desired shadow size (related to plant height). Other authors have hypothesised that shadows can be used as an indirect measure of leaf area and canopy characteristics (Zheng and Moskal, 2009), or have even suggested the possibility of using optical remote Sensing close to solar noon to monitor and map vineyard shaded area (Johnson and Scholasch, 2005). However, to our knowledge, this is the first study to follow and evaluate a field protocol for measuring vine leaf area using the shaded area under real conditions. This study takes advantage of advances in image capturing and UAV technologies, combining previous knowledge in viticulture with remote Sensing and machine learning methods.

In the present study, LAI is estimated by capturing plant shadows using UAV imagery. This method is compatible with previous methods because they are all based on the need to find a quick,

non-destructive, and accurate way of measuring leaf area. However, as previously stated, these methods usually require measurements to be carried out around midday to minimise the effect of shadowing between vine rows.

MATERIALS AND METHODS

1. Experimental site

A large-scale field experiment was carried out in a vineyard (cv. Cabernet-Sauvignon) located in 'Zamadueñas estate' (coordinates: 41.7013° N, 4.7088° W, Valladolid, Spain), which belongs to the Agricultural Technology Institute of Castilla y León (ITACyL). According to the WRB classification (FAO), the soil is medium-coarse textured (FLc) Calcaric Fluvisol + (FLe) Eutric Fluvisol (Nafria *et al.*, 2013). The climate is Csb (temperate with dry or temperate summer - Köppen-Geiger Climate Classification) and is characterised by dry summers and mild, wet winters (AEMET, 2011). Table 1 summarises the meteorological data from the study site collected by 'VA101 Finca Zamadueñas' weather station. The information is available at <http://www.inforiego.org/>.

TABLE 1. Climatic characterisation of the study area. Data collected between 1st January and 31 July 2019.

Variable	Average	Total value
Daily average temperature (°C)	12.0	2550.8
Daily max temperature (°C)	20.1	4250.8
Daily min temperature (°C)	4.7	989.6
Radiation (MJ/m ²)	19.1	4059.0
Cumulative rain (mm)	2.2	133.1

The vineyard comprised a vertical shoot positioned trellis (VSP), and the vines were spur pruned (with bilateral cordon training), with eight spurs per plant, two buds per spur, 2.5 m x 1.2 m row and plant-spacing respectively, and 1.8 m average vine height. The orientation was NE-SW (northeast-southwest), 35 ° to the north. The soil was kept free of any weeds that would have affected image processing (Fountas *et al.*, 2014).

2. Field determination of LAI

In June 2019, the vines were removed from the vineyard. The vines were geo-positioned (Figure 1a) using a GPS Triumph-2 JAVAD GNSS model (Triumph-2, JAVAD GNSS Inc, San Jose, California, USA; Figure 1b) with

centimetre accuracy to mark the vines in the field to be removed within the study area. The GPS TRIUMPH-2 has 216 channels of dual-frequency GPS and GLONASS and could be connected to the mobile phone via Bluetooth and Wi-Fi to access the local GNSS Reference Station Network. Each grapevine was cut in the lower-middle part (Figure 1c) and all the material was extracted from the vineyard.

The real LAI (Leaf Area Index) was determined on a sample of 36 vines. The total leaf area of each removed vine was measured using the EasyLeafArea application (Easlon and Bloom, 2014). The EasyLeafArea app automatically calculates leaf area from green leaf and red scale areas.

It is important to note that the shadow area analysed in this study represents PAI (Plan Area Index), as it captures all plant structures and not only the leaves.

However, the term LAI is used in the present manuscript, because, like other indirect methods based on images, the method employed in this study does not distinguish between leaf and non-leaf material in the analysis; therefore, LAI was used for consistency with real leaf area values obtained using the EasyLeafArea application, and from previous literature (Fuentes *et al.*, 2014; Kalisperakis *et al.*, 2015; De Bei *et al.*, 2016; Towers *et al.*, 2019; Beerli *et al.*, 2020). In addition, there is a strong relationship between PAI and LAI from May to October. Doring *et al.* (2014) observed that estimated PAI did not differ substantially from directly measured LAI in a vineyard, showing a remarkably high correlation between PAI and LAI ($R^2 = 0.93$). Moreover, Arnó *et al.* (2013) found a very high correlation between PAI and LAI ($R^2 = 0.99$) using 'TAI' instead of 'PAI' since LiDAR does not distinguish between green and non-green elements.



FIGURE 1. (a) GPS Triumph-2 JAVAD GNSS (b) Vine geo-positioning (c) Vine removal (d) 3DR UAV.




FIGURE 2. (a) Azimuth and relationship between sun elevation and shadows (b) Planned flight mission. Yellow line: UAV path. Red points: GCPs.

3. Image acquisition

3.1 Flight campaign/survey

The UAV images were acquired on 27 June 2019. Considering the average vine height and using basic trigonometry (Figure 2a), the sun elevation was fixed at $\beta = 45^\circ$. As a result, the flight was scheduled for 15:30 to 16:00 solar time (18:00 local time) using NOAA Solar Calculator (<https://www.esrl.noaa.gov/gmd/grad/solcalc/>), and under 1 Okta cloud cover conditions and azimuth $\alpha = 265^\circ$. This time was used to maximise the vine shadow projection on the floor.

3.2. Unmanned Aerial System (UAS)

Before the UAV flight, a set of 12 ground control points (GCPs) were located in the vineyard and georeferenced using a real-time kinematic (RTK) GPS Triumph-2 JAVAD to improve the geometric accuracy of the image mosaicking process (Figure 2b). Toffanin (2019) defines a Ground Control Point (GCP) as a position measurement made on the ground that can be set using existing structures like pavement corners or lines on a parking lot. A minimum of five GCPs are enough when they include points near corners and within the study area. In this study, clearly distinguishable field structures such as lampposts, maintenance holes and vineyard posts were used (Figure 2b).

An Unmanned Aerial System (UAS) composed of a 3DR quadcopter platform (3DR SOLO, 3D Robotics, Berkeley, California, USA, Figure 1d) was used to fly autonomously on a previously

planned mission using open-source autopilot software: ArduCopter 3.3 (Ardupilot) installed on Pixhawk 2.0 mainboard (3D Robotics, Berkeley, California, USA). The image was acquired using a MAPIR® low-cost RGB+RGN system (Survey3W, MAPIR® Inc, San Diego, California, USA) commanded by a drone's flight controller and composed of two cameras with 12-megapixel rolling shutter CMOS sensors. These sensors had a focal length of 3.37 mm with a horizontal field of view (HFOV) of 87° and -1 % extreme low distortion glass lens and dual-band filter made of silicon, which is sensitive in the Visible and Near-Infrared spectrum from about 400 to 1200 nm. The sensor captures Blue (450 nm), Green (550 nm), Red (660 nm) and Near Infrared light (850 nm). Each camera had a f/2.8 aperture and was factory calibrated. The images were automatically geotagged using an attached GNSS system (NEO-m8, u-blox, Thalwil, Switzerland).

Flight paths (Figure 2b) were designed using the Mission Planner (1.3.68 Version, Michael Osborne, GNU license), and the flight control was provided by Tower Ground Control V.4.0.0 open-source app. The UAV horizontal speed was 3 m/s, and the flying height was 22 m above ground level (AGL) with a 75 % forward and 80 % side overlap. Moreover, it is crucial to correctly configure the camera settings (shutter speed, ISO and EV) so that no pixels reach the maximum pixel value. If a pixel is higher than the maximum value, the information will be lost. Pixels have a value that ranges from a minimum to a maximum based on the image bitrate. The higher the bitrate, the




FIGURE 3. LAI estimation workflow.

more information that can be stored in the image. A sensor captures each image in a RAW format and then saves the RAW or converts it to a more standard format (typically by compressing it). Based on the information provided by the manufacturer, the Survey3 cameras capture 16-bit RAW photos per RGB/RGN channel, which means that there are 16 bits (65,536) pixels and that a pixel value ranges from 0 to 65,535. In this work, since the reflectance of light was captured to analyse differences between pixels to identify shadows, RAW was the used format. In order to keep the pixels from reaching the maximum value mentioned above, the camera was configured as follows: shutter speed: 1/1000 seconds, ISO:50,

and exposure: +0.0. The Ground Sample Distance (GSD) estimated by the software (Mission planner) for the used camera profile (SURVEY 3W) and a flight height of 22 was 1.01 cm/px.

3.3. Orthomosaic generation

The 16-bit raw images were first converted to tiff format using MAPIR® Camera Control (MCC) software. Each pixel was corrected using a known reflectance value by capturing a photo of the 'MAPIR® Camera Reflectance Calibration Ground Target Package' just before the survey; the photo contained four targets that were measured along incremental wavelengths by a calibrated spectrometer (based on the information provided

by the manufacturer, reflective measurements were made along incremental wavelengths of 1 nm and from 350 nm to 1100 nm using multiple Shimadzu spectrophotometers with an integrating sphere). The pixel values of the captured target image were then compared with the known reflectance values of the targets. Using this information in MAPIR® Camera Control (MCC), the pixel values were transformed, and thus the survey images were calibrated. Then, the images were imported into image mosaicking software (Agisoft Metashape 1.5.2, Agisoft LLC, St Petersburg, Russia) based on the structure-from-motion method (SfM) algorithm (Westoby *et al.*, 2012) to generate the orthophotos. The Exif metadata of each image from the GNSS was first used to help in the image alignment process. Then the locations of GCPs from the JAVAD GNSS were manually identified and added to the aligned images to optimise camera positions and orientation data and in turn to improve orthophoto accuracy.

4. Data analysis

The data analysis pipeline is presented in Figure 3. Shadows were detected using remote sensing data via three methods: i) Image reclassification (sensitivity method/manual), ii) K-means, and iii) Random Forest. Each plant area was then cropped and the shadow within the area was measured and correlated with real LAI.

4.1. Grid definition

A vectorial grid was developed in order to isolate the shadow of each vine. First, azimuth and row orientations were used to calculate the grid angles, resulting in a parallelepiped with angles of 95 ° (360 - 265 = 95 °) and 35 ° (Figure 4a) and four sides which were 1.2 and 1.8 m long. The next step was to replicate the grid in the whole vineyard (Figure 4b), excluding a 0.7 m width line corresponding to the vegetation.

Once the grid was designed (Figure 4c), the points taken in the field using GPS were used to indicate which grid area corresponds to each vine. Finally, the image was cropped crop using the grid to isolate the area that belonged to each vine.

4.2. Shadow recognition models

4.2.1 Pixel value analysis

Once the image corresponding to each vine was isolated, a random sampling strategy was manually carried out at various points where there was shade, obtaining the R, G, B and NIR values.

Subsequently, a sensitivity threshold was defined by the ‘ a ’ coefficient:

$$f(x) = (1 \pm a) x$$

whereby the detected shaded area is a function of the band value x modified by the sensitivity coefficient a . As a result, a range was defined by an upper and lower limit, depending on the sensitivity value. Within the range, the value is considered ‘shadow positive’. It is important to consider that not all shades have the same intensity due to the differences in vegetative development modifying intercepted radiation (Zheng and Moskal, 2009, Baeza *et al.*, 2010); therefore, in order to establish an optimal sensitivity value, a visual analysis was performed of the threshold effect on the image. The coefficient varied from 0.1 to 1 (10 % to 100 %) at intervals of 0.1 (10 levels in total), covering the whole range of shadows: from low to high shadow intensity. This process was carried out for each band, reclassifying the image with the values corresponding to the range of shadows, where ‘1’ corresponds to ‘shadow’ and ‘0’ indicates ‘absence of shadow’ (Figure 5a).

Subsequently, the bands were combined to create an RGB or RGN product comprising a combination of the corresponding bands (Figure 5b); the corresponding shaded area was calculated from the total area of the vine and a product with the following shaded area was obtained:

$$f(x, y, z) = (1 \pm a)x \cdot (1 \pm b)y \cdot (1 \pm c)z$$

where x , y and z are the band values (RGB or RGN) and a , b and c are the sensitivity coefficients for each band (10 levels ranging from 0.1 to 1.0). For each RGB and RGN product, $10^3 = 1000$ cases were calculated. This information was validated with the real LAI values in order to find the closest relationship between the detected shadows and the LAI. The best result was used as input for the machine learning algorithms.

Finally, the potential of the method is shown by the classification of the vines depending on shaded area into three LAI levels (high, medium, and low), thus demonstrating that the method could be useful for real applications, such as zoning for differential management, irrigation, or fertilisation.

4.2.2. K-means clustering (Unsupervised machine learning)

K-means clustering is an unsupervised machine learning method that classifies the input data objects into multiple classes based on their inherent




FIGURE 4. (a) Area definition, (b) Ground area of one vine, (c) Vineyard grid.




FIGURE 5. (a) Pixel reclassification method, (b) Single-vine shadow, Reclassified single-vine shadow (multi-band) and Reclassified final product.

distance from each other, thus dividing the input data set into k clusters previously defined by the user (Hung *et al.*, 2005). The clustering problem can be formulated as an optimisation problem, described by:

$$P: \text{minimise } z(W, M) = \sum_{i=1}^n \sum_{j=1}^k w_{ij} d(x_i, \mu_j)$$

$$\text{subject to } \sum_{j=1}^k w_{ij} = 1, \text{ for } i = 1, \dots, n,$$

$$w_{ij} = 0 \text{ or } 1, \text{ for } i = 1, \dots, n, \text{ and } j = 1, \dots, k,$$

where $w_{ij} = 1$ implies object x_i belongs to cluster $G(j)$, and $d(x_i, \mu_j)$ denotes the Euclidean distance between x_i and μ_j for $i = 1, \dots, n$ and $j = 1, \dots, k$. (Pérez-Ortega *et al.*, 2020). The standard version of the algorithm consists of four steps: 1) centroids (k points) are randomly generated in the space, 2) each point is assigned to its closest centroid, according to the distance from all the centroids, 3) new centroids are calculated using the mean value of the objects that belong to each cluster, and 4) the process is repeated from step 2 until equilibrium is reached (i.e. when the number of points remains stable within each cluster).

By using k-means it is possible to classify pixels automatically without training samples. The number of k clusters was set from 2 to 6 to determine the effect of different clusters in the shadow classification process. Subsequently, the cluster with the best visual coincidence with the shadow locations was assigned to the *shadow class*. The initial location of the centroids was set randomly, and the maximum number of iterations was set to 1000.

4.2.3. Random Forest classification (Supervised machine learning)

Random Forest is a supervised machine learning method that uses a decision tree for classification and prediction. The algorithm fits many classification trees to a dataset and then combines the predictions from all the trees. Each tree can be computed separately from other trees, because each tree is independently constructed using a bootstrap sample of the data set (Kuhn, 2008).

The Random Forest algorithm works in four steps: 1) many bootstrap samples from the data are selected, 2) a classification tree is fit to each bootstrap sample, 3) each tree is used to predict the out-of-bag observations, and 4) the predicted class of an observation is calculated by majority vote

of the out-of-bag predictions for that observation (Cutler *et al.*, 2007). The observations in the original dataset that do not occur in a bootstrap sample are the out-of-bag observations. In this study, the number of trees was set to 500, and the training set was divided into four classes: soil, shadows, shaded vegetation, and vegetation.

4.3. Model comparison

Calibration (cross-validated, 50 % split) and validation were used to assess and compare the ability of each model to predict actual LAI. The coefficient of determination (R^2), root mean square error (RMSE) and mean absolute error (MAE) were used to define the model's performance.

Some authors recommend MAE as the most natural measure of average error magnitude instead of RMSE, since measures of average error (such as RMSE), which are based on the sum of squared errors, are functions of the average error (MAE), the distribution of error magnitudes (or squared errors) and $n^{1/2}$; therefore, they do not describe average error alone and MAE is less sensitive to the effect of outliers than RMSE as an indicator of model performance (Willmott and Matsuura, 2005). However, RMSE is also indicated, since it is commonly used in Remote Sensing literature (López-Lozano *et al.*, 2009; Li *et al.*, 2014; Darvishzadeh *et al.*, 2019; Beeri *et al.*, 2020; Campos *et al.*, 2021).

All image and data analyses were carried out using AutoCAD® (version 2021 R.47.X Autodesk, Inc. San Rafael, California, USA), QGIS (version 3.14.X, QGIS developer team 2020), customised codes written in R (version 3.6.X, R Core Team 2019) and R packages *stat*, *caret* and *randomForest* obtained from the Comprehensive R Archive Network (CRAN).

RESULTS

1. Shadow pixel analysis

The sensitivity of the thresholds for the shadow detection of each band was adjusted separately (Figure 6a). Most of the bands have a maximum correlation with LAI at a sensitivity level of around 30 %.

Once the maximum R^2 value is reached, the correlation decreases progressively. As previously explained, the band combinations were analysed using sensitivity values from 0.1 to 1.0, at intervals of 0.1 (10 levels in total). A strong linear correlation can be observed between the real LAI




FIGURE 6. Correlation values (y-axis) for each sensitivity level (x-axis). Sensitivity values from 0.1 to 1.0, in intervals of 0.1 (10 levels in total). (a) single-band, and (b) multi-band.

and the area obtained from the shadows. For the RGB product, using a sensitivity for all coefficients of 0.3, the maximum R^2 value was 0.57. For the RGN product, the maximum was $R^2 = 0.64$ (Table 2), using a sensitivity of 0.4 (Figure 6b).

To increase accuracy, combinations of different coefficients were formed for each band, showing that the highest correlation for RGB was $f(x, y, z) = (1 \pm 0.3)R \cdot (1 \pm 0.3)G \cdot (1 \pm 0.4)B$, with $R^2 = 0.61$, and for RGN it was $f(x, y, z) = (1 \pm 0.3)R \cdot (1 \pm 0.5)G \cdot (1 \pm 0.4)$, with $R^2 = 0.68$ (Table 2).

2. Shadow pixels classification

RGN was the input selected for the machine learning models, since it achieved the maximum correlation with real LAI. Figure 7 shows k-means clustering results for each cluster number. Since the input data is automatically classified using an unsupervised machine learning method, the products obtained differed substantially; however, for any number of clusters, and beginning from $k = 2$, k-means was able to identify shadows. Regarding Random Forest, the algorithm was

TABLE 2. Maximum R^2 values for each product and combination.

BAND	R^2	p-value	Coefficients		
			<i>a</i>	<i>b</i>	<i>c</i>
R	0.36	< 0.01	0.3	-	-
G	0.46	< 0.01	0.3	-	-
B	0.36	< 0.01	0.2	-	-
NIR	0.60	< 0.01	0.3	-	-
RGB	0.57	< 0.01	0.3	0.3	0.3
RGN	0.64	< 0.01	0.4	0.4	0.4
RGB	0.61	< 0.01	0.3	0.3	0.4
RGN	0.68	< 0.01	0.3	0.5	0.4

a, *b* and *c* are the sensitivity coefficients used for each band.




FIGURE 7. *K*-means classification results.

The number of k clusters was set from 2 to 6. (a) Original image, (b) k -means, $k = 2$, (c) k -means, $k = 3$, (d) k -means, $k = 4$, (e) k -means, $k = 5$, and (f) k -means, $k = 6$.




FIGURE 8. Random Forest classification results.

able to identify the four required classes, and the shadows were appropriately classified (Figure 8).

3. Observed vs predicted LAI values

First, RGB and RGN datasets were compared, because they had the highest correlation with LAI. Once the model was defined, the predicted LAI was compared with the observed LAI (Figure 9).

For the RGB product, the best result was obtained using coefficients $a = 0.3$, $b = 0.3$ and $c = 0.4$ ($y = 1.005x + 0.741$), with $R^2 = 0.71$, $RMSE = 0.141 \text{ m}^2 \text{ m}^{-2}$, and $MAE = 0.110 \text{ m}^2 \text{ m}^{-2}$. For RGN, the highest accuracy was obtained using the coefficients $a = 0.3$, $b = 0.5$ and $c = 0.4$ ($y = 1.163x + 0.642$), with $R^2 = 0.74$, $RMSE = 0.146 \text{ m}^2 \text{ m}^{-2}$, and $MAE = 0.123 \text{ m}^2 \text{ m}^{-2}$.




FIGURE 9. Observed vs. Predicted LAI. (a) RGB, (b) RGN.




FIGURE 10. Observed vs. Predicted LAI. (a) Random Forest, (b) k -means, $k = 2$, (c) k -means, $k = 3$, (d) k -means, $k = 4$, (e) k -means, $k = 5$, and (f) k -means, $k = 6$.

Regarding machine learning models (Figure 10), Random Forest slightly improved the previous RGN accuracy. It showed the highest accuracy for predicting LAI ($R^2 = 0.76$, $RMSE = 0.160 \text{ m}^2 \text{ m}^{-2}$, and $MAE = 0.139 \text{ m}^2 \text{ m}^{-2}$) matched by k-means with $k = 6$ ($R^2 = 0.76$, $RMSE = 0.165 \text{ m}^2 \text{ m}^{-2}$, and $MAE = 0.142 \text{ m}^2 \text{ m}^{-2}$). However, Random Forest had slightly lower error values. The rest of k-means classification moved from $R^2 = 0.62$ to 0.75. The worst correlation was found for k-means with $k = 4$.

DISCUSSION

Aerial orthophotography provides information about the canopy size in two dimensions, but shadows comprise a projection in the third dimension, providing additional valuable information. The shadows depend not only on the shape of the vegetation but also on the lighting. Therefore, it is imperative to have an optimal light source (sunny days). Shadows vary throughout the day depending on the position of the sun; therefore, it is possible to plan the flight at the optimum time when the sun is in the desired position (e.g., in the afternoon). However, images can be captured at other times of the day, as long as there are shadows, but the accuracy will probably be related to the size and quality of the shadows.

Our results show that it is possible to accurately plan a flight at a given time by calculating the azimuth and elevation of the sun so that the

information extracted from the shadows can be maximised. This study shows that, in terms of shadow extraction, the afternoon is a good time to take images; however, the exact time should be adjusted depending on vineyard characteristics. At the optimal time, shadows effectively cover the ground between rows, but they are neither affected by the vegetation in the adjacent line, nor by the lack of precision due to an absence of shade. A balance can thereby be achieved, and the maximum amount of information can be obtained from the shadows generated on the ground. The optimum time for taking the image will be determined by the height of the vines and the distance between the rows of plants.

Overall, the results showed a significant positive relationship between the plant shadows and the LAI. According to the results of the RGB and RGN analysis, a correctly identified shadow resulted in a positive and close significant relationship of up to $R^2 = 0.74$. Figure 6 shows a maximum correlation between the shadows and the LAI at around 30 % sensitivity: if the sensitivity is too low, the plant's shadows cannot be easily detected, whereas if it is too high, the algorithm will identify pixels as shadows when they are not (Figure 11). Therefore, errors can occur by overestimating or by underestimating the shadows. However, the slope is much more stable after reaching the maximum value of R^2 ; thus, in order to detect shadows, it is better to overestimate than to underestimate




FIGURE 11. Effect of the sensitivity level.

the value of the pixels. In this study, the models tend to underestimate at high LAI values and overestimate at low LAI values (Figures 9 and 10), which is probably due to an increase in leaf overlap in big canopies.

When comparing RGB and RGN products, the results show RGN to be a better approach, probably because NIR can identify the shaded vegetation, thus helping to discern it from shaded soil.

Regarding machine learning methods, Random Forest improved the RGN accuracy for predicting LAI reaching $R^2 = 0.76$; this was matched by k-means with $k = 6$ ($R^2 = 0.76$). The rest of the k-means classifications showed good accuracy, even in the worst case, with R^2 ranging from 0.62 to 0.75. The best accuracy was obtained for $k = 3$ and $k = 6$, and the worst was found for $k = 4$, showing that in k-means, a higher number of clusters for classification is not strictly related to a better accuracy level.

1. Method considerations

In order to ensure that this method works optimally, several essential factors must be taken into consideration, for example:

- ▶ **i)** Sun position, which influences the shape of the shadows; it is, therefore, essential to consider azimuth and elevation.

- ▶ **ii)** Grapevine management. Trimming the vegetation will modify the vineyard shadows. Depending on the phenological stage, new leaves may cover the gaps. Moreover, errors in shadow detection can occur if the vegetation is not within the trellis for mainly two reasons:

- a. The vegetation covers the shade, which therefore goes undetected (Figure 12a)

- b. The vegetation itself creates shaded areas onto itself (Figure 12b). NIR can help identify them since the values of shade in NIR are different from that in RGB, thus explaining why it is better to use NIR for the detection of vegetation.

- ▶ **iii)** Weed management. Weeds can add noise to the image and render shade detection difficult.

- ▶ **iv)** Vineyard orientation. The optimum orientation for late-day image capture in the study zone is close to SSE-NW, since it is the orthogonal plane regarding the path of the sun. The applicability of this method decreases as the difference between the real plane and the optimum plane increases. However, this should not be an issue in viticulture, since rows are generally oriented close to north-south to maximise light interception on both sides of the canopy for a part of the day (Jackson, 2020).



FIGURE 12. Shadow recognition issues: (a) vegetation over the shadows, and (b) shadows in the vegetation.

2. Limitations of the method

There are some limitations and important points to raise related to the vineyard characteristics and the method itself:

- ▶ **i)** The vineyard vegetation growing in the assigned area extends along the whole length of the vertical trellis, so that it is possible for the vegetation of one grapevine to mix with the adjacent one and thus be wrongly assigned to the other vine. However, this is inherent to the farming system, and it is not a source of error specific to this method.
- ▶ **ii)** If the vineyard dimensions are not exact, by creating an equal and regular mesh of parallelepipeds at certain points, it is possible to under- or overestimate the vegetation due to the error introduced by the designated area. This could be overcome by delineating a boundary (box) around and above each vine trunk using a centroid approach (with prior knowledge of vine spacing).
- ▶ **iii)** Proper overlap is extremely important in order to obtain good quality data and avoid defects such as blotchy artefacts or errors in image alignment.
- ▶ **iv)** The effect of the slope on the shadows could be a problem; however, the effects of topography can be addressed by proper flight/mission planning and the use of DEMs/DCMs. The terrain slope effect was ignored in this work because the vineyard was on flat terrain.
- ▶ **v)** Light intensity. This study was carried out under good light conditions, and according to our results, a clear sky is needed. If the light intensity varies because of clouds or diffuse radiation, the shadows will not be defined, and the results will be affected.
- ▶ **vi)** Structures, such as VSP wires, poles or irrigation pipes project shadows which could get mixed up with the shadows of the vines.
- ▶ **vii)** The method might not work in high-density vineyards/orchards due to the mutual shading of vines/trees.

3. Comparison with other Remote Sensing methods to estimate LAI

As previously discussed, each method has its advantages and disadvantages. Table 3 briefly compares some previously described methods. The comparison considered similar factors to

those considered by Jin *et al.* (2021), including ‘economic cost’ in an attempt to represent the cost of the operation, including all the equipment involved and ‘time investment’, which is the estimated time required for data collection in the field.

In terms of time investment, our proposed method is much quicker than methods that employ specific instrumentation such as PCAs or ceptometers, which are carried on foot to survey plants one at a time (Johnson and Pierce, 2004; López-Lozano and Casterad, 2013; White *et al.*, 2018). LiDAR must be mounted on a ground vehicle (Arnó *et al.*, 2013), as is generally the case for equipment in any field survey method (Diago *et al.*, 2012; Fuentes *et al.*, 2014; Towers *et al.*, 2019). Compared to other methods that use similar technologies (UAV/Airborne + camera), our method involves similar input time (Hall *et al.*, 2008; Kalisperakis *et al.*, 2015; Comba *et al.*, 2020) and is quicker than SfM methods, which require more images (Mathews and Jensen, 2013). However, it is still necessary to go to the vineyard to collect the data; therefore, satellite methods are even quicker (Johnson, 2003; Beerli *et al.*, 2020).

The proposed method is low-cost as basic UAV and normal RGB+RGN cameras can be used. The best performance was obtained with the RGN camera, which is slightly more expensive than an RGB camera, such as that used in Diago *et al.* (2012) and Fuentes *et al.* (2014); however, it is cheaper than the multispectral sensors used by Towers *et al.* (2019) and Comba *et al.* (2020) or the hyperspectral sensor used by Kalisperakis *et al.* (2015). Specific sensors such as PCA or ceptometer are also more expensive. Moreover, when considering the cost of the platform, the UAV used in the study is much cheaper than a ground vehicle (Arnó *et al.*, 2013).

As regards accuracy, our method is in line with other suitable methods in studies reporting similar correlation values. Furthermore, to our knowledge, this is the first time a method of this kind has been developed and will therefore likely be improved in further experiments, which has been in the case in other studies; for example, Mathews and Jensen (2013) reported $R^2 > 0.5$ accuracy, but in subsequent studies, Kalisperakis *et al.* (2015) and Comba *et al.* (2020) reported higher accuracy ($R^2 > 0.8$).

In summary, the method described in this article is cheaper and less time-consuming than other methods for calculating LAI and similar levels of

accuracy can be obtained (Table 3). Lastly, other methods usually require the experiment to be carried out close to solar noon, or they try to at least avoid shadows; the present method thus allows the flight to be scheduled during other periods of the day than solar noon, such as morning or afternoon, enabling pilots to extend their working day.

It should be noted that this comparison only aims to highlight the potential and accuracy of existing methods versus the usefulness of the method proposed in this paper. The results presented in the literature are not fully comparable, because they have been obtained from studies carried out under different experimental conditions. The reference LAI used was not obtained in the same way in all the experiments. In the present study, real LAI was used, which was measured destructively to validate the estimated results, but other authors have used LAI estimated by other methods, such as with a Li-COR PCA (Johnson, 2003; Fuentes *et al.*, 2014) or an AccuPAR LP-80 ceptometer (Mathews and Jensen, 2013).

4. Potential applications

This method can be applied to other woody crops, such as olive or walnut trees, where mutual shading of consecutive trees has a lower effect,

depending on the planting distance. However, in these cases (bigger canopies), the internal leaf overlap is higher, an effect which would need to be considered in the application/calibration of the proposed method. In addition, given that the vegetation of one plant can mix with the adjacent in vertical-trellis trained crops, this method may be even more effective when applied to non-trellis trained crops.

Images could also be taken several times a year to monitor the growth of the vegetation (for plant vigour). From the image history of the crop, it would be possible to create a temporal model of the evolution of the shadows, and therefore of the LAI, and thereby adjust vineyard management accordingly (e.g., irrigation, treatments, and leaf removal). However, the number of woody structures covered by the leaves will certainly affect the accuracy of the method.

Finally, to illustrate the real applicability of the method, a cluster analysis was developed: the dataset was split into three groups, with each plant being classified according to shaded area on three LAI levels (high, medium, and low), and 0.88, 0.75 and 0.63 m² of soil shaded area as centroids and 1.79, 1.54 and 1.31 for high, medium, and low LAI respectively. Figure 13a shows three different

TABLE 3. Comparison between current Remote Sensing LAI measurement methods and shadow measurement methods.

Method	Platform	Economic cost	Time invested	LAI Correlation	Authors
Shadow measurement	UAV	Low	Low	$R^2 > 0.7$	Present study
3D SfM	UAV	Low	Low	$R^2 > 0.5$	Mathews and Jensen (2013)
	UAV	Low	Low	$R^2 > 0.8$	Kalisperakis <i>et al.</i> (2015)
	UAV	Medium	Low	$R^2 > 0.8$	Comba <i>et al.</i> (2020)
	UAV	Low	Low	$R^2 > 0.7$	Kalisperakis <i>et al.</i> (2015)
2D RGB Or multispectral	Ground	Low	High	$R^2 > 0.8$	Diago <i>et al.</i> (2012)
	Ground	Medium	High	$R^2 > 0.9$	Fuentes <i>et al.</i> (2014)
	Ground	Medium	High	$R^2 > 0.5$	Towers <i>et al.</i> (2019)
	Airborne	Medium	Low	$R^2 > 0.5$	Hall <i>et al.</i> (2008)
LiDAR	Ground	High	Medium	$R^2 > 0.8$	Arnó <i>et al.</i> (2013)
Hyperspectral camera	UAV	High	Low	$R^2 > 0.8$	Kalisperakis <i>et al.</i> (2015)
Plant canopy analyser	Ground	Medium	High	$R^2 > 0.7$	Johnson and Pierce (2004)
				$R^2 > 0.7$	White <i>et al.</i> (2018)
Satellite	Satellite	Low	Very low	$R^2 > 0.3$	Beerli <i>et al.</i> (2020)
				$R^2 > 0.7$	Johnson <i>et al.</i> (2003)

The R^2 values are the values reported by the authors. The 'Economic cost' and 'Time invested' values are based on the methods described by authors compared to the present study method. In 'Economic cost': 'low' total cost up to 3,000; 'medium' up to 6,000 \$; 'high' more than 6,000 \$.

clusters in which the vines are grouped according to LAI; k-means classification was used for this, but other machine learning methods could be applied. Figure 13b shows the result of the classification on a map, showing that this method could be used for, for example, zoning the vineyard according to different irrigation or fertilisation management.

The previously mentioned factors prove that shadows can estimate the LAI. Furthermore, the results show that, by using simple equations and machine learning methods and by controlling the limitation factors, leaf surface area can be estimated from the shadow of the plants. Therefore, all advantages and limitations considered, the shadow captured from UAV images is a good estimator of LAI, provided that the method used to obtain the shadows is the appropriate one.

Further research is needed to assess the temporal stability of the relationship between plant shadows and LAI, and the applicability of the method to other

woody crops and farming systems or vineyards planted with cover crops. Moreover, it would be interesting to explore whether this method can be used to estimate other vineyard parameters or to assess the possibility of extracting more information about canopy structure and vegetation density; for example, Figure 11 shows gaps in the detected vegetation using different sensitivity levels (*a*, *b* and *c*) due to differing shadow intensities for each pixel, indicating that it may be possible to use this method for extracting more information about canopy structure and vegetation density. Other authors (Zheng and Moskal, 2009; Baeza *et al.*, 2010) have studied the relationships between the incident radiation intercepted by the vine, LAI, and aboveground biomass, concluding that the measurement of the gap fraction is a way of analysing canopy structure and that it can be parameterised by LAI and leaf angle distribution. Additional research is required in this area.




FIGURE 13. (a) Classification according to LAI level using k-means and (b) Mapping/zoning according to LAI level.

CONCLUSIONS

This study shows a simple and effective method for estimating LAI in vineyards using machine learning tools and projected shadows captured by a UAV. It is a combination of methods known for centuries and modern image recognition techniques.

A strong positive relationship was observed between the shaded area and the leaf area of the vines, thus resulting in a high level of accuracy for the LAI estimation. ($R^2 = 0.76$, $RMSE = 0.160 \text{ m}^2 \text{ m}^{-2}$ and $MAE = 0.139 \text{ m}^2 \text{ m}^{-2}$). However, to accurately estimate LAI, shadow areas must be correctly identified, otherwise errors can occur due to over- or underestimating the shadows. In addition, it is essential to manage the influence of parameters on the method (e.g., the position of the sun, vineyard management or weed management) to avoid noise in the image.

The results of the study are useful because LAI is an essential parameter for vineyard management and zoning. Moreover, this method is fully compatible with other Remote Sensing methods and can be incorporated into a flexible working day.

Acknowledgements: This study was possible thanks to the financial support of Junta de Castilla y León (Spain), the project INIA RTA2014-00077-C02, FPI-INIA2016-017 and FEDER funding. We would like to thank the staff of Viticulture for their cooperation in the vineyard operations.

REFERENCES

- Aboutaleb, M., Torres-Rua, A. F., McKee, M., Kustas, W., Nieto, H., & Coopmans, C. (2018). *Behavior of vegetation/soil indices in shaded and sunlit pixels and evaluation of different shadow compensation methods using UAV high-resolution imagery over vineyards*. Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping III. Published. <https://doi.org/10.1117/12.2305883>
- AEMET (2011). Agencia Estatal de Meteorología. *Iberian climate Atlas*. ISBN: 978-84-7837-079-5
- Arnó, J., Escolà, A., Vallès, J. M., Llorens, J., Sanz, R., Masip, J., Palacín, J., & Rosell-Polo, J. R. (2013). Leaf area index estimation in vineyards using a ground-based LiDAR scanner. *Precision Agriculture*, 14(3), 290–306. <https://doi.org/10.1007/s11119-012-9295-0>
- Baeza, P., Sánchez-De-Miguel, P., & Lissarrague, J. R. (2010). Radiation Balance in Vineyards. *Methodologies and Results in Grapevine Research*, 21–29. https://doi.org/10.1007/978-90-481-9283-0_2
- Balafoutis, A. T., Beck, B., Fountas, S., Tsiropoulos, Z., Vangeyte, J., van der Wal, T., Soto-Embodas, I., Gómez-Barbero, M., & Pedersen, S. M. (2017). Smart Farming Technologies – Description, Taxonomy and Economic Impact. *Progress in Precision Agriculture*, 21–77. https://doi.org/10.1007/978-3-319-68715-5_2
- Beeri, O., Netzer, Y., Munitz, S., Mintz, D. F., Pelta, R., Shilo, T., Horeish, A., & Mey-tal, S. (2020). Kc and LAI Estimations Using Optical and SAR Remote Sensing Imagery for Vineyards Plots. *Remote Sensing*, 12(21), 3478. <https://doi.org/10.3390/rs12213478>
- Bramley, R. & Lamb, D. (2003). Making sense of vineyard variability in Australia. In: Ortega, R. and Esser, A. (Eds) *Precision Viticulture*. Proceedings of an international symposium held as part of the IX Congreso Latinoamericano de Viticultura y Enología, Chile. Centro de Agricultura de Precisión, Pontificia Universidad Católica de Chile, Facultad de Agronomía e Ingeniería Forestal, Santiago, Chile. pp. 35-54.
- Bramley, R., & Hamilton, R. (2004). Understanding variability in winegrape production systems. *Australian Journal of Grape and Wine Research*, 10(1), 32–45. <https://doi.org/10.1111/j.1755-0238.2004.tb00006.x>
- Carbonneau, A. (1976). *Principes et méthodes de mesure de la surface foliaire*. Essai de caractérisation des types de feuilles dans le genre *Vitis*, Ann. Amélior. Plantes, vol.26, issue.2, pp.327-343.
- Campos, J., García-Ruiz, F., & Gil, E. (2021). Assessment of Vineyard Canopy Characteristics from Vigour Maps Obtained Using UAV and Satellite Imagery. *Sensors*, 21(7), 2363. <https://doi.org/10.3390/s21072363>
- Comba, L., Biglia, A., Ricauda Aimonino, D., Tortia, C., Mania, E., Guidoni, S., & Gay, P. (2020). Leaf Area Index evaluation in vineyards using 3D point clouds from UAV imagery. *Precision Agriculture*, 21(4), 881–896. <https://doi.org/10.1007/s11119-019-09699-x>
- Cutler, D. R., Edwards, T. C., Beard, K. H., Cutler, A., Hess, K. T., Gibson, J., & Lawler, J. J. (2007). Random Forests for classification in ecology. *Ecology*, 88(11), 2783–2792. <https://doi.org/10.1890/07-0539.1>
- Darvishzadeh, R., Wang, T., Skidmore, A., Vrieling, A., O'Connor, B., Gara, T., Ens, B., & Paganini, M. (2019). Analysis of Sentinel-2 and RapidEye for Retrieval of Leaf Area Index in a Saltmarsh Using a Radiative Transfer Model. *Remote Sensing*, 11(6), 671. <https://doi.org/10.3390/rs11060671>
- De Bei, R., Fuentes, S., Gilliam, M., Tyerman, S., Edwards, E., Bianchini, N., Smith, J., & Collins, C. (2016). VitiCanopy: A Free Computer App to Estimate Canopy Vigor and Porosity for Grapevine. *Sensors*, 16(4), 585. <https://doi.org/10.3390/s16040585>
- Del-Moral-Martínez, I., Rosell-Polo, J., Company, J., Sanz, R., Escolà, A., Masip, J., Martínez-Casasnovas, J., & Arnó, J. (2016). Mapping Vineyard Leaf Area Using Mobile Terrestrial Laser Scanners: Should Rows be Scanned On-the-Go or Discontinuously Sampled? *Sensors*, 16(1), 119. <https://doi.org/10.3390/s16010119>

- Delrot, S., Medrano, H., Or, E., Bavaresco, L., & Grando, S. (Eds.). (2010). *Methodologies and Results in Grapevine Research*. Springer. Published. <https://doi.org/10.1007/978-90-481-9283-0>
- Diago, M. P., Correa, C., Millán, B., Barreiro, P., Valero, C., & Tardaguila, J. (2012). Grapevine Yield and Leaf Area Estimation Using Supervised Classification Methodology on RGB Images Taken under Field Conditions. *Sensors*, 12(12), 16988–17006. <https://doi.org/10.3390/s121216988>
- Doring, J., Stoll, M., Kauer, R., Frisch, M., & Tittmann, S. (2014). Indirect Estimation of Leaf Area Index in VSP-Trained Grapevines Using Plant Area Index. *American Journal of Enology and Viticulture*, 65(1), 153–158. <https://doi.org/10.5344/ajev.2013.13073>
- Dube, T., Pandit, S., Shoko, C., Ramoelo, A., Mazvimavi, D., & Dalu, T. (2019). Numerical Assessments of Leaf Area Index in Tropical Savanna Rangelands, South Africa Using Landsat 8 OLI Derived Metrics and In-Situ Measurements. *Remote Sensing*, 11(7), 829. <https://doi.org/10.3390/rs11070829>
- Easlon, H. M., & Bloom, A. J. (2014). Easy Leaf Area: Automated digital image analysis for rapid and accurate measurement of leaf area. *Applications in Plant Sciences*, 2(7), 1400033. <https://doi.org/10.3732/apps.1400033>
- Fountas, S., Anastasiou, E., Balafoutis, A., Koundouras, S., Theoharis, S. & Theodorou, N. (2014). *The influence of vine variety and vineyard management on the effectiveness of canopy sensors to predict winegrape yield and quality*. In Proceedings of the International Conference of Agricultural Engineering, Zurich, Switzerland, 6–10 July 2014.
- Fuentes, S., Poblete-Echeverría, C., Ortega-Farias, S., Tyerman, S., & de Bei, R. (2014). Automated estimation of leaf area index from grapevine canopies using cover photography, video and computational analysis methods. *Australian Journal of Grape and Wine Research*, 20(3), 465–473. <https://doi.org/10.1111/ajgw.12098>
- Hall, A., Louis, J., & Lamb, D. (2008). Low-resolution remotely sensed images of winegrape vineyards map spatial variability in planimetric canopy area instead of leaf area index. *Australian Journal of Grape and Wine Research*, 14(1), 9–17. <https://doi.org/10.1111/j.1755-0238.2008.00002.x>
- Hung, M.-C., Wu, J., Chang, J.-H. & Yang, D.-L. (2005). An Efficient K-Means Clustering Algorithm Using Simple Partitioning. *J Journal of Information Science and Engineering*, Vol. 21 No. 6, pp. 1157–1177.
- Jackson, R. (2020). *Wine Science: Principles and Applications*, 5th ed., Elsevier: Cambridge. ISBN 978-0-12-816118-0.
- Jiang, H., Wang, S., Cao, X., Yang, C., Zhang, Z., & Wang, X. (2018). A shadow- eliminated vegetation index (SEVI) for removal of self and cast shadow effects on vegetation in rugged terrains. *International Journal of Digital Earth*, 12(9), 1013–1029. <https://doi.org/10.1080/17538947.2018.1495770>
- Jin, X., Zarco-Tejada, P. J., Schmidhalter, U., Reynolds, M. P., Hawkesford, M. J., Varshney, R. K., Yang, T., Nie, C., Li, Z., Ming, B., Xiao, Y., Xie, Y., & Li, S. (2021). High-Throughput Estimation of Crop Traits: A Review of Ground and Aerial Phenotyping Platforms. *IEEE Geoscience and Remote Sensing Magazine*, 9(1), 200–231. <https://doi.org/10.1109/mgrs.2020.2998816>
- Johnson, L. F. (2003). Temporal stability of an NDVI-LAI relationship in a Napa Valley vineyard. *Australian Journal of Grape and Wine Research*, 9(2), 96–101. <https://doi.org/10.1111/j.1755-0238.2003.tb00258.x>
- Johnson, L.F. & Pierce, L.L. (2004). *Institute for Earth Systems Science and Policy*, California State University, Monterey Bay, 100 Campus Center, Seaside, CA 93955. Crop Production, 39, 3.
- Johnson, L., Roczen, D., Youkhana, S., Nemani, R., & Bosch, D. (2003). Mapping vineyard leaf area with multispectral satellite imagery. *Computers and Electronics in Agriculture*, 38(1), 33–44. [https://doi.org/10.1016/s0168-1699\(02\)00106-0](https://doi.org/10.1016/s0168-1699(02)00106-0)
- Johnson, L., & Scholasch, T. (2005). Remote Sensing of Shaded Area in Vineyards. *HortTechnology*, 15(4), 859–863. <https://doi.org/10.21273/horttech.15.4.0859>
- Kalisperakis, I., Stentoumis, C., Grammatikopoulos, L., & Karantzas, K. (2015). Leaf Area Index estimation in vineyards from UAV hyperspectral data, 2D image mosaics and 3D canopy surface models. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XL-1/W4*, 299–303. <https://doi.org/10.5194/isprsarchives-xl-1-w4-299-2015>
- Keller, M. (2015). *The Science of Grapevines: Anatomy and Physiology*. Second edition. Elsevier/AP, Academic Press. Amsterdam, Boston. ISBN: 9780124199873.
- Kuhn, M. (2008). Building Predictive Models in R Using the caret Package. *Journal of Statistical Software*, 28, 1–26.
- Lambers, H., & Oliveira, R. S. (2019). *Plant Physiological Ecology*. Springer. Published. <https://doi.org/10.1007/978-3-030-29639-1>
- Li, X., Zhang, Y., Bao, Y., Luo, J., Jin, X., Xu, X., Song, X., & Yang, G. (2014). Exploring the Best Hyperspectral Features for LAI Estimation Using Partial Least Squares Regression. *Remote Sensing*, 6(7), 6221–6241. <https://doi.org/10.3390/rs6076221>
- Lopes, C. & Pinto, P.A. (2005). Easy and Accurate Estimation of Grapevine Leaf Area with Simple Mathematical Models. *Vitis* 44 (2), 55–61. <https://doi.org/10.5073/vitis.2005.44.55-61>


- López-Lozano, R., Baret, F., García De Cortázar-Atauri, I., Bertrand, N., & Casterad, M. A. (2009). Optimal geometric configuration and algorithms for LAI indirect estimates under row canopies: *The case of vineyards. Agricultural and Forest Meteorology*, 149(8), 1307–1316. <https://doi.org/10.1016/j.agrformet.2009.03.001>
- López-Lozano, R., & Casterad, M. (2013). Comparison of different protocols for indirect measurement of leaf area index with ceptometers in vertically trained vineyards. *Australian Journal of Grape and Wine Research*, 19(1), 116–122. <https://doi.org/10.1111/ajgw.12005>
- Ma, H., Qin, Q., & Shen, X. (2008). *Shadow Segmentation and Compensation in High Resolution Satellite Images*. IGARSS 2008 - 2008 IEEE International Geoscience and Remote Sensing Symposium. Published. <https://doi.org/10.1109/igarss.2008.4779175>
- Mananze, S., Pôças, I., & Cunha, M. (2018). Retrieval of Maize Leaf Area Index Using Hyperspectral and Multispectral Data. *Remote Sensing*, 10(12), 1942. <https://doi.org/10.3390/rs10121942>
- Matese, A., di Gennaro, S. F., & Berton, A. (2016). Assessment of a canopy height model (CHM) in a vineyard using UAV-based multispectral imaging. *International Journal of Remote Sensing*, 38(8–10), 2150–2160. <https://doi.org/10.1080/01431161.2016.1226002>
- Mathews, A., & Jensen, J. (2013). Visualising and Quantifying Vineyard Canopy LAI Using an Unmanned Aerial Vehicle (UAV) Collected High Density Structure from Motion Point Cloud. *Remote Sensing*, 5(5), 2164–2183. <https://doi.org/10.3390/rs5052164>
- Meyer, L. H., Heurich, M., Beudert, B., Premier, J., & Pflugmacher, D. (2019). Comparison of Landsat-8 and Sentinel-2 Data for Estimation of Leaf Area Index in Temperate Forests. *Remote Sensing*, 11(10), 1160. <https://doi.org/10.3390/rs11101160>
- Munitz, S., Schwartz, A., & Netzer, Y. (2019). Water consumption, crop coefficient and leaf area relations of a *Vitis vinifera* cv. “Cabernet Sauvignon” vineyard. *Agricultural Water Management*, 219, 86–94. <https://doi.org/10.1016/j.agwat.2019.03.051>
- Nafria, D.A., Garrido, N., Álvarez, M.V., Cubero, D., Fernández, M., Villarino, I., Gutiérrez, A. & Abia, I. (2013). *Atlas agroclimático de Castilla y León*. NIPO 281-13-008-5.
- Neinavaz, E., Darvishzadeh, R., Skidmore, A., & Abdullah, H. (2019). Integration of Landsat-8 Thermal and Visible-Short Wave Infrared Data for Improving Prediction Accuracy of Forest Leaf Area Index. *Remote Sensing*, 11(4), 390. <https://doi.org/10.3390/rs11040390>
- Netzer, Y., Yao, C., Shenker, M., Bravdo, B. A., & Schwartz, A. (2008). Water use and the development of seasonal crop coefficients for Superior Seedless grapevines trained to an open-gable trellis system. *Irrigation Science*, 27(2), 109–120. <https://doi.org/10.1007/s00271-008-0124-1>
- Oliveira, M. & Santos, M. (1995) A semi-empirical method to estimate canopy leaf area of vineyards. *American Journal of Enology and Viticulture* 46, 389–391.
- Pérez-Ortega, J., Nely Almanza-Ortega, N., Vega-Villalobos, A., Pazos-Rangel, R., Zavala-Díaz, C. & Martínez-Rebollar, A. (2020). *The K-Means Algorithm Evolution*. In *Introduction to Data Science and Machine Learning*, Sud, K., Erdogmus, P., Kadry, S., Eds., IntechOpen, ISBN 978-1-83880-333-9.
- Pessarakli, M. (2014). *Plant and crop physiology*. 3rd ed. CRC Press, Taylor & Francis Group. Boca Raton, FL. ISBN: 978-1-4665-5329-3
- Poblete-Echeverría, C., Olmedo, G., Ingram, B., & Bardeen, M. (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), 268. <https://doi.org/10.3390/rs9030268>
- Reynolds, A.G. (2010). *Managing Wine Quality. Volume 1: Viticulture and wine quality*. Woodhead Publishing. ISBN 9781845694845
- Rouse, J.W., Jr., Haas, R.H., Schell, J.A. & Deering, D.W. (1973). *Monitoring vegetation systems in the Great Plains with ERTS*. In *Proceedings of the Third ERTS Symposium*, NASA SP-351 1. U.S., Government Printing Office, Washington, DC, USA, 10–14 December 1973, pp. 309–317.
- Santesteban, L., di Gennaro, S., Herrero-Langreo, A., Miranda, C., Royo, J., & Matese, A. (2017). High-resolution UAV-based thermal imaging to estimate the instantaneous and seasonal variability of plant water status within a vineyard. *Agricultural Water Management*, 183, 49–59. <https://doi.org/10.1016/j.agwat.2016.08.026>
- Santesteban, L. G. (2019). Precision viticulture and advanced analytics. A short review. *Food Chemistry*, 279, 58–62. <https://doi.org/10.1016/j.foodchem.2018.11.140>
- Smart, R. & Robinson, M. (1991). *Sunlight into wine. Winetitles*. ISBN: 9781875130108.
- Toffanin, P. (2019). *Open Drone Map: The Missing Guide*. First edition. UAV4GEO. MasseranoLabs LLC.
- Towers, P. C., Strever, A., & Poblete-Echeverría, C. (2019). Comparison of Vegetation Indices for Leaf Area Index Estimation in Vertical Shoot Positioned Vine Canopies with and without Grenbiule Hail-Protection Netting. *Remote Sensing*, 11(9), 1073. <https://doi.org/10.3390/rs11091073>

- Vélez, S., Barajas, E., Rubio, J. A., Poblete-Echeverría, C. & Olmedo, G.F. (2020a) ‘*Vitis*: Biology and Species’. Chapter 10. Remote Sensing: In *the Digital Viticulture Era*. ISBN: 978-1-53618-308-5. Nova Publishers.
- Vélez, S., Barajas, E., Rubio, J. A., Vacas, R., & Poblete-Echeverría, C. (2020b). Effect of Missing Vines on Total Leaf Area Determined by NDVI Calculated from Sentinel Satellite Data: Progressive Vine Removal Experiments. *Applied Sciences*, 10(10), 3612. <https://doi.org/10.3390/app10103612>
- Wang, L., Chang, Q., Li, F., Yan, L., Huang, Y., Wang, Q., & Luo, L. (2019). Effects of Growth Stage Development on Paddy Rice Leaf Area Index Prediction Models. *Remote Sensing*, 11(3), 361. <https://doi.org/10.3390/rs11030361>
- Watson, D. J. (1947). Comparative Physiological Studies on the Growth of Field Crops: I. Variation in Net Assimilation Rate and Leaf Area between Species and Varieties, and within and between Years. *Annals of Botany*, 11(1), 41–76. <https://doi.org/10.1093/oxfordjournals.aob.a083148>
- Weiss, M., & Baret, F. (2017). Using 3D Point Clouds Derived from UAV RGB Imagery to Describe Vineyard 3D Macro-Structure. *Remote Sensing*, 9(2), 111. <https://doi.org/10.3390/rs9020111>
- Westoby, M., Brasington, J., Glasser, N., Hambrey, M., & Reynolds, J. (2012). ‘Structure-from-Motion’ photogrammetry: A low-cost, effective tool for geoscience applications. *Geomorphology*, 179, 300–314. <https://doi.org/10.1016/j.geomorph.2012.08.021>
- White, W. A., Alsina, M. M., Nieto, H., McKee, L. G., Gao, F., & Kustas, W. P. (2018). Determining a robust indirect measurement of leaf area index in California vineyards for validating remote sensing-based retrievals. *Irrigation Science*, 37(3), 269–280. <https://doi.org/10.1007/s00271-018-0614-8>
- Williams, L., & Martinson, T. E. (2003). Non-destructive leaf area estimation of ‘Niagara’ and ‘DeChaunac’ grapevines. *Scientia Horticulturae*, 98(4), 493–498. [https://doi.org/10.1016/s0304-4238\(03\)00020-7](https://doi.org/10.1016/s0304-4238(03)00020-7)
- Willmott, C., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30, 79–82. <https://doi.org/10.3354/cr030079>
- Wu, J., & Bauer, M. (2013). Evaluating the Effects of Shadow Detection on QuickBird Image Classification and Spectroradiometric Restoration. *Remote Sensing*, 5(9), 4450–4469. <https://doi.org/10.3390/rs5094450>
- Yost, M. A., Kitchen, N. R., Sudduth, K. A., Sadler, E. J., Drummond, S. T., & Volkmann, M. R. (2016). Long-term impact of a precision agriculture system on grain crop production. *Precision Agriculture*, 18(5), 823–842. <https://doi.org/10.1007/s11119-016-9490-5>
- Zarco-Tejada, P., Guillén-Climent, M., Hernández-Clemente, R., Catalina, A., González, M., & Martín, P. (2013). Estimating leaf carotenoid content in vineyards using high resolution hyperspectral imagery acquired from an unmanned aerial vehicle (UAV). *Agricultural and Forest Meteorology*, 171–172, 281–294. <https://doi.org/10.1016/j.agrformet.2012.12.013>
- Zarco-Tejada, P., Hubbard, N. & Loudjani, P. (2014) *Precision agriculture: an opportunity for EU farmers – potential support with the CAP 2014–2020*. Joint Research Centre (JRC) of the European Commission. Monitoring Agriculture ResourceS (MARS). Unit H04, Brussels, Belgium
- Zhang, Z., & Chen, F. (2010). A shadow processing method of high spatial resolution remote sensing image. 2010 3rd International Congress on Image and Signal Processing. Published. <https://doi.org/10.1109/cisp.2010.5646850>
- Zhang, L., Sun, X., Wu, T., & Zhang, H. (2015). An Analysis of Shadow Effects on Spectral Vegetation Indexes Using a Ground-Based Imaging Spectrometer. *IEEE Geoscience and Remote Sensing Letters*, 12(11), 2188–2192. <https://doi.org/10.1109/lgrs.2015.2450218>
- Zheng, G., & Moskal, L. M. (2009). Retrieving Leaf Area Index (LAI) Using Remote Sensing: Theories, Methods and Sensors. *Sensors*, 9(4), 2719–2745. <https://doi.org/10.3390/s90402719>



This article is published under the **Creative Commons licence (CC BY 4.0)**.

Use of all or part of the content of this article must mention the authors, the year of publication, the title, the name of the journal, the volume, the pages and the DOI in compliance with the information given above.



CAPÍTULO IV

CAPÍTULO IV. Sentinel-2 satellite imagery for agronomic and quality variability assessment of pistachio (*Pistacia vera* L.).



sustainability

“Sentinel-2 satellite imagery for agronomic and quality variability assessment of pistachio (*Pistacia vera* L.)”. Barajas, E.; Álvarez, S.; Fernández, E.; Vélez, S.; Rubio, J.A.; Martín, H. C. Sustainability 2020, 12(20), 8437

doi: <https://doi.org/10.3390/su12208437>.

Article

Sentinel-2 Satellite Imagery for Agronomic and Quality Variability Assessment of Pistachio (*Pistacia vera* L.)

Enrique Barajas *, Sara Álvarez, Elena Fernández, Sergio Vélez, José Antonio Rubio and Hugo Martín *

Instituto Tecnológico Agrario de Castilla y León. Ctra. Burgos km 119, 47071 Valladolid, Spain; alvmarsa@itacyl.es (S.Á.); ita-feroteel@itacyl.es (E.F.); velmarse@itacyl.es (S.V.); rubcanjo@itacyl.es (J.A.R.)

* Correspondence: enrique.barajasl@itacyl.es (E.B.); marguthu@itacyl.es (H.M.)

Received: 31 July 2020; Accepted: 7 October 2020; Published: 13 October 2020



Abstract: The objective of this work is to evaluate the agronomic, phenological, nutritional quality and organoleptic characteristics of pistachios (*Pistacia vera* L.) based on the NDVI (Normalized Difference Vegetation Index) calculated in the phenological stage of nut filling from Sentinel satellite imagery. Based on this index, three pistachio tree orchards were studied and classified into two levels of vigour: high and low. The results obtained have discriminated the production per tree, which is strongly related to yield. Regarding the nutritional quality parameters, significant differences were not observed between vigour levels, although the most vigorous trees have shown nuts with a higher percentage of fibre and protein. In terms of phenology, there have not been differences between trees of different vigour, only a slight advance of some phenological stages has been observed in several high-vigour trees. Triangular tests have been made successfully to discriminate the origin of the dry nut and the vigour of the trees. In conclusion, for a given nut quality within a given orchard, the NDVI is a good index to classify different areas according to productive capacity and can be useful to apply variable management, irrigation and fertilization according to vigour.

Keywords: Sentinel 2; NDVI; pistachio; vigour; nutritional quality

1. Introduction

In recent years, pistachio (*Pistacia vera* L.) has become one of the most interesting species in the nut sector. The viability of pistachio crops and their agronomic behaviour in a given place is conditioned by the edaphoclimatic conditions of the place [1]. In such a way, the temperature variations in different geographical locations can influence the biochemical processes during the nut development and can influence the nutritional and organoleptic characteristics of the pistachio nuts [2]. Besides, the nutritional quality of the nut is strongly affected by the composition of fatty acids present in the seed [3]. In this sense, some studies affirm that the stability and quality of the nut are greater when the concentration of oleic acid is greater, proposing the amount of iron as a useful parameter for the discrimination of pistachio varieties [4].

Another factor that determines the pistachio nuts quality is the time of harvest [2]. In this sense, it was observed that the sooner the pistachio harvest the higher the contents of potassium, calcium, magnesium, nitrogen and protein but the lower the yield [5]. Other researchers have linked the quality and production of pistachio nuts with the water regime and the rootstock used [6,7].

Moreover, the development of new technologies based on remote sensing allows information about the crops and the land surface to be obtained quickly and accurately [8]. High-resolution images can provide an estimate of the spatial variability of the vigour of many herbaceous and woody crops [9].

The images to calculate Vegetation Indexes can be obtained from various sources, such as UAV, aircraft, satellites, proximal sensing, etc. Moreover, spatial information can be obtained from several satellites, which can be classified into two main groups depending on the cost of the images: free-to-use and paid-to-use satellites [10]. Regarding free-to-use satellites, the Sentinel-2 satellite constellation provides free imagery split in several bands and it is possible to access the satellite data free of charge [11]. Besides, the periodicity of Sentinel satellite images allows to build a time series that includes the entire vegetative crop cycle.

In several fields, remote sensing has been a valuable tool, such as in the evaluation of floods or natural water flows, the determination of the areas burned by fires or the advance of desertification [12–15]. Similarly, in agriculture, the vegetation indices (NDVI, SAVI, ...) obtained from satellite images, with a spatial resolution ranging from 10 m (Sentinel-2) to 30 m (Landsat) or obtained from UAV images whose resolution is at centimetre level (depending on the characteristics of the multispectral camera and the flight height), have been used in the decision-making process in many crops such as wheat, rapeseed, cotton, corn and woody species [16–20]. Specifically, Sentinel satellites can be very useful and they have been used to predict almond yields [21], to discriminate the quality of the walnut based on the vigour of the trees [22], to assess the bloom dynamics of almond orchards [23] and to classify vineyards according to their vigour [24,25].

At present, in the absence of an operational technological sensor that determines quality in situ, and based on past and present experience, the NDVI [26] calculated from detailed multispectral images is the best and most economical alternative for classifying differentiated management units in several woody crops such as vineyard [27] or walnut [22]. Similarly, using this vegetation index, relationships can be established to estimate the water needs in several crops such as almond or pistachio [28].

The objective of this work is to evaluate the agronomic, phenological, nutritional quality and organoleptic characteristics (triangular testing) of pistachio (*Pistacia vera* L.) based on the vigour (high and low) estimated by the vegetation index NDVI (Normalized Difference Vegetation Index) obtained from a Sentinel-2 satellite image, which is free and open access, during the phenological stage of nut filling in three pistachio orchards in 2018.

2. Materials and Methods

The experimental trials are located in three pistachio orchards in Toro (Zamora), Perales (Palencia) and Pozal de Gallinas (Valladolid) in the region of Castilla y León (Spain). The characteristics of the plots are shown in Table 1. The ground-truth data were taken during 2018. All orchards are irrigated periodically during the vegetative cycle in order to avoid the hydric stress of the trees. Each year, a regulatory pruning to control the vegetation has been made in each orchard, leaving the whole amount of flower buds.

Table 1. Characteristics of the orchards.

	Toro	Perales	Pozal de Gallinas
Coordinates	X: 301,985; Y: 4,598,920	X: 368,751; Y: 4,670,402	X: 347,997; Y: 4,577,704
Altitude (m)	740	770	737
Area (ha)	4.2	18.7	12.3
Planting pattern (m)	7 × 5	7 × 6	7 × 6
Planting date	2004	2002	2010
Male cultivar	Peter	Peter	Peter
Cultivar/rootstock	Kerman/Atlántica	Kerman/Cornicabra	Kerman/UCB

The NDVI is an index that allows quantifying the amount of vegetation in an area, as well as its health. It relates the reflected radiation in the red and Near InfraRed (NIR) bands of the electromagnetic spectrum. Its mathematical Equation (1) is the following:

$$\text{NDVI} = (\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED}) \quad (1)$$

To calculate the NDVI, the Equation (2) was adapted to the bands provided by Sentinel 2 satellites: B8 (NIR) with a wavelength of 0.77 to 0.90 micrometres and B4 (RED) with a wavelength of 0.65 to 0.68 micrometres, both with a spatial resolution or pixel size of 10 m.

$$\text{NDVI} = (\text{B8} - \text{B4}) / (\text{B8} + \text{B4}) \quad (2)$$

To perform the classification of the pistachio orchards, two levels of vigour were established based on the NDVI mean values of its pixels calculated from the multispectral images. Free 2018 images were downloaded from the ESA's (European Space Agency) Copernicus project website [29]. These images, obtained from the Sentinel-2A and -2B satellites, were corrected to a level-2A product with ESA's sen2cor algorithm and were filtered manually in order to obtain cloud-free products. As a result, 24 images were assessed for each orchard, between dates 17/01/2020 and 03/11/2020, as it is shown in Figure 1.




Figure 1. Normalized Difference Vegetation Index (NDVI) 2018 images of Pozal de Gallinas orchard. In red, the image chose to carry out the zoning of the pistachio orchards (26 July 2018).

The mean and the standard deviation of the NDVI of the pistachio orchards has been analysed to choose the date from which the zoning was carried out in two vigour classes (Figure 2). According to the evolution of the mean and the standard deviation of the NDVI, a minimum begins at the end of July and continues in the beginning of August (Figure 2b). According to these data, the chosen date was on July 26 because it is when the vegetation of the pistachio trees is more homogeneous. The maximum of the mean NDVI for the orchards is at the phenological state F1 (yellow colouring of the bottom of the nut mesocarp) although a maximum standard deviation has been observed suggesting a large variability of the vegetation at this moment.




Figure 2. Mean (a) and standard deviation (b) of the NDVI in the pistachio orchard of Pozal de Gallinas.

Image and time series analyses were carried out using customized codes written in R statistical program (version 3.6X, R Foundation for Statistical Computing (R Core Team 2019), <https://www.R-project.org/>, Vienna, Austria) and QGIS software (Open Source Geospatial Foundation) version 2.18.13 was used. Finally, images were processed using an unsupervised classification clustering method (k-means), organizing each pistachio orchard into two levels of vigour, high and low, according to their NDVI values (Figure 3).




Figure 3. NDVI classification. (a) Toro, (b) Perales and (c) Pozal de Gallinas orchards. Two vigour levels: high (dark green) and low (light green).

Three trees per vigour were monitored in each experimental trial, establishing an experimental design of three replications per vigour, and three trees as an experimental unit. At harvest time, several variables were measured: bunch weight, number of open, closed and empty nuts per bunch, tree yield, fruit and seed weight, as well as the percentage of open, closed and empty nuts.

The main phenological stages [30] per vigour in each plot were determined (Figure 4):

- D: appearance of clusters between the bracts;
- E: cluster opening;
- F0: reddish ovaries;
- F1: yellow colouring of the bottom of the nut mesocarp;
- F2: yellow mesocarp;
- M: detachment of the nut epicarp.




Figure 4. Main phenological stages corresponding to the appearance of clusters between the bracts (D), cluster opening (E), reddish ovaries (F0), yellow colouring of the bottom of the nut mesocarp (F1), yellow mesocarp (F2) and detachment of the nut epicarp (M).

Several nutritional parameters of a sample of pistachio nuts collected from the studied trees of each vigour were evaluated in the laboratory: grease percentages (gravimetry on soxhlet extraction), carbohydrates (gravimetrically), protein and nitrogen (Dumas combustion method), fibre (enzymatic-gravimetric method), phosphorus (UV-VIS spectrophotometry, after acid digestion by dry route), magnesium and calcium (atomic absorption spectrophotometry, after acid digestion by dry route) and the amount (mg/kg) of iron, zinc and sodium (atomic emission spectrophotometry, after acid digestion by dry route).

Finally, organoleptic tests were carried out in a tasting room equipped with ten individual boxes, according to ISO 8589: 2007 (Figure 5). In compliance with ISO 4120: 2004, a triangular test was carried out to determine if there was a perceptible sensory difference or similarity between samples of two products. The method was a forced-choice procedure and it can be used whether there are differences in several sensory attributes or only in one of them. This test was carried out among the nuts belonging to different vigour trees to find out if the consumer was able to detect differences between the experimental treatments corresponding to high and low vigour.




Figure 5. Standard tasting room where the triangular test (a) and process of the pistachio nut sample (b,c) was carried out.

The statistical analysis was performed using analysis of variance (ANOVA) in Statgraphics Centurion 17.2 software.

3. Results

3.1. Agronomic Study

The parameters related to the cluster have not shown statistical significance differences. The higher values were observed for high vigour, in all the components of the cluster (Figure 6).




Figure 6. Averages corresponding to cluster, nut and yield parameters for the experimental treatments: High Vigour and Low Vigour. Statistical significance level: *, $p < 0.05$.

Likewise, the number of nuts per cluster has been higher in the high vigour, showing 13.8 nuts per cluster compared to the 10 nuts per cluster in the low vigour, although without finding statistically significant differences. It has been observed that the low vigour has presented a greater number of open nuts and a lower number of closed and empty nuts per cluster, showing percentages of 45.5%, 33.4% and 21.1%, respectively, compared to those shown in the high vigour (30.5%, 49.9% and 19.6%, respectively) (Figure 7). The number of open nuts is an important aspect regarding the quality of the nut [1,30].




Figure 7. Averages corresponding to (a) open, closed and empty nut percentage and (b) yield corresponding to open, closed and empty nuts for the experimental treatments: High Vigour and Low Vigour. Statistical significance level: *, $p < 0.05$.

It has been observed that the higher the nut or seed size the less the vigour of the individual trees, although the production of these trees has shown statistically significant differences in favour of the high vigour (Figure 6). It has been observed that the higher the individual vigour of the trees the lower the percentage of open nuts they present, although the yield per hectare is almost 88% higher, which would offset the lower percentage in the number of open nuts in high vigour. Similarly, the production of closed nuts per tree has shown statistical significance differences in favour of high vigour, observing a value of 2.93 kg/tree compared to 0.24 kg/tree of low vigour (Figure 7).

3.2. Phenological Study

The dates of the several phenological stages evaluated have not presented significant differences or lags. Only a slight delay in the F2 phenological stage (yellow mesocarp) was observed in one of the experimental trials (Table 2). The harvest maturity date was determined by evaluating the difficulty to detach the epicarp of the nut, and this is the day of nut collection. In this sense, certain differences have been observed between experimental trials, probably due to the differences in heat hours in the Toro orchard compared to the other orchards, showing a 9-day advance in the harvest maturity date.

Table 2. Date of the main phenological stages [30] depending on the vigour and the location.

Phenological Stage	High Vigour			Low Vigour		
	Toro	Perales	Pozal	Toro	Perales	Pozal
D	May 1th	May 4th	May 1th	May 1th	May 4th	May 1th
E	May 6th	May 9th	May 6th	May 6th	May 9th	May 6th
F0	May 11th	May 16th	May 11th	May 13th	May 16th	May 13th
F1	May 27th	May 29th	May 25th	May 27th	May 29th	May 25th
F2	Jun 25th	Jul 11th	Jun 19th	Jun 22th	Jul 23th	Jun 20th
M	Oct 15th	Oct 24th	Oct 24th	Oct 15th	Oct 24th	Oct 24th

3.3. Nutritional Quality Study

The nutritional and quality parameters of the pistachio nuts have not shown statistically significant differences between different vigour (Figure 8). On one hand, the higher the vigour, the higher the percentages of fibre, protein and nitrogen, and the higher the amount of sodium. On the other hand, the low vigour has shown the highest percentage of humidity, although without being significant. Concerning the rest of the nutritional and quality parameters, no statistically significant differences have been found (Figure 8).




Figure 8. Averages corresponding to the nutritional and quality parameters of the pistachio nut for each experimental treatment: High Vigour and Low Vigour. Statistical significance level: *, $p < 0.05$.

3.4. Triangular Tasting

Regarding the sensory analysis, triangular tests have shown that consumer was able to detect pistachio nuts from different vigour trees at a 95% probability level in a total of 68 trials, and pistachio nuts from different provenances or experimental trials at a 99% probability level in a total of 66 trials (Table 3).

Table 3. Triangular test results for the vigour factor and the provenance factor. Statistical significance level (SL): ns, not significant; *, $p < 0.05$; **, $p < 0.01$.

Factor	Number of Trials	Hits	SL
Vigour (high–low)	68	34	*
Provenance	66	40	**

4. Discussion

On the one hand, the NDVI calculated from the Sentinel-2 satellite image taken on July 26 has delimited two areas of vigour in the phenological stage of nut filling, showing that the vigour of trees is related to the yield. This aspect may allow using the zoning calculated from the vegetation indices (NDVI, SAVI, etc.) to forecast the pistachio harvest and the more complete the time series of raster images (number of images, date of the first image, etc.), the better the harvest forecast will be.

On the other hand, this classification did not discriminate the quality of the nuts since the percentage of open pistachio nuts and the nutritional and quality parameters did not show significant differences

between experimental treatments. However, the higher the vigour of the tree, the higher the percentage of proteins. Therefore, the quality of the pistachio nut is not related to the amount of vegetation on the trees. Besides, research suggests that the nutritional quality of pistachio nuts is affected by the concentration of fatty acids and the amount of iron present in the seed [3,4], although a relationship between these parameters and the vigour of pistachio trees has not been observed.

These results are consistent with those observed in other crops classified using Sentinel-2 satellite NDVI, such as vineyard [24,27,31] or walnuts [22]. In addition, some authors have observed differences in pistachio nut yields due to different NPK fertilization [32], water regime [33,34], the use of male trees [35,36] or different rootstocks [37]. The small differences observed in some parameters may be due to temperature variations between the different geographic locations that influence the biochemical processes during the development of the fruit and the nutritional characteristics of the pistachio [2].

Regarding the dates of the phenological stages, different vigour trees have not shown differences between them, showing that even with such differences in the yields the dates of the phenological stages have been maintained stable. However, some non-significant differences were observed between trees from different geographic locations, probably due to the different accumulation of hot hours. In this sense, the amount of vegetation of the trees does not imply that the vegetative cycle varies. The phenological development of the pistachio orchard being uniform over time. Other authors found differences in some phenological stages due to other factors, such as the variety [36], water regime [38], geographic location [39] or leaf nitrogen foliar applications [40].

Finally, the triangular test showed that the consumer was able to discriminate the origin of the pistachios (different orchards) and, therefore, the vigour of the trees. Pistachio tasters have detected organoleptic differences between nuts from trees of different vigour and trees from different pistachio orchards. It would have been interesting to carry out a descriptive tasting of the pistachio nut and observe what attributes are different depending on the vigour or origin of the pistachio nut.

In this sense, other investigations have managed to discriminate pistachios under different water regimes [34,37].

5. Conclusions

The results obtained show that the vigour of the trees or the amount of vegetation is related to the production per pistachio tree. For this, these results suggest that for a given nut quality, the NDVI is a good index to classify different areas according to productive capacity. The proposed methodology may be interesting to apply to variable management, irrigation and fertilization according to the vigour of the pistachio trees.

It would also be interesting to know the sensory differences of the pistachio nut through descriptive tastings or ordering tastings since the consumer can distinguish nuts from trees of different vigour or origin.

In further studies, it might be interesting to explore the possibility of measuring the leaf area and geopositioning the trees to correlate ground-truth data and Sentinel satellite information, using techniques that have been carried out in other crops [8]. Besides, it would be interesting to combine ground measured data with Sentinel satellite information to forecast other variables such as yields.

Author Contributions: Conceptualization, E.B. and H.M.; methodology, E.B., S.Á., E.F., S.V., J.A.R. and H.M.; formal analysis, E.B. and S.V.; investigation, E.B., S.V. and H.M.; resources, E.B., S.V. and H.M.; data curation, S.Á., E.F. and H.M.; writing—original draft preparation, E.B. and H.M.; writing—review and editing, E.B., S.Á., S.V. and H.M.; visualization, E.B., S.Á., S.V., J.A.R. and H.M.; supervision, E.B., S.Á., S.V. and H.M.; project administration, J.A.R. and H.M.; funding acquisition, J.A.R. and H.M. All authors have read and agreed to the published version of the manuscript.

Funding: This work has been possible thanks to the project “Adaptation and development of new species and varieties of nuts: pistachio, almond and walnut in Castilla y León” which is co-financed by FEADER funds and Junta de Castilla y León (Spain).

Acknowledgments: The authors want to thank the Association of Pistachio Producers of Castilla y León (ASPROPICYL) and the company PISTACYL S.L. for their selfless collaboration in this work.

Conflicts of Interest: The authors declare no conflict of interest.

References


1. Ferguson, L.; Vito, P.; Craig, K. The pistachio tree; botany and physiology and factors that affect yield. In *Pistachio Production Manual*, 4th ed.; Ferguson, L., Ed.; University of California: Davis, CA, USA, 2005; pp. 31–39.
2. Polari, J.J.; Zhang, L.; Ferguson, L.; Maness, N.O.; Wang, S.C. Impact of Microclimate on Fatty Acids and Volatile Terpenes in “Kerman” and “Golden Hills” Pistachio (*Pistacia vera*) Kernels. *J. Food Sci.* **2019**, *84*, 1937–1942. [[CrossRef](#)]
3. Bai, S.H.; Brooks, P.; Gama, R.; Nevenimo, T.; Hannet, G.; Hannet, D.; Randall, B.; Walton, D.; Grant, E.; Wallace, H.M. Nutritional quality of almond, canarium, cashew and pistachio and their oil photooxidative stability. *J. Food Sci. Technol.* **2019**, *56*, 792–798. [[CrossRef](#)]
4. Rabadan, A.; Alvarez-Orti, M.; Gomez, R.; Pardo-Gimenez, A.; Pardo, J.E. Characterization of pistachio oils and defatted flours regarding cultivar and geographic origin. *J. Food Compos. Anal.* **2018**, *71*, 56–64. [[CrossRef](#)]
5. Esmaeilpour, A.; Shakerardekani, A. Effects of early harvest times on nut quality and physiological characteristics of pistachio (*Pistacia vera*) trees. *Fruits* **2018**, *73*, 110–117. [[CrossRef](#)]
6. Memmi, H.; Gijón López, M.C.; Couceiro, J.F.; Pérez López, D. Water stress thresholds for regulated deficit irrigation in pistachio trees: Rootstock influence and effects on yield quality. *Agric. Water Manag.* **2016**, *164*, 58–72. [[CrossRef](#)]
7. Houssem, M.; Couceiro, J.F.; Gijón, C.; Pérez-López, D. Impacts of water stress, environment and rootstock on the diurnal behaviour of stem water potential and leaf conductance in pistachio (*Pistacia vera* L.). *Span. J. Agricul. Res.* **2016**, *14*. [[CrossRef](#)]
8. Krishna, K.R. *Push Button Agriculture: Robotics, Drones, Satellite-Guided Soil and Crop Management*; Apple Academic Press, Inc.: Cambridge, MA, USA; CRC Press: Boca Raton, FL, USA; Taylor & Francis Group: Abingdon, UK, 2016; ISBN 978-1-77188-305-4.
9. Lamb, D.W.; Weedon, M.M.; Bramley, R.G.V. Using remote sensing to predict grape phenolics and colour at harvest in a Cabernet Sauvignon vineyard: Timing observations against vine phenology and optimising image resolution. *Aust. J. Grape Wine Res.* **2008**, *10*, 46–54. [[CrossRef](#)]
10. Vélez, S.; Barajas, E.; Rubio, J.A.; Vacas, R.; Poblete-Echeverría, C. Effect of missing vines on total leaf area determined by NDVI calculated from Sentinel satellite data: Progressive vine removal experiments. *Appl. Sci.* **2020**, *10*, 3612. [[CrossRef](#)]
11. Caballero, I.; Ruiz, J.; Navarro, G. Sentinel-2 satellites provide near-real time evaluation of catastrophic floods in the west Mediterranean. *Water* **2019**, *11*, 2499. [[CrossRef](#)]
12. Sanyal, J.; Lu, X.X. Application of remote sensing in flood management with special reference to monsoon Asia: A review. *Nat. Hazards* **2004**, *33*, 283–301. [[CrossRef](#)]
13. Joyce, K.E.; Belliss, S.E.; Samsonov, S.V.; McNeill, S.J.; Glassey, P.J. A review of the status of satellite remotesensing and image processing techniques for mapping natural hazards and disasters. *Prog. Phys. Geogr.* **2009**, *33*, 183–207. [[CrossRef](#)]
14. Schnebele, E.; Cervone, G. Improving remote sensing flood assessment using volunteered geographical data. *Nat. Hazards Earth Syst. Sci.* **2013**, *13*, 669–677. [[CrossRef](#)]
15. Li, Y.; Martinis, S.; Plank, S.; Ludwig, R. An automatic change detection approach for rapid flood mapping in Sentinel-1 SAR data. *Int. J. Appl. Earth Obs. Geoinf.* **2018**, *73*, 123–135. [[CrossRef](#)]
16. Mercier, A.; Betbeder, J.; Baudry, J.; Le Roux, V.; Spicher, F.; Lacoux, J.; Roger, D.; Hubert-Moy, L. Evaluation of Sentinel-1 & 2 time series for predicting wheat and rapeseed phenological stages. *ISPRS J. Photogramm. Remote Sens.* **2020**, *163*, 231–256. [[CrossRef](#)]
17. Feng, A.; Zhou, J.; Vories, E.D.; Sudduth, K.A.; Zhang, M. Yield estimation in cotton using UAV-based multi-sensor imagery. *Biosyst. Eng.* **2020**, *193*, 101–114. [[CrossRef](#)]
18. Lykhovyd, P. Sweet Corn Yield Simulation Using Normalized Difference Vegetation Index and Leaf Area Index. *J. Ecol. Eng.* **2020**, *21*, 228–236. [[CrossRef](#)]

19. Yang, Y.; Wu, T.; Wang, S.; Li, H. Fractional evergreen forest cover mapping by MODIS time-series FEVC-CV methods at sub-pixel scales. *ISPRS J. Photogramm. Remote Sens.* **2020**, *163*, 272–283. [CrossRef]
20. Vilar, P.; Morais, T.G.; Rodrigues, N.R.; Gama, I.; Monteiro, M.L.; Domingos, T.; Teixeira, R.F.M. Object-Based Classification Approaches for Multitemporal Identification and Monitoring of Pastures in Agroforestry Regions using Multispectral Unmanned Aerial Vehicle Products. *Remote Sens.* **2020**, *12*, 814. [CrossRef]
21. Zhang, Z.; Jin, Y.; Chen, B.; Brown, P. California Almond Yield Prediction at the Orchard Level with a Machine Learning Approach. *Front. Plant Sci.* **2019**, *10*, 809. [CrossRef]
22. Martín, H.; Gutiérrez, M.A.; Vacas, R.; Rubio, J.A.; y Barajas, E. Evaluación de diferentes índices espectrales obtenidos por imágenes de satélite para discriminar la calidad del fruto del nogal en Castilla y León. In Proceedings of the III Symposium Nacional de Ingeniería Hortícola, I Symposium Ibérico de Ingeniería Hortícola SECH. Uso de Drones y Satélites en Agricultura, Lugo, Spain, 21–23 February 2018.
23. Chen, B.; Jin, Y.; Brown, P. An enhanced bloom index for quantifying floral phenology using multi-scale remote sensing observations. *ISPRS J. Photogramm. Remote Sens.* **2019**, *156*, 108–120. [CrossRef]
24. Vélez, S.; Rubio, J.A.; Andrés, M.I.; Barajas, E. Agronomic classification between vineyards ('Verdejo') using NDVI and Sentinel-2 and evaluation of their wines. *Vitis J. Grapevine Res.* **2019**, *58*, 33–38. [CrossRef]
25. Di Gennaro, S.F.; Dainelli, R.; Palliotti, A.; Toscano, P.; Matese, A. Sentinel-2 Validation for Spatial Variability Assessment in Overhead Trellis System Viticulture Versus UAV and Agronomic Data. *Remote Sens.* **2019**, *11*, 2573. [CrossRef]
26. Rouse, J.W., Jr.; Haas, R.H.; Schell, J.A.; Deering, D.W. Monitoring vegetation systems in the Great Plains with ERTS. In Proceedings of the Third ERTS Symposium, NASA SP-351 1. U.S. Government Printing Office, Washington, DC, USA, 10–14 December 1973; pp. 309–317.
27. Martinez-Casasnovas, J.A.; Agelet-Fernandez, J.; Arno, J.; Ramos, M.C. Analysis of vineyard differential management zones and relation to vine development, grape maturity and quality. *Span. J. Agric. Res.* **2012**, *10*, 326–337. [CrossRef]
28. Bellvert, J.; Adeline, K.; Baram, S.; Pierce, L.; Sanden, B.; Smart, D. Monitoring Crop Evapotranspiration and Crop Coefficients over an Almond and Pistachio Orchard Throughout Remote Sensing. *Remote Sens.* **2018**, *10*, 2001. [CrossRef]
29. European Space Agency (ESA). SENTINEL-2 User Handbook ESA Standard Document: 2015. Available online: https://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook (accessed on 18 December 2019).
30. Couceiro, J.F.; Guerrero, J.; Gijón, M.C.; Moriana, A.; Pérez, D.; Rodríguez, M. *El cultivo del Pistacho*, 2nd ed.; Mundiprensa: Madrid, Spain, 2017; p. 772.
31. Santesteban, L.G.; Urretavizcaya, I.; Miranda, C.; Garcia, A.; Royo, J.B. Agronomic significance of the zones defined within vineyards early in the season using NDVI and fruit load information. In Proceedings of the Precision Agriculture '13: Papers Presented at the 9th European Conference on Precision Agriculture, Lleida, Catalonia, Spain, 7–11 July 2013; ISBN 978-90-8686-224-5.
32. Kumar, P.; Sharma, S.K.; Chandel, R.S.; Singh, J.; Kumar, A. Nutrient dynamics in pistachios (*Pistacia vera* L.): The effect of mode of nutrient supply on agronomic performance and alternate-bearing in dry temperate ecosystem. *Sci. Hortic.* **2016**, *210*, 108–121. [CrossRef]
33. Ak, B.E.; Agackesen, N. Some pomological fruit traits and yield of *Pistacia vera* grown under irrigated and unirrigated conditions. *Acta Hortic.* **2006**, *726*, 165–168. [CrossRef]
34. Noguera-Artiaga, L.; Lipan, L.; Vázquez-Araújo, L.; Barber, X.; Pérez-López, D.; Carbonell-Barrachina, A.A. Opinion of Spanish Consumers on Hydrosustainable Pistachios. *J. Food Sci.* **2016**, *81*, 2559–2565. [CrossRef]
35. Ak, B. Effects of different *Pistacia* species pollen on fruit dimension and weight in the Siirt cultivar. *Acta Hortic.* **1998**, *470*, 294–299. [CrossRef]
36. Guerrero, J.; Memmi, H.; Pérez-López, D.; Couceiro, J.F.; Moriana, A.; Martínez, E.; Gijón, M.C. Phenological Behavior of Two New Male Cultivars of Pistachio (*Pistacia vera* L.): "Chaparrillo" and "Guerrero". *Acta Hortic.* **2014**, *1028*, 297–303. [CrossRef]
37. Carbonell-Barrachina, A.A.; Memmi, H.; Noguera-Artiaga, L.; Gijón-López, M.C.; Ciapa, R.; Pérez-López, D. Quality attributes of pistachio nuts as affected by rootstock and deficit irrigation. *J. Sci. Food Agric.* **2015**, *95*, 2866–2873. [CrossRef]

38. Gijón, M.C.; Giménez, C.; Pérez-López, D.; Guerrero, J.; Couceiro, J.F.; Moriana, A. Water relations of pistachio (*Pistacia vera* L.) as affected by phenological stages and water regimes. *Sci. Hortic.* **2011**, *128*, 415–422. [[CrossRef](#)]
39. Avanzato, D.; Meli, M.; Vaccaro, A.; Bevilacqua, D.; Zhivondov, A. Agronomic behaviour of *P. vera* established in non-traditional areas. *Acta Hortic.* **2009**, *825*, 333–340. [[CrossRef](#)]
40. Barone, E.; la Mantia, M.; Marra, F.P.; Motisi, A.; Sottile, F. Manipulation of the vegetative and reproductive cycle of pistachio (*Pistacia vera* L.). *Options Méditerranéennes* **2005**, *63*, 355–364.




© 2020 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).



CAPÍTULO V

CAPÍTULO V. Potential of functional analysis applied to Sentinel-2 time-series to assess relevant agronomic parameters at the within-field level in viticulture.



Aceptado con cambios en “*Computers and electronics in agriculture*” (Elsevier)

<https://www.journals.elsevier.com/computers-and-electronics-in-agriculture>

“Potential of functional analysis applied to Sentinel-2 time-series to assess relevant agronomic parameters at the within-field level in viticulture”. Sergio Vélez, Florian Rançon, Enrique Barajas, Guilhem Brunel, José Antonio Rubio and Bruno Tisseyre.



CAPÍTULO VI

CAPÍTULO VI. Vitis: Biology and Species. Chapter 10. Remote Sensing: In the Digital Viticulture Era.



“Vitis: Biology and Species”. Chapter 10. Remote Sensing: In the Digital Viticulture Era. Sergio Vélez, Enrique Barajas, José A. Rubio, Carlos Poblete-Echeverría and Guillermo F. Olmedo. Nova Science Publishers. ISBN: 978-1-53618-308-5. September 2020.



CAPÍTULO VII

CAPÍTULO VII. Spatio-Temporal Analysis of Satellite Imagery (NDVI) to Identify *Terroir* and Vineyard Yeast Differences according to Appellation of Origin (AOP) and Biogeographic Origin.



J Multidisciplinary
Scientific Journal

“Spatio-Temporal Analysis of Satellite Imagery (NDVI) to Identify *Terroir* and Vineyard Yeast Differences according to Appellation of Origin (AOP) and Biogeographic Origin”. Sergio Vélez, Enrique Barajas, Pilar Blanco, José Antonio Rubio, David Castrillo. J multidisciplinary journal (MDPI). 2021, 4(3), 244-256.

doi: <https://doi.org/10.3390/j4030020>

Article

Spatio-Temporal Analysis of Satellite Imagery (NDVI) to Identify *Terroir* and Vineyard Yeast Differences according to Appellation of Origin (AOP) and Biogeographic Origin

Sergio Vélez ^{1,*} , Enrique Barajas ¹ , Pilar Blanco ², José Antonio Rubio ¹ and David Castrillo ^{2,*} 

¹ Instituto Tecnológico Agrario de Castilla y León (ITACyL), Unidad de Cultivos Leñosos y Hortícolas, 47071 Valladolid, Spain; BarTolEn@itacyl.es (E.B.); rubcanjo@itacyl.es (J.A.R.)

² Estación de Viticultura e Enología de Galicia (EVEGA-AGACAL), Ponte San Clodio s/n, 32428 Leiro-Ourense, Spain; pilar.blanco.camba@xunta.gal

* Correspondence: velmarse@itacyl.es (S.V.); david.castrillo.cachon@xunta.gal (D.C.)

Abstract: Terroir is one of the core concepts associated with wine and presumes that the land from which the grapes are grown, the plant habitat, imparts a unique quality that is specific to that growing site. Additionally, numerous factors can influence yeast diversity, and terroir is among the most relevant. Therefore, it can be interesting to use Remote Sensing tools that help identify and give helpful information about the terroir and key characteristics that define the AOP (Appellation of Origin). In this study, the NDVI (Normalized Difference Vegetation Index) calculated from Landsat 8 imagery was used to perform a spatio-temporal analysis during 2013, 2014, and 2015 of several vineyards belonging to four different AOP in Galicia (Spain). This work shows that it is possible to use Remote Sensing for AOP delimitation. Results suggest: (i) satellite imagery can establish differences in terroir, (ii) the higher the NDVI, the higher the yeast species richness, (iii) the relationship between NDVI, terroir, and yeasts shows a stable trend over the years (Pearson's $r = 0.3894$, $p = 0.0119$).

Keywords: designation of origin; appellation of origin; NDVI; vegetation index; precision viticulture; yeast; biogeography; terroir; *Vitis vinifera* L.; remote sensing



Citation: Vélez, S.; Barajas, E.; Blanco, P.; Rubio, J.A.; Castrillo, D. Spatio-Temporal Analysis of Satellite Imagery (NDVI) to Identify *Terroir* and Vineyard Yeast Differences according to Appellation of Origin (AOP) and Biogeographic Origin. *J* **2021**, *4*, 244–256. <https://doi.org/10.3390/j4030020>

Academic Editor: Lammert Kooistra

Received: 31 May 2021

Accepted: 24 June 2021

Published: 28 June 2021

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Worldwide, the average climatic conditions of wine regions determine, to a large degree, the grape cultivars that can be grown there, while wine production and quality are chiefly influenced by site-specific factors, production practices, and short-term climate variability [1]. These factors can be captured within the terroir definition. *Terroir* (*terruño*, in Spanish) is one of the core concepts associated with wine. It is a French term that describes how the environment, farming practices, crop characteristics, and cultural elements of a place affect grape and wine production, combined in a specific way that cannot be replicated in any other place. This concept is the basis of the French wine *appellation d'origine contrôlée* (AOC) system, which is a model for wine appellation and regulation in France and around the world. It is also known as *Apelación d'Origine Protégée* (AOP, Appellation of Origin) in the European Union, as Designation of Origin (in English), and as *Denominación de Origen* (DO, Denomination of Origin) in Spanish. This system presumes that the land from which the grapes are grown, the plant habitat, imparts a unique quality specific to that growing site [2].

According to European Union regulations, any group of wine producers can apply to establish an AOP by giving reasons and proofs for the request, including full details of the terroir, among others. Terroir seems to play a critical role in the quality of wines, and AOP boundaries are fixed according to geological, topographical, morphological, and agro-pedological criteria. Terroir affects the chromatic characteristics of wines and clearly affects the phenolic composition [3]. Furthermore, tasting confirms, without doubt, these

differences according to the nature of the terroir [4]. Therefore, it could be interesting to develop and use tools that help to identify and give helpful information about the terroir and key characteristics that define the AOP, not only for the European production model, mainly based on Appellations of Origin, but also for the emerging wine grape-producing countries, whose production is much more liberalized [5].

Remote sensing can be a valuable tool to achieve this goal, since it allows obtaining information quickly, accurately, objectively, and non-destructively [6]. Algebraic combinations of spectral information bands are helpful, such as the NDVI (Normalized Difference Vegetation Index) [7], which has proved to be a valuable tool in precision viticulture to classify vineyards according to their characteristics [8], monitor table grape quality characteristics [9], differentiate zones with respect to biomass, vine water status, and fruit and wine character [10], or estimate different specific zones according to grape maturity and quality parameters [11]. The NDVI has also been used to assess other crop parameters, including LAI [12], amount of vegetation [13], and even fruit quality parameters such as phenols [14].

Imagery can be obtained from various sources, such as UAV (unmanned aerial vehicle), aircraft, satellites, or proximal sensing. Each approach has its advantages and disadvantages. Aiming to work at the AOP scale level, satellite information can be handy because it can capture a large image of the entire area at once, so vineyards can be compared simultaneously. Moreover, sensors mounted on satellites usually have a better spectral and radiometric resolution and, as they are not usually repairable once launched, they have better electronics and redundancy [15]. Even a breakpoint was placed slightly above 5 ha, meaning that satellite images may be more convenient above such scale size [16]. Furthermore, some satellite images can be downloaded for free, such as Landsat 8 imagery, equipped with the Operational Land Imager (OLI) instrument. OLI is a visible and near-infrared (VNIR) multispectral sensor that operates from 400 to 2500 nm and provides reflectance products with a spatial resolution of 30 m and a revisit time of 16 days [17].

As previously stated, terroir gives wines their complexity [18]. It also affects yeast diversity by linking yeasts to a geographical area [19,20]; therefore, it is interesting to properly monitor the variables that compose terroir, such as yeast diversity, to improve wine quality [21]. The influence of a greater diversity of indigenous yeasts, especially non-*Saccharomyces*, has been amply demonstrated [22,23], and these biogeographical patterns of indigenous yeasts, specific to a given region, can improve the chemical–sensory characteristics of wines [20,24]. However, few studies have developed and related the concept of microbial terroir or yeast terroir to other disciplines, since this concept is controversial because it is still unclear how microbes contribute to terroir [25].

The oenological potential of non-*Saccharomyces* autochthonous yeasts has been reported, comparing yeast diversity in musts from organic and conventional production in four Denominations of Origin (AOP) from Galicia [26,27]. However, to our knowledge, this is the first work that aims to identify a spatio-temporal relationship between NDVI calculated from satellite imagery, terroir, and, more specifically, the biogeographic patterns of yeasts in vineyards of the northwest Iberian Peninsula.

The objective of the present study was to analyze the potential use of satellite multispectral imagery to detect differences in terroir and yeast population due to AOP according to NDVI variations, studying: (i) if satellite imagery can establish differences in terroir, (ii) the relationship between NDVI and yeast species richness, (iii) the temporal stability over the years between NDVI, terroir, and yeasts. Considering the inherent relationship between the terroir and the AOP, a spatio-temporal analysis was carried out between 14 vineyards belonging to 4 different AOP in Galicia (Spain). Several open-access multispectral images obtained from the Landsat satellite in 2013, 2014, and 2015 were used to calculate the NDVI (Normalized Difference Vegetation Index), which provides information about the vegetation within the vineyards, including vine canopy.

2. Materials and Methods

2.1. Satellite Imagery

Free-cloud Landsat 8 images from the study area (Figure 1) of 2013, 2014, and 2015 were downloaded and atmospherically corrected using the DOS1 algorithm. The selected months were July and August due to the proximity of veraison since, at this phenological stage (or even after), the relationship between leaf area and NDVI is greater [14,28]. Unfortunately, the image of august 2014 had to be changed to the immediately previous ones (25 July 2014) due to clouds.



Figure 1. Location of the Landsat imagery and commercial vineyards in Galicia (Spain).

The NDVI was used to perform the spatio-temporal analysis. NDVI is an index that allows quantifying the amount of vegetation of an area and its health. It relates the reflected radiation in the Red and Near-Infrared (NIR) bands of the electromagnetic spectrum (1).

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)} \quad (1)$$

2.2. Vineyards

Grapes were harvested from 14 commercial vineyards planted with representative grapevine cultivars within 4 different AOP during 3 consecutive years (2013, 2014, 2015) in Galicia (Figures 1 and 2). Table 1 shows the characteristics of the vineyards and grapevine cultivars used in this study. The vineyards have different characteristics and were under two different farming systems: organic and conventional. There were one organic and one conventional vineyard per AOP and cultivar. Regular phytosanitary treatments were used depending on rainfall and management system: copper and plant extract treatments in organic, without herbicides, and traditional fungicides and herbicides in conventional management, in both cases managed according to each AOP protocol and legislation in force. Regarding soil and canopy management, there was non-irrigated vegetation cover in all vineyards, except in Ribeira Sacra, with adventitious vegetation without mowing, vertical trellis training system in Monterrei and Ribeiro, no vegetation management in Ribeira Sacra, and pergola/overhead trellising in Rías Baixas.

In addition, climate data were collected from the closest weather station to each vineyard during the three years of the study. The average values for the three-year study for monthly average temperature (T), monthly average rainfall (R), monthly average wind speed (WS), and monthly average relative humidity (RH) were 14.40 °C, 242.67 L/mm², 3.08 m/s, and 77.00% for Ribeiro; 14.93 °C, 331.67 L/m², 6.78 m/s, 77.33% for Rias Baixas; 13.67 °C, 225.00 L/m², 5.82 m/s, 79.00% for Ribeira Sacra; 12.83 °C, 162.33 L/m², 4.88 m/s, 77.67% for Monterrei. The weather information can be found on the web service of the

Meteorological Observation and Prediction Unit of Galicia (<https://www.meteogalicia.gal/web/inicio.action>, accessed on 28 May 2021).




Figure 2. Commercial vineyards. Codes are shown in Table 1. Scales are different to ease visualization.

Table 1. Characteristics of vineyards and grapevine cultivars used in this study. Average annual rainfall during the three years of the study, obtained from the closest weather station to each vineyard (MeteoGalicia). AOP: Appellation of Origin.

AOP	Cultivar	Code	Coordinates	Elevation (m)	Average Annual Rainfall (L/m ²) 2013-2014-2015	Row Orientation
Monterrei	Treixadura	Mo-Trx	41°52'11.9" N, 7°25'49.7" W 41°52'12.8" N, 7°25'54.5" W	406 402	787-928-595	N-S E-W
	Mencía	Mo-Men	41°52'11.0" N, 7°25'51.9" W 41°52'12.5" N, 7°25'56.9" W	404 399		N-S E-W
Ribeiro	Brancellao	Ri-Bra	42°19'24.8" N, 8°6'7.8" W 42°19'22.3" N, 8°5'51.7" W	270 290	1211-1351-752	E-W N-S
	Treixadura	Ri-Trx	42°19'27.6" N, 8°6'2.0" W 42°19'22.0" N, 8°5'52.4" W	278 289		E-W N-S
Ribeira Sacra	Mencía	RS-Men	42°34'11.5" N, 7°43'3.4" W 42°34'11.4" N, 7°43'3.5" W	243 244	1075-1197-719	NE-SW NE-SW
Rías Baixas	Albariño	RB-Alb	42°5'47.9" N, 8°21'18.1" W 42°5'46.8" N, 8°21'16.9" W	74 72	1489-1649-1071	N-S N-S
	Treixadura	RB-Trx	42°5'48.2" N, 8°21'15.1" W 42°5'46.2" N, 8°21'17.7" W	75 71		E-W N-S

2.3. Sample Processing and Yeast Isolation

A total of 42 samples per year were collected and processed. The obtained must (grape juice) was separated for different analyses, including isolation and yeast diversity identification. The materials and methods used for sample processing and yeast identification at the species level consisted of PCR amplification of the 5.8S rRNA gene and the ITS1 and ITS2 spacers, and sequencing of the D1/D2 region of 26S rDNA gene was used to confirm yeast identity, as described in Castrillo et al. [27].

2.4. Statistical and Data Analysis

Differences in NDVI and yeast population due to AOPs, production system, cultivars, and years were tested using one-way and two-way Bray-Curtis PERMANOVA. In addition, Principal Component Analysis (PCA) and Two-block Partial Least squares (TB-PLS) were carried out to separate richness of yeast species (S) and NDVI samples according to AOPs, production systems, cultivars, and years. Finally, Canonical Correlation Analysis (CCA) and a bilateral Pearson correlation were carried out to evaluate the correlation between NDVI and yeast species richness (S).

Additionally, a CCA was performed to determine the influence of terroir on NDVI and yeasts during the years of the study concerning the different AOPs. Several factors that characterize terroir were assessed in the analysis: monthly average temperature (T); canopy (C); monthly average rainfall (R); monthly average wind speed (WS); soil management (SM); monthly average relative humidity (RH); altitude (A); orientation.

All image, statistical, and data analyses were carried out using customized codes written in R statistical program (version 3.6.X, R Foundation for Statistical Computing, R Core Team 2019, <https://www.R-project.org/>, accessed on 21 May 2021, Vienna, Austria), Python (version 3.9.X, Python Software Foundation, <https://www.python.org/>, accessed on 21 May 2021, Wilmington, DE, USA), and PAST software (version 4.04, Hammer & Harper, Oslo, Norway).

3. Results

Table 2 shows NDVI values calculated using free-cloud Landsat 8 images in the chosen dates. Figure 3 shows that NDVI was relatively stable over the years in all vineyards, although the trend shows that maximum values were reached during 2014 and minimum values during 2015, except in Ribeiro. When analyzing NDVI per AOP, Rias Baixas had the highest values during the three years, with maximum values of 0.49 and minimum values of 0.24, followed by Ribeira Sacra AOP, with 0.45 and 0.24, respectively. On the other hand, the lowest NDVI values were in Monterrei AOP, with maximum and minimum values of 0.25 and 0.13, followed by Ribeiro AOP, with values of 0.32 and 0.19, respectively. In addition, the NDVI ranged from a maximum of 0.49 to a minimum of 0.13 for all AOPs and years. Each year, the maximum and minimum values were similar: for 2015, between 0.43 and 0.13, for 2014, between 0.49 and 0.14, and for 2013, between 0.48 and 0.14.

Table 2. NDVI (Normalized Difference Vegetation Index) values calculated using free-cloud Landsat 8 images from the study area taken in 2013, 2014, and 2015. July and August were selected due to the proximity of veraison.

Vineyard	6 July 2013	23 August 2013	9 July 2014	25 July 2014	12 July 2015	29 August 2015
Mo-Men-A	0.25	0.22	0.22	0.24	0.23	0.24
Mo-Men-B	0.17	0.14	0.14	0.15	0.15	0.13
Mo-Trx-A	0.23	0.20	0.19	0.22	0.20	0.23
Mo-Trx-B	0.23	0.18	0.23	0.20	0.20	0.17
RB-Alb-A	0.36	0.26	0.39	0.36	0.36	0.32
RB-Alb-B	0.27	0.25	0.30	0.26	0.25	0.24
RB-Trx-A	0.48	0.38	0.49	0.48	0.43	0.41
RB-Trx-B	0.39	0.36	0.46	0.47	0.37	0.37
Ri-Bra-A	0.26	0.24	0.31	0.29	0.31	0.26
Ri-Bra-B	0.25	0.19	0.23	0.25	0.26	0.22
Ri-Trx-A	0.29	0.24	0.32	0.29	0.29	0.27
Ri-Trx-B	0.23	0.23	0.25	0.25	0.24	0.22
RS-Men-A	0.31	0.29	0.33	0.31	0.31	0.24
RS-Men-B	0.39	0.35	0.45	0.38	0.39	0.31




Figure 3. NDVI values per AOP calculated using Landsat imagery close to veraison. Years 2013, 2014, and 2015.

The statistical analysis confirmed the previous analysis. PERMANOVA was used to evaluate differences in NDVI between years, cultivars, AOPs, and culture systems. The NDVI only showed significant differences between AOPs ($p = 0.0040$, $F = 7.2530$) but not between years ($p = 0.3353$, $F = 1.374$), farming systems ($p = 0.4865$, $F = 0.5193$), and cultivars ($p = 0.9309$, $F = 0.2096$). In addition, significant differences were found in the RB-Mo pairwise ($p = 0.0311$, $F = 13.2700$), and in the Mo-Ri pairwise ($p = 0.0208$, $F = 5.2270$). In RS-Mo pairwise, the values were $F = 9.621$ at $p = 0.0637$. However, in the RS-RB pairwise, no significant differences were found, with the lowest $F = 0.1310$ and the highest $p = 0.7971$. Therefore, this paper focused on the AOPs.

Figure 4 shows a different NDVI and a different yeast species richness for each AOP, being in both cases higher in the Rías Baixas and Ribeira Sacra AOPs than in the Ribeiro and Monterrei AOPs for each vintage during the three years.




Figure 4. Species richness and NDVI in the four AOPs during 2013, 2014, and 2015. AOPs: Mo: Monterrei, Ri: Ribeiro, RS: Ribeira Sacra, RB: Rías Baixas.

PERMANOVA was also used to assess differences in yeast population (species richness) between campaigns, cultivars, AOPs and farming systems. Species richness presented significant differences among AOPs [27,29]. Regarding yeast diversity in musts, in terms of species richness, different yeast species were identified during the three years of study, distributed as shown in Figure 4. A PCA of NDVI of the vineyards (Figure 5) was used to analyze both data sets separately between the different AOPs, considering all grapevine cultivars, farming systems, and years. Furthermore, Axis1 separated Rías Baixas and Ribeira Sacra from Ribeiro and Monterrei AOP samples on both sides of the Y-axis. However, the separation between NDVI values was not clear, considering the different farming systems and cultivars.




Figure 5. PCA of NDVI during 2013, 2014, and 2015 in vineyards planted with four representative cultivars within four Galician AOPs. AOPs: Mo: Monterrei, Ri: Ribeiro, RS: Ribeira Sacra, RB: Rías Baixas; grape cultivars (in green: organic, in black: conventional): Trx: Treixadura, Alb: Albariño, Bra: Brancellao, Men: Mencía.

To study if there was a significant correlation between NDVI and species richness in the vineyards of the different AOPs, a CCA (Figure 6A), a TB-PLS (Figure 6B), and a Pearson's correlation test were performed on both data sets combined. The TB-PLS also separated

AOPs like PCA (Figure 5: NDVI data set separately). Regarding the CCA, the NDVI triplot was not grouped by year, but the NDVI values of each year were grouped closely, pointing towards the Rías Baixas AOP and the 2015 and 2014 quadrats. Accordingly, taking the whole data set over the three years, Pearson's linear correlation test results showed significant differences ($p = 0.0119$) in the correlation NDVI-S ($r = 0.3894$). Furthermore, this correlation between NDVI and species richness increased to a value of $r = 0.6804$ ($p = 0.0105$) when comparing the 2014 data. However, no significant differences in Pearson's linear correlation were found in 2013 and 2015 separately, although, in the latter year, the Pearson's r value was 0.4903, and the p -value was remarkably close to significance ($p = 0.0751$).




Figure 6. CCA (A) and TB-PLS (B) of the correlation between NDVI and regional yeast species diversity in the four AOPs during the three consecutive years examined. AOPs: Mo: Monterrei, Ri: Ribeiro, RS: Ribeira Sacra, RB: Rías Baixas.

Finally, to further assess the influence of terroir on NDVI for each year concerning the different AOPs, we performed a CCA of the influence of several factors that characterize terroir, such as climatic factors, altitude, orientation, canopy, and soil management on the NDVI for each year in relation to the different AOPs during the years of the study (Figure 7). The results showed the factors that most influenced or presented the highest correlation between NDVI and species richness were temperature (T) and rainfall (R), as the triplot of these factors point to 2014 and RB (year and AOP with the highest NDVI) and S15, with 2015 and BR the year and the DO showing the highest species richness.




Figure 7. CCA of the influence of climatic factors, altitude, orientation, canopy, and soil management on the NDVI concerning the different AOPs during the three consecutive years examined. Factors: T, monthly average temperature; C canopy; R, monthly average rainfall; WS, monthly average wind speed; SM, soil management; RH, monthly average relative humidity; A, altitude; NS, north–south orientation; EW, east–west orientation; NESW, northeast–southwest orientation. S13, S14, and S15: yeast species richness in 2013, 2014, and 2015, respectively.

4. Discussion

Firstly, the TB-PLS (Figure 6B) confirmed the separation between AOPs determined in the PCA (Figure 5) with identical biogeographical separation by pairwise RS–RB and Mo–Ri. Besides, a correlation between NDVI and S was confirmed, since the NDVI of the three years in the CCA triplot pointed to the year with higher species richness (2015, together with 2014) and to the AOP with a higher S (Rías Baixas AOP), without the need to use the vintage variable. Consequently, Pearson’s correlation, which establishes not only if there exists a correlation (at $p < 0.05$) but also a measure of this correlation according to the r value, showed a moderate and positive correlation between NDVI and species richness for the whole data set ($r = 0.3894$, $p = 0.0119$). Furthermore, Figure 7 results showed that, relative to NDVI and yeast species richness, the most influential terroir factors studied in this research were temperature (T) and rainfall (R). It was not surprising, since these factors increase vegetation and greenness, which affects the NDVI [13], and these factors are optimal for the development of yeasts as well [19]. Additionally, it is worth noticing that there is a clear separation between AOPs.

Secondly, to explore the temporal stability in the relationship between NDVI and yeasts, each year data were analyzed separately. There was a good and positive correlation in 2014 ($r = 0.6804$, $p = 0.0105$), the year of the highest rainfall (Table 1). Although no significant differences were found in 2013 and 2015, the r value was high, and the p -value close to significance ($r = 0.4903$, $p = 0.0751$ in 2015). Furthermore, Figures 4 and 6A seem to reveal a stable trend each year, showing that the higher the NDVI value, the higher the yeast species richness, except for the Ribeiro samples in 2013 and 2014. This result can be explained since the NDVI represents the vegetative development of a specific group of grapevines within each pixel [13] and, as well as the NDVI, yeasts are affected by factors such as human intervention [30] or variations in groundcover vegetation and soil [31]. Moreover, plant growth and development depend on the terroir, i.e., the plant environment, linked to different factors such as soil, crop management, climate, and others. This fact is already included in the European legislation in force [32], showing that plant growth and development within an AOP (and therefore, the quality and characteristics of the grapes) are exclusively due to a particular geographical environment with its inherent natural and human factors and depend on a specific place, region, or country. Therefore, it is reasonable to suggest that (i) NDVI can identify changes in yeasts species, since a larger leaf surface could generate a microclimate or the most appropriate conditions in the stages of higher

yeast proliferation due to several factors such as the greater presence of birds and insect vectors, a better regulation and conservation of optimal temperature and humidity, shading or healthier vegetation, air-wind passage, and machinery [19,33–35] and (ii) these changes have an effect on terroir since microbial populations are part of it [19–21].

Additionally, it must be noted that vineyards are different and can present different characteristics such as groundcover vegetation or more soil proportion that affect the NDVI values, but also the vegetation and characteristics within the pixel area and, therefore, the plant environment and yeast population [36], being consistent with the central hypothesis of the study. For example, RS and RB had the highest S and NDVI values, although for totally different reasons: RS has adventitious vegetation, and the grapevines are isolated without trellising, whereas the grapevines in RB are trained using overhead trellis and cover almost the whole area. In pairwise RS–RB, the PERMANOVA test of the NDVI found no significant differences, which statistically supports this conclusion.

Furthermore, higher species richness was found in Rías Baixas and Ribeira Sacra, the AOPs with the highest NDVI values (Figure 4). The separation between AOPs in the PCA and the PLS grouped the samples in the pairwise RB–RS, and Mo–Ri reinforced the biogeographical approach or differentiation of the Galician terroir. These findings are consistent with what has already been reported in previous works, which showed the different distribution of yeasts in the four AOPs in the same vineyards [27,29], but they also add a correlation between NDVI (terroir) and yeasts. This result is important since the contribution of the microbiota in defining terroir is currently in the spotlight of scientific research due to the abundance, equilibrium, and predominance of certain yeast species during the fermentation are essential [37]. Furthermore, the association of certain species with specific conditions such as farming systems or regions, and even beyond anthropogenic factors, has also been studied by other authors [30,38–42].

Finally, it is interesting to note that although the NDVI varies from year to year, the difference between vineyards remains relatively constant (Figure 3); therefore, NDVI seems to be a stable factor over time. This feature is critical for developing a valuable Remote Sensing tool for monitoring and defining parameters related to terroir [43], such as AOP or yeast level.

Other authors have reported the presence of regionally differentiated communities of yeasts associated with grapes and terroir and the importance of microbial populations for the regional identity of wine [44], and our results support the existence of biogeographical patterns in yeast populations linked to terroir factors implicit in the NDVI (such as climate, soils, or agronomic practices of each region) as a regional discriminator capable of providing unique quality and typicity to wines [20,24,37,44,45]. Therefore, the importance of predicting and better understanding the existence of regionally differentiated communities of yeasts associated with grapes and terroir and the possible existence of a microbial terroir warrant further research and support the need for the present research.

5. Conclusions

The main objective of this work was to analyze the potential use of spatio-temporal analysis of satellite multispectral imagery to detect differences in terroir and yeast population due to AOP according to NDVI variations. The results suggest that it is possible to use Remote Sensing for AOP delimitation, showing that: (i) satellite imagery can establish differences in terroir and can help to predict it at yeast species richness level, (ii) the higher the NDVI, the higher the yeast species richness during the same year, probably linked to the a higher vegetation in the pixel area, and (iii) although there was no significance in the differences in the years, the relationship between NDVI, terroir, and yeasts seems to show a stable trend over the years. In addition, the most influential terroir factors regarding NDVI and species richness were temperature and rainfall. This study is valuable, since terroir affects grapevines and wine differentiation and characterization, so it is worth analyzing these factors using new technologies.

Although the results are promising, it is necessary to validate these results in more vineyards within each AOP. Furthermore, it might be worthwhile to analyze whether these results can be extended to other AOP in Spain, Europe, or worldwide. In further studies, it might be interesting to explore the potential of other satellite imagery sources such as Sentinel-2, the use of other vegetation indices that include a background adjustment factor, such as SAVI, or even develop new indexes that help to classify AOP or yeast characteristics.

Author Contributions: Conceptualization, S.V. and D.C.; Data curation, S.V. and D.C.; Formal analysis, S.V. and D.C.; Funding acquisition, E.B., P.B., and J.A.R.; Investigation, S.V. and D.C.; Methodology, S.V. and D.C.; Project administration, P.B. and D.C.; Resources, S.V., E.B., P.B., and D.C.; Software, S.V. and D.C.; Supervision, S.V., E.B., P.B., J.A.R., and D.C.; Validation, S.V. and D.C.; Visualization, S.V. and D.C.; Writing—original draft, S.V. and D.C.; Writing—review & editing, S.V., E.B., P.B., J.A.R., and D.C. All authors have read and agreed to the published version of the manuscript.

Funding: This work has been made possible thanks to the economic support of Junta de Castilla y León (Spain), Instituto Tecnológico Agrario de Castilla y León (ITACyL), and Xunta de Galicia (Axencia Galega da Calidade Alimentaria), projects INIA RTA2014-00077-C02 and RTA2012-00021-C03-01, co-financed with FEDER funds (European Regional Development Fund). SV and DC thank INIA and European Social Fund for their FPI predoctoral contracts FPI-INIA2016-017 and FPI-INIA2014-32, respectively.

Acknowledgments: We would like to thank the producers: Esther Teixeira Lemos, Roberto Regal, Cooperativa Cume do Avia, Víctor Diéguez, Begoña Troncoso, María del Carmen Álvarez, José Luis Mateo and José dos Santos Diz, for allowing us to collect samples from their vineyards.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Jones, G.V.; Hellman, E. Site Assessment. In *Oregon Viticulture*, 5th ed.; Hellman, E., Ed.; Oregon State University Press: Corvallis, OR, USA, 2003; pp. 44–50.
2. Robinson, J. *The Oxford Companion to Wine*; Oxford University Press (OUP): Oxford, UK, 2006; pp. 693–695.
3. Cosme, F.; Vilela, A.; Moreira, L.; Moura, C.; Enríquez, J.; Filipe-Ribeiro, L.; Nunes, F. Terroir Effect on the Phenolic Composition and Chromatic Characteristics of Mencía/Jaen Monovarietal Wines: Bierzo D.O. (Spain) and Dão D.O. (Portugal). *Molecules* **2020**, *25*, 6008. [[CrossRef](#)] [[PubMed](#)]
4. Seguin, G. ‘Terroirs’ and pedology of wine growing. *Cell. Mol. Life Sci.* **1986**, *42*, 861–873. [[CrossRef](#)]
5. Vivas, C.; Sousa, A. La globalización en el sector del vino: Nuevo mundo, viejo mundo y Portugal. In *XXVII AEDEM Annual Meeting*; ESIC Editorial: Huelva, Spain, 2013.
6. Krishna, K.R. *Push Button Agriculture: Robotics, Drones, Satellite-Guided Soil and Crop Management*; Apple Academic Press: Palm Bay, FL, USA; CRC Press: Boca Raton, FL, USA; Taylor & Francis Group: Milton Park, UK, 2016; ISBN 13978-1-77188-305-4.
7. Rouse, J.W., Jr.; Haas, R.H.; Schell, J.A.; Deering, D.W. *Monitoring Vegetation Systems in the Great Plains with ERTS*; NASA: Washington, DC, USA, 1973.
8. Vélez, S.; Rubio, J.A.; Andrés, M.I.; Barajas, E. Agronomic classification between vineyards (‘Verdejo’) using NDVI and Sen-tinel-2 and evaluation of their wines. *Vitis J. Grapevine Res.* **2019**, *58*, 33–38. [[CrossRef](#)]
9. Anastasiou, E.; Balafoutis, A.; Darra, N.; Psiroukis, V.; Biniari, A.; Xanthopoulos, G.; Fountas, S. Satellite and Proximal Sensing to Estimate the Yield and Quality of Table Grapes. *Agriculture* **2018**, *8*, 94. [[CrossRef](#)]
10. Johnson, L.F.; Bosch, D.F.; Williams, D.C.; Lobitz, B.M. Remote sensing of vineyard management zones: Implications for wine quality. *Appl. Eng. Agric.* **2001**, *17*, 557–560. [[CrossRef](#)]
11. Martinez-Casasnovas, J.A.; Agelet-Fernandez, J.; Arnó, J.; Ramos, M.C. Analysis of vineyard differential management zones and relation to vine development, grape maturity and quality. *Span. J. Agric. Res.* **2012**, *10*, 326. [[CrossRef](#)]
12. Johnson, L.F. Temporal stability of an NDVI-LAI relationship in a Napa Valley vineyard. *Aust. J. Grape Wine Res.* **2003**, *9*, 96–101. [[CrossRef](#)]
13. Vélez, S.; Barajas, E.; Rubio, J.A.; Vacas, R.; Poblete-Echeverría, C. Effect of Missing Vines on Total Leaf Area Determined by NDVI Calculated from Sentinel Satellite Data: Progressive Vine Removal Experiments. *Appl. Sci.* **2020**, *10*, 3612. [[CrossRef](#)]
14. Lamb, D.; Weedon, M.; Bramley, R. Using remote sensing to predict grape phenolics and colour at harvest in a Cabernet Sauvignon vineyard: Timing observations against vine phenology and optimising image resolution. *Aust. J. Grape Wine Res.* **2004**, *10*, 46–54. [[CrossRef](#)]
15. Vélez, S.; Barajas, E.; Rubio, J.A.; Poblete-Echeverría, C.; Olmedo, G.F. Chapter 10. Remote Sensing: In the Digital Viticulture Era. In *Vitis: Biology and Species*; Nova Publishers: Hauppauge, NY, USA, 2020; ISBN 978-1-53618-308-5.

16. Matese, A.; Toscano, P.; Di Gennaro, S.F.; Genesio, L.; Vaccari, F.P.; Primicerio, J.; Belli, C.; Zaldei, A.; Bianconi, R.; Gioli, B. Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture. *Remote. Sens.* **2015**, *7*, 2971–2990. [CrossRef]
17. Markham, B.; Storey, J.; Morfitt, R. Landsat-8 Sensor Characterization and Calibration. *Remote. Sens.* **2015**, *7*, 2279–2282. [CrossRef]
18. Hall, C.M.; Mitchell, R. *Wine Marketing: A Practical Guide*, 1st ed.; Elsevier: Amsterdam, The Netherlands; Boston, MA, USA, 2008; ISBN 978-0-7506-5420-3.
19. Barata, A.; Malfeito-Ferreira, M.; Loureiro, V. The microbial ecology of wine grape berries. *Int. J. Food Microbiol.* **2012**, *153*, 243–259. [CrossRef] [PubMed]
20. Bokulich, N.A.; Thorngate, J.H.; Richardson, P.M.; Mills, D.A. PNAS Plus: From the Cover: Microbial biogeography of wine grapes is conditioned by cultivar, vintage, and climate. *Proc. Natl. Acad. Sci. USA* **2014**, *111*, E139–E148. [CrossRef]
21. Ribéreau-Gayon, P.; Dubourdieu, D.; Donèche, B. *Handbook of Enology*, 2nd ed.; John Wiley: Chichester, UK; Hoboken, NJ, USA, 2006; ISBN 978-0-470-01034-1.
22. Ciani, M.; Comitini, F.; Mannazzu, I.; Domizio, P. Controlled mixed culture fermentation: A new perspective on the use of non-Saccharomyces yeasts in winemaking. *FEMS Yeast Res.* **2010**, *10*, 123–133. [CrossRef] [PubMed]
23. Tofalo, R.; Patrignani, F.; Lanciotti, R.; Perpetuini, G.; Schirone, M.; Di Gianvito, P.; Pizzoni, D.; Arfelli, G.; Suzzi, G. Aroma profile of Montepulciano d'Abruzzo wine fermented by single and co-culture starters of autochthonous Saccharomyces and Non-Saccharomyces yeasts. *Front. Microbiol.* **2016**, *7*, 610. [CrossRef]
24. Bokulich, N.A.; Collins, T.S.; Masarweh, C.; Allen, G.; Heymann, H.; Ebeler, S.E.; Mills, D.A. Associations among Wine Grape Microbiome, Metabolome, and Fermentation Behavior Suggest Microbial Contribution to Regional Wine Characteristics. *mBio* **2016**, *7*, e00631-16. [CrossRef]
25. Alexandre, H. Wine Yeast Terroir: Separating the Wheat from the Chaff—For an Open Debate. *Microorganisms* **2020**, *8*, 787. [CrossRef]
26. Castrillo, D.; Rabuñal, E.; Neira, N.; Blanco, P. Oenological potential of non-Saccharomyces yeasts to mitigate effects of climate change in winemaking: Impact on aroma and sensory profiles of Treixadura wines. *FEMS Yeast Res.* **2019**, *19*, foz065. [CrossRef]
27. Castrillo, D.; Rabuñal, E.; Neira, N.; Blanco, P. Yeast diversity on grapes from Galicia, NW Spain: Biogeographical patterns and the influence of the farming system. *OENO One* **2018**, *53*. [CrossRef]
28. Hall, A.; Lamb, D.; Holzapfel, B.P.; Louis, J.P. Within-season temporal variation in correlations between vineyard canopy and winegrape composition and yield. *Precis. Agric.* **2010**, *12*, 103–117. [CrossRef]
29. Castrillo Cachón David (2018) Study of Yeast Diversity in Organic and Conventional Grapes from GALICIA: Biogeographic Patterns and Influence on the Chemical and Sensory Characteristics of Wine. Available online: <https://www.educacion.gob.es/teseo/imprimirFicheroTesis.do?idFichero=ifNKO0Hc9YT%3D> (accessed on 25 June 2021).
30. Drumonde-Neves, J.; Franco-Duarte, R.; Lima, T.; Schuller, D.; Pais, C. Yeast Biodiversity in Vineyard Environments Is Increased by Human Intervention. *PLoS ONE* **2016**, *11*, e0160579. [CrossRef]
31. Botha, A. Yeasts in Soil. In *Biodiversity and Ecophysiology of Yeasts*; Springer Science and Business Media LLC: Berlin/Heidelberg, Germany, 2006; pp. 221–240.
32. Consolidated text: Regulation (EU) No 1151/2012 of the European Parliament and of the Council of 21 November 2012 on Quality Schemes for Agricultural Products and Foodstuffs. Available online: <http://data.europa.eu/eli/reg/2012/1151/2019-12-14> (accessed on 14 June 2021).
33. Francesca, N.; Canale, D.E.; Settanni, L.; Moschetti, G. Dissemination of wine-related yeasts by migratory birds. *Environ. Microbiol. Rep.* **2011**, *4*, 105–112. [CrossRef]
34. Schuller, D.; Alves, H.; Dequin, S.; Casal, M. Ecological survey of Saccharomyces cerevisiae strains from vineyards in the Vinho Verde Region of Portugal. *FEMS Microbiol. Ecol.* **2005**, *51*, 167–177. [CrossRef]
35. Mortimer, R.; Polsinelli, M. On the origins of wine yeast. *Res. Microbiol.* **1999**, *150*, 199–204. [CrossRef]
36. Ramírez, M.; López-Piñeiro, A.; Velázquez, R.; Muñoz, A.; Regodón, J.A. Analysing the vineyard soil as a natural reservoir for wine yeasts. *Food Res. Int.* **2020**, *129*, 108845. [CrossRef]
37. Belda, I.; Zarraonaindia, I.; Perisin, M.; Palacios, A.; Acedo, A. From Vineyard Soil to Wine Fermentation: Microbiome Approximations to Explain the “terroir” Concept. *Front. Microbiol.* **2017**, *8*, 821. [CrossRef] [PubMed]
38. Comitini, F.; Ciani, M. Influence of fungicide treatments on the occurrence of yeast flora associated with wine grapes. *Ann. Microbiol.* **2008**, *58*, 489–493. [CrossRef]
39. Drumonde-Neves, J.; Franco-Duarte, R.; Lima, T.; Schuller, D.; Pais, C. Association between Grape Yeast Communities and the Vineyard Ecosystems. *PLoS ONE* **2017**, *12*, e0169883. [CrossRef]
40. Grangeteau, C.; Roullier-Gall, C.; Rousseaux, S.; Gougeon, R.; Schmitt-Kopplin, P.; Alexandre, H.; Guilloux-Benatier, M. Wine microbiology is driven by vineyard and winery anthropogenic factors. *Microb. Biotechnol.* **2017**, *10*, 354–370. [CrossRef] [PubMed]
41. Setati, M.E.; Jacobson, D.; Andong, U.-C.; Bauer, F. The Vineyard Yeast Microbiome, a Mixed Model Microbial Map. *PLoS ONE* **2012**, *7*, e52609. [CrossRef]
42. Bagheri, B.; Bauer, F.F.; Setati, M. The Diversity and Dynamics of Indigenous Yeast Communities in Grape Must from Vineyards Employing Different Agronomic Practices and their Influence on Wine Fermentation. *S. Afr. J. Enol. Vitic.* **2016**, *36*, 243–251. [CrossRef]
43. Pierce, F.J.; Clay, D. *GIS Applications in Agriculture*; CRC Press: Boca Raton, FL, USA, 2007; ISBN 978-0-8493-7526-2.

-
44. Knight, S.; Klaere, S.; Fedrizzi, B.; Goddard, M.R. Regional microbial signatures positively correlate with differential wine phenotypes: Evidence for a microbial aspect to terroir. *Sci. Rep.* **2015**, *5*, 14233. [[CrossRef](#)] [[PubMed](#)]
 45. Mezzasalma, V.; Sandionigi, A.; Guzzetti, L.; Galimberti, A.; Grando, M.S.; Tardaguila, J.; Labra, M. Geographical and Cultivar Features Differentiate Grape Microbiota in Northern Italy and Spain Vineyards. *Front. Microbiol.* **2018**, *9*, 946. [[CrossRef](#)] [[PubMed](#)]



RESULTADOS Y DISCUSIÓN

ÍNDICE RESULTADOS Y DISCUSIÓN

<u>RESULTADOS Y DISCUSIÓN</u>	<u>249</u>
<u>1. RESULTADOS GENERALES</u>	<u>251</u>
<u>2. RESULTADOS Y DISCUSIÓN DEL CAPÍTULO I</u>	<u>255</u>
<u>3. RESULTADOS Y DISCUSIÓN DEL CAPÍTULO II</u>	<u>257</u>
<u>4. RESULTADOS Y DISCUSIÓN DEL CAPÍTULO III</u>	<u>259</u>
<u>5. RESULTADOS Y DISCUSIÓN DEL CAPÍTULO IV</u>	<u>267</u>
<u>6. RESULTADOS Y DISCUSIÓN DEL CAPÍTULO V</u>	<u>269</u>
<u>7. RESULTADOS Y DISCUSIÓN DEL CAPÍTULO VI</u>	<u>274</u>
<u>8. RESULTADOS Y DISCUSIÓN DEL CAPÍTULO VII</u>	<u>274</u>
<u>9. REFERENCIAS</u>	<u>276</u>
<u>CONCLUSIONES</u>	<u>283</u>
<u>CONCLUSIONS</u>	<u>287</u>

RESULTADOS Y DISCUSIÓN

Los ensayos se realizaron en parcelas situadas en **distintas localizaciones geográficas**. Las parcelas correspondientes a los Capítulos I, II, III, IV y V se situaron en las provincias de Valladolid, Burgos y Zamora, en Castilla y León, mientras que las correspondientes al Capítulo VI se localizaron en Galicia. Todas las estimaciones basadas en métodos de teledetección y algoritmos de clasificación fueron validadas empleando conjuntos de datos tomados de forma directa en cada zona de estudio, durante los **años 2016, 2018 y 2019** (Capítulos I, II, III y V). De este modo, se evaluaron en campo los principales parámetros agronómicos y de madurez, realizando su medición siguiendo protocolos estándar en viticultura recogidos por diversos autores (Blouin y Guimberteau, 2004; Hidalgo, 2006; Reynolds, 2010; Jackson, 2020):

- Parámetros de rendimiento y desarrollo vegetativo:
 - Peso de la madera de poda (kg planta^{-1})
 - Número de sarmientos por vid
 - Peso del sarmiento (g)
 - Índice de Ravaz
 - Número de racimos por planta
 - Rendimiento de uva por planta (kg planta^{-1})
 - Peso del racimo (g)
 - Peso de la baya (g)
- Parámetros de maduración y calidad:
 - Contenido de sólidos solubles totales ($^{\circ}\text{Brix}$)
 - Azúcar (g L^{-1})
 - pH
 - Acidez total (g de ácido tartárico L^{-1})
 - Ácido Málico (g L^{-1})
 - Ácido Tartárico (g L^{-1})
 - Potasio (ppm)

Adicionalmente, se midieron parámetros para caracterizar el suelo, como la fracción del suelo en arcilla, arena y limo, materia orgánica, capacidad de intercambio catiónico (CIC) y conductividad eléctrica aparente del suelo (σ).

La figura 1 muestra los viñedos objeto de estudio en la **DO Rueda** (cv. Verdejo, Capítulos I y V), **DO Ribera del Duero** (cv. Tempranillo, Capítulo V) y un viñedo experimental localizado en las instalaciones del Instituto Tecnológico Agrario de Castilla y León (ITACyL), en la Finca Zamadueñas, Valladolid (cv. Cabernet Sauvignon, Capítulos II y III). **Este último viñedo se arrancó** para analizar el efecto en las imágenes de satélite y medir de forma exacta e inequívoca la superficie foliar retirada en el laboratorio. Todos estos viñedos se sometieron a un manejo

ligado a desbroces mecánicos o químicos, manteniendo el suelo libre de malas hierbas y de cualquier elemento que pudiera afectar a la información espectral (Fountas et al., 2014).




Figura 1. Situación de los viñedos en Castilla y León

De igual modo, para el Capítulo IV se tomaron en 2018 datos de campo en tres parcelas de **pistacho** en Toro (Zamora), Perales (Palencia) y Pozal de Gallinas (Valladolid) en la región de Castilla y León (España). En cada parcela se controlaron tres árboles por vigor, estableciendo un diseño experimental de tres réplicas por tratamiento, y tres árboles como unidad experimental. En el momento de la cosecha se midieron diversas variables: peso del racimo, número y porcentaje de pistachos abiertos, cerrados y vacíos por racimo, rendimiento del árbol, peso del fruto y de la semilla, porcentajes de grasa, hidratos de carbono, proteínas y nitrógeno, fibra, fósforo, magnesio, calcio, hierro, zinc y sodio. Adicionalmente, para el Capítulo VII se emplearon datos de riqueza de especies de levadura tomados durante la consecución de los trabajos para la tesis doctoral de David Castrillo Cachón (Castrillo, 2018). Los datos se tomaron de **14 viñedos comerciales** plantados con cultivares de vid representativos dentro de cuatro Denominaciones de Origen: Monterrei, Ribeiro, Ribeira Sacra y Rías Baixas, que comprenden los cultivares Treixadura, Mencía, Brancellao y Albariño. La toma de datos de campo se llevó a cabo durante 3 años consecutivos (2013, 2014 y 2015) en Galicia. Se tomaron datos climáticos de la estación meteorológica más cercana a cada viñedo durante los tres años del estudio correspondientes a la

temperatura media mensual, la precipitación media mensual, la velocidad media mensual del viento y la humedad relativa media mensual. Además, se tuvieron en cuenta el manejo (ecológico/orgánico o convencional), la orientación y altitud.

Por otra parte, para la obtención de datos de teledetección, se emplearon las plataformas habilitadas para la descarga de imágenes de **satélite gratuitas** (Sentinel-2: <https://scihub.copernicus.eu/dhus/#/home>; Landsat-8: <https://earthexplorer.usgs.gov/>), realizando una corrección atmosférica en caso necesario (Sentinel-2: **sen2cor**; Landsat-8: **DOS1**). En el caso de **imágenes de dron**, se empleó instrumentación propia para realizar los trabajos. El NDVI empleado en los Capítulos se computó de acuerdo con lo ya expuesto anteriormente.

Para las vinificaciones, se elaboraron **vinos en función del vigor** de cada unidad de manejo. Se emplearon depósitos de acero inoxidable de 35 L. **El sistema de vinificación fue el tradicional de los vinos blancos**: recepción de la uva, estrujado y despalillado, con sulfitado de 5 g hl⁻¹, prensado e introducción en cámara frigorífica para la decantación. Al cabo de dos días, se realizó en primer lugar el trasiego y en segundo lugar la siembra de levaduras *Saccharomyces cerevisiae* (ex rf. *Bayanus*) SB (*EnartisFerm*) a 16 °C durante la fermentación. Se añadieron nutrientes a la siembra y se repitió la adición a densidades de 1070 y 1020 g L⁻¹. Al final de la fermentación, se realizó otro sulfitado y se redujo la temperatura a 5 °C. Por último, el vino se decantó y se mantuvo a 6 °C hasta el embotellado.

Con el fin de evaluar sensorialmente los vinos y pistachos, se estableció un **panel de jueces consumidores**, que realizaron **pruebas triangulares** para establecer si existía diferencia entre vigos, entendiendo que un resultado positivo en la prueba implicaba que las diferencias entre vigos son suficientemente perceptibles. Las pruebas se realizaron en una **sala de cata** equipada con diez puestos individuales, según la norma ISO 8589: 2007 y de acuerdo con la norma ISO 4120: 2004 para la prueba triangular.

Todos los análisis de imágenes y datos se llevaron a cabo utilizando AutoCAD, Statgraphics, QGIS, Python, R, software ofimático y software basado en SfM para la elaboración de ortomosaicos.

1. Resultados generales

La teledetección ha sido ampliamente utilizada en cultivos extensivos. Existe abundante bibliografía que acredita la utilidad del empleo de imágenes de satélite para la estimación de parámetros relacionados con cultivos herbáceos, como los cereales. Así, se ha observado que el NDVI es sensible a los cambios en la cobertura fraccional de la vegetación hasta que se alcanza una **cobertura total** (Carlson y Ripley, 1997), una **situación común en cultivos extensivos, pero que rara vez se da en viñedo**.

En cultivos extensivos se ha empleado con éxito la información de las imágenes de satélite, prediciendo rendimientos e incluso parámetros de calidad. Estas imágenes contienen información de la vegetación observada, por lo que **cuanto mayor sea la correlación entre los parámetros vegetativos y los de producción y calidad, mejor será la relación entre estos últimos y la información que proporcionan las imágenes**. Así, en cultivos extensivos como el cereal, es posible encontrar **buena correlación entre el desarrollo vegetativo y la producción** de grano en la cosecha (Remison y Akinleye, 1979; McClellan et al., 2012), por lo que es posible encontrar buenas relaciones entre estos parámetros y las imágenes. De este modo, Mirasi et al. (2021) emplearon el NDVI para calcular estadísticos descriptivos y comprobar su relación con el rendimiento en trigo. Hallaron que el sumatorio de NDVI, calculado hasta 49 días antes de la cosecha cuando los granos de trigo se encontraban en la fase de madurez, era el parámetro más adecuado para la estimación del rendimiento, obteniendo una fuerte relación lineal con valores de hasta $R^2 = 0,90$, empleando imágenes Landsat con el sensor OLI. Tan et al. (2020) mostraron valores R^2 superiores a 0,8 empleando un modelo PLS para predecir el contenido en proteínas del grano en trigo a partir de imágenes de satélite. Por otra parte, López-Lozano et al. (2015) indican que las series temporales de imágenes de satélite son una herramienta efectiva para la previsión del rendimiento de los cultivos a nivel regional, estudiando trigo, cebada y maíz. Panek y Gozdowski (2020) confirman que los datos de satélite pueden ayudar a mejorar la precisión de la predicción del rendimiento de los cereales. Para ello emplearon imágenes MODIS a nivel regional en Europa Central desde principios de la primavera e imágenes Sentinel-2 en trigo de invierno y triticale (Panek et al., 2020).

Sin embargo, aunque, como en cualquier cultivo, el rendimiento de la vid está formado por varios componentes, **la relación entre el rendimiento y las imágenes no es tan clara** debido, entre otros factores, al carácter perenne del cultivo. Los componentes del rendimiento son aquellos factores de la vid que, multiplicados juntos, suman el rendimiento obtenido en vendimia y, entre otros, está limitado por el número de inflorescencias iniciadas en las yemas durante la **temporada de crecimiento anterior** y su **máxima producción** está condicionada por el **desarrollo vegetativo de la planta** (Keller, 2015). Estos componentes varían ligeramente en función de los autores. Así, Coombe y Dry (2001) establecen que depende del número de yemas, pámpanos, número de racimos, número de uvas y peso de cada uva. En todo caso, el **rendimiento en viñedo es más complejo que otros cultivos**, debido a sus características. La vid es una planta leñosa y plurianual y, por tanto, vecera. La vecería se debe, entre otras cosas, a la **variación de reservas de carbohidratos**, por lo que para conseguir cosechas regulares es

preciso podarla anualmente (Hidalgo, 2006). Todas estas características hacen que la **estimación de parámetros de producción o calidad sea más compleja** que en otros cultivos.

Por todo ello, la tesis tuvo como objetivo global aportar **conocimientos y herramientas basados en la teledetección**, que permitan monitorizar de forma **precisa y rápida** el viñedo, para su caracterización según su heterogeneidad y, de este modo, **mejorar la gestión, manejo del cultivo y aumentar su adaptabilidad**. Con este fin, se realizaron diversos experimentos. Más concretamente, a lo largo de los Capítulos de la presente tesis doctoral se exploró la relación entre la información obtenida a partir de la teledetección con los parámetros de desarrollo vegetativo y productivos del viñedo y los parámetros de calidad, tratando de resolver las distintas problemáticas encontradas al avanzar en la realización de los trabajos.

De este modo, para la consecución del Capítulo I, se emplearon técnicas previamente empleadas por otros autores en viñedo. En este Capítulo se realiza una clasificación de viñedos distantes entre sí, a partir del NDVI de las imágenes de satélite, encontrando **diferencias significativas respecto al vigor** de los viñedos y la producción. En la realización de los trabajos se efectúa un primer acercamiento a la problemática de los píxeles mixtos, ya que el uso de las imágenes del satélite Sentinel-2 (100 m² de píxel) implica que los **valores reales del NDVI no son sólo valores de vegetación**, sino que incluyen tanto el cultivo como la flora espontánea, suelo y sombras.

Con el objetivo de estudiar la problemática de los píxeles mixtos en viñedo más a fondo y la **relación entre la vegetación del viñedo y las imágenes del satélite**, en el Capítulo II se ideó un ensayo para **arrancar un viñedo de forma progresiva**, de tal modo que se estudió el efecto de la reducción de vegetación a lo largo del mes de julio en las imágenes captadas por el satélite, encontrando que, aún con la problemática de los píxeles mixtos, en un viñedo tipo en espaldera **el NDVI se reduce de forma proporcional a la reducción de la vegetación**. En paralelo, planteando otro enfoque para afrontar la problemática de los píxeles mixtos, se observó que en la práctica totalidad de los casos las sombras se consideraban elementos no deseables de la imagen. Por ello, en el Capítulo III se decidió emplear un dron para estudiar el viñedo arrancado, para poder analizar posteriormente las imágenes y estudiarlas de forma conjunta con los datos de desarrollo vegetativo. Con este fin, se realizaron **varios vuelos con UAV a distintas horas con el objetivo de analizar las sombras**.

En teledetección agrícola, usualmente en la literatura científica se establece que los métodos empleados en un cultivo son extensibles a otros similares, por ejemplo, entre el trigo, la cebada o el triticale (Panek et al., 2020). En el Capítulo IV se trató de emular esta idea, empleando la **misma metodología** utilizada en el Capítulo I, pero en otro tipo de cultivo leñoso: el **pistacho**.

Debido a los problemas encontrados con la falta de resolución espacial de los satélites y la problemática de los píxeles mixtos, en el Capítulo V se exploró la posibilidad de explotar una

de las ventajas de los satélites Sentinel-2: su **resolución temporal**. Para ello, se empleó el análisis funcional PCA y una serie temporal de imágenes de **todo el ciclo fenológico del viñedo**. Adicionalmente, se **mejoró la toma de datos en campo**, para llevar a cabo un muestro más **representativo** de la parcela y captar mejor su variabilidad espacial. De este modo, se realizó un muestreo sistemático en forma de **malla**, monitorizando un total de 160 plantas en el viñedo de Rueda y 294 plantas en el de Ribera del Duero durante cada año.

El Capítulo VI constó de una **revisión actual de la viticultura en viñedo**, a través del capítulo de un libro. Y, finalmente, en el Capítulo VII se quiso aprovechar y **explorar nuevas potencialidades de las imágenes de satélite** que, desde un punto de vista razonado podrían funcionar, aunque su relación sea **compleja y difícil de interpretar**.

Como se ha indicado, el empleo de imágenes en cultivos leñosos, y más concretamente en viñedo, es más complicado que en otro tipo de cultivos. No obstante, **los resultados globales** de la presente tesis muestran que la teledetección es una **herramienta muy útil para su utilización en viñedo**. Es posible desarrollar tecnologías basadas en la teledetección accesibles y de bajo coste para definir de manera dinámica (espacial y temporalmente) los viñedos, de acuerdo con las características de distintas unidades de manejo diferenciado dentro de los mismos y optimizar su gestión hasta obtener el producto final perfectamente determinado. Esta herramienta no sólo puede permitir **automatizar tareas y ahorrar tiempo**, sino que puede proporcionar un enorme **valor añadido** al entregar **información útil que de otro modo no sería posible**. Su enorme potencial reside no sólo en la posibilidad de empleo de diferentes plataformas capaces de entregar distintas resoluciones espaciales y temporales, sino también en la amplia gama de sensores disponibles, que permite la captura de información en **distintas regiones del espectro electromagnético** para su análisis. Por otra parte, la información recogida puede ser tratada con infinitud de métodos de análisis y algoritmos, con el fin de encontrar patrones que permitan la obtención de **información útil para la toma de decisiones** sobre el cultivo. Con el objetivo de explorar la utilidad de las imágenes de satélite para su uso en viñedo, en el Capítulo II se estudió la **relación entre el NDVI y las imágenes de satélite Sentinel-2 en viñedos en espaldera**, que, si bien tiene una resolución moderadamente alta teniendo en cuenta que son plataformas satelitales, se ven afectadas por el fenómeno de los píxeles mixtos. Se encontró que **el NDVI se reduce proporcionalmente a la reducción de vegetación, si bien en una magnitud inferior**. Por otra parte, en el Capítulo VII se exploró su uso como indicador del *terroir* de una zona e incluso de un parámetro de calidad más allá de los tradicionales: la riqueza de especies de levadura, a través de su relación con la vegetación de la parcela.

Finalmente, en la presente tesis se adaptaron métodos conocidos o se desarrollaron métodos novedosos para proporcionar información al viticultor acerca de las distintas subunidades de manejo diferenciado que se pueden establecer dentro de su viñedo, en forma de mapas. Para ello, se emplearon imágenes de **distinta resolución espacial y temporal** (tomadas

con satélite y UAV) y **diversos algoritmos y métodos de clasificación**. Así, con el objetivo de proporcionar herramientas para la **gestión interparcelaria, intraparcilaria e incluso a nivel de cepa**, en los **Capítulos I, III y V** se crearon **productos basados en el desarrollo vegetativo del viñedo**. La figura 2 muestra estos mapas, que pueden ser empleados para la creación de **Unidades de Manejo Diferenciado**, con unidades de gestión basadas en la **parcela** (Capítulo I), **subparcela** (Capítulo V) y **planta** (Capítulo III). Adicionalmente, en el Capítulo IV se adaptó la metodología empleada en el Capítulo I para comprobar la idoneidad de su aplicación en otro tipo de cultivos leñosos.




Figura 2. Mapas para zonificación. (a) Interparcelaria, Capítulo I; (b) Intraparcilaria, Capítulo V; (c) A nivel de planta, Capítulo III (c).

2. Resultados y discusión del Capítulo I

Los experimentos se realizaron en 2016, en la DO Rueda, en tres viñedos comerciales cv. Verdejo. Para la realización del estudio, se descargaron y seleccionaron once imágenes del año 2016, asignando un **nivel de vigor a cada viñedo en función de los valores medios de NDVI** de sus píxeles (alto, medio y bajo, Figura 3).

Se eligió la imagen tomada el 5/8/16 porque estaba en el rango de valores medios máximos de NDVI, y la desviación estándar (NDVIsd) fue la más baja en ese rango (Figura 3). Se empleó la imagen con menor desviación estándar puesto el objetivo era asignar un valor medio uniforme de NDVI a toda la parcela. Esta imagen es muy cercana al estado fenológico de envero, corroborando los resultados ya expuestos por otros autores. Finalmente, se empleó un método de **clasificación no supervisado** (k-means) en el producto NDVI para clasificar cada viñedo en un nivel de vigor. Los viñedos se asociaron con vigor bajo (LV), medio (MV) y Alto (HV).

Puesto que los viñedos tenían marcos de plantación distintos, los resultados se **promediaron por unidad de superficie**. Pérez (2002) afirma que el aumento de la densidad de plantación contribuye a un ligero aumento de la superficie foliar total (LAI) y externa (SA) por metro cuadrado de suelo y a una mejor distribución espacial de la masa vegetativa, aunque otros autores han encontrado que la distancia entre cepas no es un factor decisivo para el desarrollo foliar de las plantas, peso de madera de poda, el rendimiento y sus componentes, o la actividad fisiológica y la calidad de uva (Barajas, 2011).




Figura 3: Evolución del NDVI (línea azul) y desviación estándar del NDVI (línea naranja) de cada viñedo. De izquierda a derecha: Vigor alto (HV), medio (MV) y bajo (LV).

En este Capítulo se realiza un **primer acercamiento a la problemática de los píxeles mixtos**, ya que el uso de las imágenes del satélite Sentinel-2 (100 m² de píxel) implica que los valores reales del **NDVI no son sólo valores de vegetación**, sino que incluyen tanto el cultivo como la flora espontánea, suelo y sombras. Pese a ello, la clasificación del NDVI de las imágenes de satélite fue capaz de discriminar correctamente el vigor de los viñedos, así como la producción, encontrando diferencias significativas en el peso de madera de poda de 2.438, 1.895 y 1.487 kg ha⁻¹, para NDVI alto, medio y bajo respectivamente, mostrando que un valor mayor de NDVI se correspondía con un valor mayor de peso de madera de poda. Se encontraron diferencias significativas en el rendimiento por hectárea, con 15.984, 12.990 y 10.576 kg ha⁻¹, para NDVI alto, medio y bajo respectivamente. También se hallaron diferencias significativas en el resto de los parámetros agronómicos evaluados, excepto en el Índice de Ravaz, lo que indica que en este trabajo el aumento del desarrollo vegetativo fue proporcional al rendimiento, **sin implicar un desequilibrio en el viñedo**. En cuanto a los parámetros de madurez, el momento de la vendimia

para cada viñedo se estableció en función de la acumulación de sólidos solubles totales (23 °Brix), por lo que no hay diferencias significativas en este parámetro ni en azúcares. Sin embargo, hay una semana de diferencia entre las fechas de cosecha y existen diferencias significativas en los parámetros de madurez evaluados (pH, acidez total, ácido málico, ácido tartárico y K). No obstante, no existen patrones claros, coincidiendo con otros autores, que establecen que **el NDVI suele estar mucho más relacionado con los parámetros agronómicos que con los de madurez** (Santesteban et al., 2014). Respecto al análisis organoléptico, el panel de cata sí detectó diferencias, que llegaron a ser significativas entre los vinos de los distintos vigos.

3. Resultados y discusión del Capítulo II

Con el objetivo de analizar la **relación entre el NDVI y los píxeles mixtos en viñedo**, se realizó una simulación de **eliminación de la viña** en condiciones de control en un invernadero, utilizando cepas cultivadas en maceta, cv. Cabernet Sauvignon, seleccionando 12 vides de un año de edad situadas en dos hileras para simular un sistema de espaldera vertical (VSP). Se eliminaron las vides progresivamente para comprobar su efecto en las imágenes, captadas con una cámara multiespectral Parrot Sequoia. Adicionalmente, se realizó un experimento de campo en el viñedo situado en la Finca Zamadueñas del ITACyL (coordenadas: 41,7013° N, 4,7088° W, Valladolid, España), cv. Cabernet Sauvignon y en espaldera. Se marcaron las cepas con GPS de alta precisión y se marcaron en campo tres píxeles de Sentinel-2 (10 × 10 m) dentro del viñedo, con 38 vides aproximadamente dentro de cada píxel (Figura 4). Durante el verano de 2019, **se eliminó progresivamente la masa vegetativa de cada píxel** para comprobar su efecto en el NDVI calculado a partir de imágenes de satélite Sentinel-2. El área foliar retirada de cada planta se determinó empleando la aplicación *EasyLeafArea* (Easlon y Bloom, 2014).

La simulación en invernadero mostró una clara relación ($R^2 = 0,986$) entre la reducción del NDVI y la reducción de vegetación (TLA, Total Leaf Area). Los valores de NDVI son los valores del píxel mixto simulado. Cuando se eliminaron las vides del píxel mixto simulado (alrededor de 2 m²), los valores de NDVI disminuyeron linealmente hasta alcanzar los valores del suelo base (definidos en este caso como NDVI = 0,20). En cuanto al experimento de campo, se observa una reducción del valor del NDVI después de cada eliminación de la vid hasta alcanzar los valores del suelo base (en este caso, valores del NDVI entre 0,17 y 0,19), excepto en el píxel 1 (Figura 5). Los valores de NDVI de partida, que corresponden a la máxima cobertura de vid, fueron 0,251, 0,321 y 0,306, para los píxeles 1, 2 y 3, respectivamente. Se encontró una **relación lineal** entre la reducción del NDVI y la TLA ($R^2 = 0,72$).




Figura 4. Representación esquemática de la eliminación de la viña en cuatro pasos implementada en el experimento de campo.




Figura 5. (a) Detalle de la eliminación de la vid por fase. (b) TLA (m^2) y valores de NDVI en cada píxel.

Es interesante observar que, tanto en el experimento de invernadero, como en el experimento de campo, la **pendiente de la ecuación lineal es de en torno al 30%**, ($y = 0,3x$), por lo que la reducción del NDVI respecto a la vegetación es similar en los dos experimentos: por cada 20% de reducción de vegetación, la reducción del NDVI es de alrededor del 6% (Figura 6).

Este estudio ha abordado el efecto de píxel mixto de dos maneras diferentes: un enfoque de laboratorio (invernadero) y un enfoque a escala real con un experimento de campo. Los dos experimentos presentaron resultados consistentes, mostrando el mismo patrón de reducción del NDVI, confirmando su capacidad de identificar la vegetación contenida en un píxel Sentinel-2 tomado de una parcela de viñedo. Por otra parte, se observa que la relación es **proporcional**, existiendo una relación lineal fuerte entre el NDVI y la vegetación del viñedo. Finalmente, cabe reseñar que, en el caso de **viñedo en espaldera**, si la vegetación dentro del píxel se reduce en un 20% y el NDVI se reduce proporcionalmente en un 6-7%, considerando los componentes de un píxel mixto, la **vegetación y la sombra asociada tienen un efecto del 30-35%**, por lo que el **valor restante está siendo influenciado por el suelo**.




Figura 6. Relación entre el NDVI (%) y la reducción de la vegetación (TLA, %). (a) Experimento de invernadero, (b) experimento de campo.

4. Resultados y discusión del Capítulo III

Este estudio aprovecha los avances en las tecnologías de captura de imágenes y de vehículos aéreos no tripulados, combinando los conocimientos previos en viticultura con la teledetección y los métodos de aprendizaje automático. Se emplearon los mismos datos de campo que para el Capítulo II.

El 27 de junio de 2019, se tomaron imágenes multiespectrales con cámaras MAPIR montadas sobre UAV, fijando la elevación del sol en $\beta = 45^\circ$ para **maximizar las sombras sobre el suelo**. Como resultado, el vuelo se programó entre las 15:30 y las 16:00 horas solares (18:00 horas locales). Se tomaron con GPS puntos de control para corregir la imagen y se construyó un

ortomosaico con software a partir de todas las imágenes tomadas. Las imágenes contenían las bandas roja, azul, verde (RGB) e infrarroja (NIR).

Posteriormente, se emplearon **tres métodos diferentes** para aislar las sombras: i) reclasificación de imágenes (método de sensibilidad/manual), ii) K-means, y iii) Random Forest (Figuras 7 y 8).




Figura 7. Resultados de la clasificación K-means. El número k , clústeres, se estableció entre 2 y 6. (a) Imagen original, (b) k-means, $k = 2$, (c) k-means, $k = 3$, (d) K-means, $k = 4$, (e) k-means, $k = 5$, y (f) k-means, $k = 6$.

Finalmente, se **delimitó una cuadrícula** definida por los **ángulos acimut solar y orientación** de la fila del viñedo, se recortó cada área de la planta, se midió la sombra dentro del área y se correlacionó con el LAI real (Figura 9).




Figura 8. Resultados de la clasificación empleando Random Forest.

Se observó que, con el método manual de la sensibilidad, la extracción de las sombras de la imagen para su **correlación con el LAI real era óptima para valores de píxel de sombra $\pm 30\%$** , aproximadamente (Figura 10), siendo mayores para el producto que incorporaba la banda infrarroja, debido probablemente a la **capacidad del NIR de detectar la vegetación** y, por tanto, facilitando la **diferenciación entre sombras y vegetación sombreada**.

En primer lugar, se compararon los conjuntos de datos RGB y RGN, puesto que presentaron una mayor correlación con el LAI. Una vez definido el modelo, se comparó el LAI estimado con el LAI observado (Figura 11). Para el producto RGB, el mejor resultado se obtuvo utilizando los coeficientes $a = 0,3$, $b = 0,3$ y $c = 0,4$ ($y = 1,005x + 0,741$), con $R^2 = 0,71$, $RMSE = 0,141 \text{ m}^2 \text{ m}^{-2}$, y $MAE = 0,110 \text{ m}^2 \text{ m}^{-2}$. Para la RGN, la mayor precisión se obtuvo utilizando los coeficientes $a = 0,3$, $b = 0,5$ y $c = 0,4$ ($y = 1,163x + 0,642$), con $R^2 = 0,74$, $RMSE = 0,146 \text{ m}^2 \text{ m}^{-2}$, y $MAE = 0,123 \text{ m}^2 \text{ m}^{-2}$. Para los algoritmos de clasificación, se empleó directamente la imagen con el infrarrojo. La figura 12 muestra que **Random Forest** mejoró ligeramente la precisión anterior de RGN. Mostró la **mayor precisión para predecir el LAI** ($R^2 = 0,76$, $RMSE = 0,160 \text{ m}^2 \text{ m}^{-2}$, y $MAE = 0,139 \text{ m}^2 \text{ m}^{-2}$), igualada por k-means con $k = 6$ ($R^2 = 0,76$, $RMSE = 0,165 \text{ m}^2 \text{ m}^{-2}$, y $MAE = 0,142 \text{ m}^2 \text{ m}^{-2}$). Sin embargo, Random Forest obtuvo valores de error ligeramente inferiores. El resto de la clasificación k-means osciló entre $R^2 = 0,62$ y $R^2 = 0,75$. La peor correlación se encontró para k-means con $k = 4$.




Figura 9. Izquierda: (a) Definición de la superficie, (b) Superficie de una planta, (c) Cuadrícula completa. Derecha: (a) Método de reclasificación de píxeles, (b) de arriba abajo: sombra de una sola viña, sombra de una sola viña reclasificada (multibanda) y producto final reclasificado.




Figura 10. Valores de correlación (eje Y) para cada nivel de sensibilidad (eje X). Valores de sensibilidad de 0,1 a 1,0, en intervalos de 0,1 (10 niveles en total). (a) banda única, y (b) combinación de bandas.




Figura 11. LAI observado frente al estimado. (a) RGB, (b) RGN.

Para que esta metodología funcione de forma óptima, se debe tener en cuenta varios **factores esenciales**, tales como la **posición del sol** o la **orientación y el manejo del viñedo** (poda, laboreos, etc.). Además, en la figura 13 se muestran algunas de las principales limitaciones del método. Existen otras **limitaciones inherentes al tipo de cultivo**, que también existen en otros métodos, tales como el efecto de la iluminación, la combinación de vegetación de distintas plantas en la espaldera, etc.

La ortofotografía aérea proporciona información sobre el tamaño del dosel en dos dimensiones, pero la **sombra es la proyección en el plano de la tercera dimensión**, o dimensión vertical, lo que proporciona **información valiosa adicional que usualmente es complicada de extraer empleando otros métodos de teledetección que se basan en la ortofotografía aérea**. Las sombras no sólo dependen de la forma de la vegetación, sino también de la iluminación existente. Por lo tanto, es imprescindible contar con una **fuentes de luz óptima** (días soleados), siendo necesaria la **radiación solar directa**, ya que la radiación difusa generaría problemas debido a complicaciones en la definición de las sombras en la imagen. Adicionalmente, las **sombras varían a lo largo del día** en función del sol; por lo tanto, es posible planificar el vuelo en el momento óptimo cuando el sol está en la posición deseada. El **momento óptimo** para tomar la imagen estará determinado por la **altura de las vides y la separación entre las filas de plantas**.

En general, los resultados mostraron una **relación positiva significativa** entre las sombras de las plantas y el LAI, mostrando una **precisión de $R^2 = 0,76$** empleando el algoritmo Random Forest sobre una imagen RGN.




Figura 12. LAI observado frente al estimado. (a) Random Forest, (b) k-means, k = 2, (c) k-means, k = 3, (d) k-means, k = 4, (e) k-means, k = 5, y (f) k-means, k = 6.




Figura 13. Problemas de reconocimiento de sombras: (a) vegetación sobre las sombras, (b) sombras en la vegetación.

a. Comparación con otras metodologías de teledetección para estimar LAI

Cada metodología tiene ventajas y desventajas. La tabla 1 muestra una breve comparación con algunos de los métodos expuestos anteriormente. La comparación se realizó utilizando consideraciones similares a las de Jin et al. (2021), incluyendo el "coste económico", que trata de representar el coste de la operación, incluyendo todo el equipo implicado y la "inversión de tiempo", que es el tiempo estimado necesario para la recogida de datos en el campo.

En cuanto a la **inversión de tiempo**, el método propuesto es **mucho más rápido** que los métodos que emplean instrumentación específica, como el PCA o el ceptómetro, que se llevan a pie para realizar el reconocimiento planta por planta (Johnson y Pierce, 2004; López-Lozano y Casterad, 2013; White et al., 2018), o los métodos que realizan la toma de datos en campo (Diago et al., 2012; Fuentes et al., 2014; Towers et al., 2019), como el caso del LiDAR, que debe montarse en un vehículo terrestre (Arnó et al., 2013). En comparación con otros métodos que utilizan tecnologías similares (UAV/Aeronave + cámara), el presente método presenta un consumo de tiempo similar (Hall et al., 2008; Kalisperakis et al., 2015; Comba et al., 2020), y es **más rápido que los métodos SfM que requieren más imágenes** (Mathews y Jensen, 2013). Sin embargo, sigue siendo necesario ir al viñedo para tomar las imágenes, por lo que los métodos por satélite son aún más rápidos (Johnson, 2003; Beerli et al., 2020).

En cuanto al **coste de la operación**, el método propuesto es un **método de bajo coste**, ya que se pueden utilizar UAV básicos y cámaras RGB+RGN normales. El mejor rendimiento se obtuvo con la cámara RGN, que tiene un coste ligeramente superior al de una cámara RGB, como las utilizadas por Diago et al. (2012) y Fuentes et al. (2014), pero es más barato que los sensores multiespectrales utilizados por Towers et al. (2019) y Comba et al. (2020) o el sensor hiperespectral utilizado por Kalisperakis et al. (2015). Los sensores específicos como el PCA o el ceptómetro también tienen un coste más elevado. Además, si se considera el coste de la plataforma, el UAV utilizado en el estudio es mucho más barato que un vehículo terrestre (Arnó et al., 2013).

En cuanto a la **precisión**, el presente método está en línea con otros métodos basados en teledetección, ya que reporta valores de correlación similares. Además, **es la primera vez que se desarrolla un método de este tipo**, por lo que, al igual que otros métodos en sus inicios, es **susceptible de ser mejorado** en experimentos posteriores. Por ejemplo, Mathews y Jensen (2013) informaron de una precisión $R^2 > 0,5$, pero en trabajos posteriores, Kalisperakis et al. (2015) y Comba et al. (2020) alcanzaron una precisión mayor ($R^2 > 0,8$).

En resumen, el método presentado en este Capítulo es **más barato y requiere menos tiempo** que otros métodos para calcular el LAI, obteniendo precisiones similares (Tabla 1). Por último, otros métodos suelen trabajar cerca del mediodía solar, o al menos intentan evitar las sombras, por lo que la presente metodología permite programar el vuelo en **otros periodos del**

día, como la mañana o la tarde, alejados del mediodía solar, **otorgando a los pilotos una mayor flexibilidad** a la hora de realizar los trabajos.

Tabla 1. Comparación entre los métodos actuales de medición del LAI por teledetección y los métodos de medición por sombra. Los valores de R^2 son los valores reportados por los autores. Los valores de 'Coste económico' y 'Inversión de tiempo' se basan en los métodos descritos por los autores en comparación con el método del presente trabajo. En 'Coste económico': 'bajo' coste total hasta 3.000\$; 'medio' hasta 6.000\$; 'alto' más de 6.000\$.

Método	Plataforma	Coste económico	Tiempo invertido	Correlación con LAI	Autores
Sombras	UAV	Bajo	Bajo	$R^2 > 0.7$	Capítulo III
	3D SfM	UAV	Bajo	$R^2 > 0.5$	Mathews y Jensen, 2013
	UAV	Bajo	Bajo	$R^2 > 0.8$	Kalisperakis <i>et al.</i> , 2015
2D RGB o multiespectral	UAV	Medio	Bajo	$R^2 > 0.8$	Comba <i>et al.</i> , 2020
	UAV	Bajo	Bajo	$R^2 > 0.7$	Kalisperakis <i>et al.</i> , 2015
	Terrestre	Bajo	Alto	$R^2 > 0.8$	Diago <i>et al.</i> , 2012
	Terrestre	Medio	Alto	$R^2 > 0.9$	Fuentes <i>et al.</i> , 2014
	Terrestre	Medio	Alto	$R^2 > 0.5$	Towers <i>et al.</i> , 2019
	Aérea	Medio	Bajo	$R^2 > 0.5$	Hall <i>et al.</i> , 2008
LiDAR	Terrestre	Alto	Medio	$R^2 > 0.8$	Arnó <i>et al.</i> , 2013
Cámara hiperespectral	UAV	Alto	Bajo	$R^2 > 0.8$	Kalisperakis <i>et al.</i> , 2015
Plant canopy analyser	Terrestre	Medio	Alto	$R^2 > 0.7$	Johnson y Pierce, 2004
Satélite	Satélite	Bajo	Muy Bajo	$R^2 > 0.3$	White <i>et al.</i> , 2018
				$R^2 > 0.7$	Beeri <i>et al.</i> , 2020 Johnson <i>et al.</i> , 2003

Es importante señalar que esta comparación sólo pretende exponer las posibilidades y la precisión de los métodos existentes frente a la utilidad del método propuesto en este trabajo. Los resultados presentados en la literatura no son totalmente comparables, puesto que se han realizado en condiciones experimentales diferentes. El LAI de referencia empleado para validar los resultados **no se ha obtenido de la misma forma** en todos los experimentos. De este modo, en el presente trabajo se utilizó el LAI real, medido destructivamente para validar los resultados estimados por la teledetección, no obstante, otros autores, utilizaron el LAI resultante de otros métodos de estimación para validar sus métodos, como el LAI medido con un Li-COR PCA (Johnson, 2003; Fuentes *et al.*, 2014) o el ceptómetro AccuPAR LP-80 (Mathews *et al.*, 2013).

La metodología presentada en el Capítulo III se empleó para crear un **mapa de manejo diferenciado**, clasificando en tres niveles de vigor empleando el algoritmo k-means (Figura 14).

Además, esta metodología podría emplearse para calcular la superficie foliar en otros cultivos leñosos o parámetros importantes relacionados con la **geometría del dosel foliar**.




Figura 14. (a) Clasificación según el nivel de LAI utilizando k-means (b) Mapa/zonificación según el nivel de LAI.

5. Resultados y discusión del Capítulo IV

En 2018 se tomaron datos en tres ensayos experimentales ubicados en tres parcelas de pistacho en Toro (Zamora), Perales (Palencia) y Pozal de Gallinas (Valladolid) en la región de Castilla y León (España). En cuanto al empleo de la teledetección, en este trabajo se empleó una **metodología similar a la del Capítulo I para la selección de la imagen** y clasificación del vigor del cultivo a partir del NDVI del satélite en dos niveles: **alto y bajo** (Figura 15). Como resultado, se evaluaron 24 imágenes para cada parcela, entre las fechas 17/01/2020 y 03/11/2020, como se muestra en la Figura 16, eligiendo la imagen del 26 de julio porque la vegetación de los pistacheros era más **homogénea**.




Figura 15. Clasificación del NDVI. (a) Parcelas de Toro, (b) Perales y (c) Pozal de Gallinas. Dos niveles de vigor: alto (verde oscuro) y bajo (verde claro).




Figura 16. Imágenes del Índice de Vegetación de Diferencia Normalizada (NDVI) 2018 de la parcela de Pozal de Gallinas. En rojo, la imagen elegida para realizar la zonificación de las parcelas de pistachos (26 de julio de 2018).

En la figura 17 se observa que el vigor bajo presentó un mayor porcentaje de pistachos abiertos y un menor porcentaje de pistachos cerrados y vacíos por racimo, mostrando porcentajes del 45,5%, 33,4% y 21,1%, respectivamente, frente a 30,5%, 49,9% y 19,6%, mostrados por el vigor alto, aunque sin diferencias significativas. Por otra parte, se observó que cuanto mayor es el vigor individual de los árboles menor es el porcentaje de pistachos abiertos que presentan, aunque el rendimiento por hectárea es casi un 88% mayor, lo que compensaría el

menor porcentaje en el número de pistachos abiertos en el vigor alto. Igualmente, la producción de pistachos cerrados por árbol ha mostrado **diferencias estadísticamente significativas a favor del vigor alto**, observándose un valor de 2,93 kg/árbol frente a 0,24 kg/árbol de vigor bajo.



Figura 17. Medias correspondientes a (a) porcentaje de pistachos abiertos, cerrados y vacíos; (b) rendimiento correspondiente a pistachos abiertos, cerrados y vacíos para los tratamientos experimentales: Vigor alto y bajo. Nivel de significación estadística: *, $p < 0,05$.

Las fechas de los diversos estadios fenológicos evaluados no han presentado diferencias ni desfases significativos. Los parámetros nutricionales y de calidad de los pistachos no han mostrado diferencias estadísticamente significativas entre los diferentes vigores. En cuanto al análisis sensorial, las pruebas triangulares han demostrado que el panel de cata fue capaz de detectar los pistachos de diferente vigor y procedencia. Los resultados indican que, si bien no existieron diferencias significativas en los parámetros de calidad, el **NDVI es un buen índice para clasificar las distintas zonas según la capacidad productiva del pistacho**.

6. Resultados y discusión del Capítulo V

Bajo la premisa de que la **resolución espacial es una desventaja** en el uso de imágenes de satélite Sentinel-2, se exploró la posibilidad de **explotar su resolución temporal**.

De este modo, se estableció un experimento durante el año 2018, localizado en dos viñedos comerciales, uno cv. Verdejo y otro cv. Tempranillo, situados en Villanueva de Duero, Valladolid (Viñedo A) y en Aranda de Duero, Burgos (Viñedo B) y pertenecientes a la DO Rueda y DO Ribera del Duero, respectivamente. Como se ha indicado, para capturar la **variabilidad espacial se realizó un muestro exhaustivo** de parámetros agronómicos y de maduración. Así, se estableció una **mall**a de sitios de muestreo (SS) distribuidos equitativamente en cada viñedo: 16 SS en el viñedo A y 98 SS en el viñedo B (Figura 18). En el viñedo A, un SS correspondía a 10 plantas de vid (cinco en una hilera y las otras cinco en la adyacente), lo que dio lugar a un total de 160 vides muestreadas. En el viñedo B, un SS correspondía a 3 vides (a lo largo de la hilera), lo que daba lugar a 294 vides muestreadas. Cada SS incluía menos plantas en el viñedo B, ya que se trata de un viñedo más grande y la prioridad del muestreo era cubrir toda la zona durante una sola campaña de muestreo.



Figura 18 - Sitios de muestreo y sectores de riego de (izquierda) el viñedo A y (derecha) el viñedo B.

Adicionalmente, se descargaron imágenes Sentinel-2 de cada zona. Para el análisis, las series temporales de NDVI de 2018 se limitaron de abril a finales de septiembre, debido al ciclo fenológico del cultivo. La figura 19 muestra las curvas de NDVI en bruto en cada viñedo para cada píxel.




Figura 19 - Evolución del NDVI durante el año 2018 para los píxeles del viñedo A (izquierda) y del viñedo B (derecha). La curva roja indica la evolución media del NDVI en cada viñedo.

A continuación, se aplicó el **f-PCA tal y como se ha detallado en la introducción** (2.8 Series temporales de imágenes), y se utilizó el **análisis de correlación de Spearman** para comprobar si estos componentes estaban relacionados con las variables medidas en el viñedo. Dado que las mediciones de campo son puntuales, sólo se consideraron los datos de estos sitios de muestreo. Los resultados muestran que el mapa de la **primera componente principal** tiende a ser muy **similar al mapa de NDVI obtenido en el envero**; ambos mapas ponen de manifiesto los mismos patrones espaciales. Según las correlaciones entre la primera componente y los valores de campo, la primera componente está vinculada al peso final de la madera de poda. Además, la **correlación es mayor entre el PWW y el PC1** ($r = -0,62$, viñedo A; y $r = -0,51$, viñedo B) que entre el PWW y el mapa de envero ($r = 0,54$ y $r = 0,39$), respectivamente (Figura 20).



Figura 20 - Comparación entre el mapa NDVI de envero y los tres primeros componentes del PCA.

Es muy probable que este resultado se observe en la mayoría de los viñedos, ya que este primer componente refleja la tendencia del vigor primario del viñedo durante toda la temporada. En consecuencia, en lo que respecta al primer componente, el f-PCA no proporciona información más novedosa que un mapa de NDVI en el envero (siendo este último el resultado final del crecimiento al final de la temporada). Sin embargo, en ambos viñedos, la relación entre el peso de la madera de poda y los valores de la primera componente fue mayor que con los mapas de NDVI en el envero, lo que sugiere que **el mapa de la primera componente calculado a partir de la metodología f-PCA da mejor cuenta del vigor de la vid que un único mapa en el envero.**

El primer componente principal también está relacionado con otros parámetros como el rendimiento, el peso del racimo y el ácido tartárico en el viñedo A, pero sólo con el ácido tartárico en el viñedo B. Además, se encontraron fuertes **correlaciones significativas con variables del**

suelo como el contenido de arena y limo, la capacidad de intercambio catiónico, el contenido de materia orgánica y la conductividad eléctrica aparente. Los resultados destacados aquí son consistentes con otros resultados de la literatura, mostrando que el vigor de la vid está a menudo relacionado con las características del suelo (Hidalgo, 2006). Parece que el **primer componente principal del f-PCA integra los cambios en el NDVI a lo largo de todo el periodo vegetativo**. Este **primer resultado confirma la pertinencia del f-PCA**, sin embargo, se deben que analizar los demás componentes para investigar su información adicional.

Las correlaciones entre el **segundo componente** de cada viñedo y sus variables **difieren**. En el viñedo A, es coherente con las variables del suelo, como el contenido de arcilla y arena, la conductividad aparente del suelo y la capacidad de intercambio catiónico, mostrando zonas claras que se desvían de la tendencia principal de vigor (crecimiento) destacada por el primer componente y relacionada con las variaciones del suelo. Sin embargo, en el viñedo B, el segundo componente está más correlacionado con las variables de la planta que con el mapa de envero, mostrando que la correlación entre el rendimiento y el PC2 es alta. La interpretación del **tercer componente** debe hacerse con prudencia, ya que **explica menos del 5% de la varianza total**.

Los **tres componentes** muestran **patrones espaciales claros**, con diferentes zonas enlazadas con las observaciones de campo. Como era de esperar, los componentes adicionales dieron lugar a mapas más ruidosos, lo que apoya la decisión de **utilizar solo tres componentes**. Las componentes, segunda y tercera, pueden considerarse ajustes de la tendencia general. No obstante, su información puede ser explicada con experiencia agronómica y un conocimiento particularmente bueno del manejo del campo. Además, cada componente presenta variaciones en distintos periodos del año. Las variaciones más notables se observan en junio, relacionadas con la compleja dinámica del viñedo. Sin embargo, para la mayoría de los viñedos, **dos o tres componentes serían suficientes** para explicar la mayor parte de la variabilidad a lo largo del tiempo, ya que más componentes sólo pueden contener ruido engañoso e información inservible.

Adicionalmente, se creó un **mapa de la varianza no explicada** en cada momento. La figura 21 presenta los mapas de los residuos en cuatro fechas críticas de la estación. Se calculó considerando la diferencia entre los valores de NDVI reconstruidos y los originales en una fecha determinada. Dado que los residuos pueden calcularse en cualquier fecha, la principal ventaja es obtener una **interpretación temporal más precisa** de la capacidad de modelización del f-PCA a lo largo del tiempo.

A primera vista, los **mapas de residuos tienden a ser similares** a los mapas de puntuaciones para algunas fechas, lo que no es sorprendente porque las zonas con puntuaciones bajas tienden a ser subestimadas mientras que las puntuaciones altas tienden a ser sobreestimadas por el modelo.



Figura 21 - Residuos locales obtenidos en diferentes fechas durante la reconstrucción del NDVI utilizando combinaciones de componentes del PCA. Arriba: Viñedo A; Abajo: Viñedo B. En cada imagen: fila superior: PCA 1, media: PCA 1 + 2, inferior: PCA 1 + 2 + 3.

En comparación con las mediciones mapeadas mediante *kriging*, los residuos del primer componente son coherentes a lo largo del ciclo fenológico con la capacidad de intercambio catiónico y las **variables del suelo**, mostrando una depresión en el centro-oeste y el este del viñedo. Los residuos del primer componente también son consistentes con otras variables como la conductividad aparente del suelo y la materia orgánica del suelo. En el viñedo B, los residuos de la primera componente son claramente coherentes con la gestión del viñedo y los clones y, quizás, con las escorrentías de agua temporales, destacando las diferencias en este periodo de alto crecimiento vegetativo y mostrando diferencias entre las partes oeste y este del viñedo.

Por último, también es interesante señalar que, aunque el método f-PCA no tiene en cuenta la autocorrelación espacial, los componentes obtenidos muestran naturalmente una fuerte estructura espacial, lo que significa que la **información espacial no es necesaria en el proceso**.

Los principales hallazgos de este trabajo pueden ser enfocados de dos formas. La primera es la **aplicación del método**: hasta donde sabemos, no existe ningún estudio que utilice los datos

temporales de Sentinel-2 para descomponer los comportamientos del viñedo en varios componentes clave. La segunda es el conocimiento aportado de la variabilidad dentro del viñedo y la **importancia creciente de las imágenes por satélite** (Viticultura de precisión y teledetección). Los resultados apoyan las observaciones comunes sobre la variabilidad dentro del viñedo (Tisseyre et al., 2008) y la variabilidad observada por Sentinel-2 (Devaux et al., 2019). Además, apoya la observación de que las medidas indirectas como el NDVI pueden tener dificultades para describir varias fuentes de variabilidad en el viñedo (Hall et al., 2010), apoyando así la **necesidad de algoritmos de descomposición**.

7. Resultados y discusión del Capítulo VI

En el Capítulo VI, correspondiente al capítulo del libro "*Chapter 10. Remote Sensing: In the Digital Viticulture Era*" ("Teledetección: en la era de la viticultura digital") se abordaron diversas cuestiones acerca del empleo de teledetección en viticultura. Hay muchas formas prácticas de incorporar las técnicas de teledetección a la gestión de los viñedos, como el empleo del NDVI en función del vigor para dividir el viñedo en subzonas o la estimación de parámetros de calidad y agronómicos en el campo. En el ámbito de la investigación, se han utilizado algoritmos para predecir los rendimientos o modelizar el desarrollo de los cultivos, haciéndose patente que estas aplicaciones se están extendiendo al sector productivo gradualmente. **La teledetección es una herramienta esencial para mejorar la sostenibilidad del viñedo y su adaptación al cambio climático**, teniendo en cuenta que el término "teledetección" abarca **varias tecnologías** y que éstas pueden utilizarse en el viñedo para diversas aplicaciones. Es posible utilizar estas técnicas invirtiendo en equipos o empleando imágenes de satélite, entre las que se encuentran los satélites Sentinel-2, que proporcionan información valiosa y gratuita. El **gran reto** de esta "**era digital en la viticultura**" es disponer de profesionales con la suficiente formación para aprovechar las oportunidades que brinda esta tecnología y ofrecer soluciones prácticas al sector vitivinícola.

8. Resultados y discusión del Capítulo VII

La relación del **NDVI con las levaduras** puede ser **compleja de explicar**, aunque quizá no más difícil que otros parámetros de calidad, como la acidez de la uva, que puede ser relacionada con la cantidad de vegetación de la planta (Hidalgo, 2006). De este modo, se estableció la cantidad de vegetación como el nexo entre las imágenes y la cantidad total de levaduras, asumiendo que a mayor NDVI, mayor cantidad de vegetación y por tanto mayor cantidad de levaduras. Este resultado puede explicarse debido a que el NDVI representa el desarrollo vegetativo de un grupo específico de vides dentro de cada píxel (Capítulo II) y, al igual que el NDVI, las **levaduras se ven afectadas** por factores como la intervención humana (Drumonde-Neves, 2016) o las variaciones en la vegetación de cobertura y el suelo (Botha, 2006).

En el Capítulo VII se emplearon imágenes **Landsat-8 de 3 años consecutivos** (2013, 2014, 2015) y datos de los 14 viñedos comerciales descritos anteriormente, plantados en Galicia. Los resultados confirman la existencia de una correlación entre NDVI y la riqueza de especies de levaduras (S), mostrando una **correlación moderada y positiva entre el NDVI y S** para todo el conjunto de datos ($r = 0,3894$, $p = 0,0119$). Además, los resultados mostraron que, en relación con el NDVI y la riqueza de especies de levaduras, los factores de *terroir* más influyentes estudiados en este trabajo fueron la temperatura y las precipitaciones. No es sorprendente, ya que estos factores aumentan la vegetación y el verdor, que afectan al NDVI, y estos factores también son **óptimos para el desarrollo de las levaduras** (Barata et al., 2012). Además, cabe destacar que existe una clara separación entre las DO y que se encontró una mayor riqueza de especies en Rías Baixas y Ribeira Sacra, los DOs con los valores más altos de NDVI.

9. Referencias

- Arnó, J., Escolà, A., Vallès, J. M., Llorens, J., Sanz, R., Masip, J., Palacín, J., & Rosell-Polo, J. R. (2013). Leaf area index estimation in vineyards using a ground-based LiDAR scanner. *Precision Agriculture*, 14(3), 290–306. <https://doi.org/10.1007/s11119-012-9295-0>
- Barajas, E. (2011). Comportamiento fisiológico y agronómico y calidad de la uva de la variedad tempranillo, en función de la distancia entre cepas, en el Valle del Río Duero. (Tesis de Doctorado, Universidad de Valladolid). Repositorio Institucional – Universidad de Valladolid.
- Barata, A., Malfeito-Ferreira, M., & Loureiro, V. (2012). The microbial ecology of wine grape berries. *International Journal of Food Microbiology*, 153(3), 243–259. <https://doi.org/10.1016/j.ijfoodmicro.2011.11.025>
- Beeri, O., Netzer, Y., Munitz, S., Mintz, D. F., Pelta, R., Shilo, T., Horesh, A., & Mey-tal, S. (2020). Kc and LAI Estimations Using Optical and SAR Remote Sensing Imagery for Vineyards Plots. *Remote Sensing*, 12(21), 3478. <https://doi.org/10.3390/rs12213478>
- Blouin, J. & Guimberteau, G. (2004). Maduración y madurez de la uva. Mundi-Prensa.
- Botha, A. (2006). Yeasts in Soil. Biodiversity and Ecophysiology of Yeasts, Springer Science and Business Media LLC: Berlin/Heidelberg, Germany, pp. 221–240.
- Carlson, T. N., & Ripley, D. A. (1997). On the relation between NDVI, fractional vegetation cover, and leaf area index. *Remote Sensing of Environment*, 62(3), 241–252. [https://doi.org/10.1016/S0034-4257\(97\)00104-1](https://doi.org/10.1016/S0034-4257(97)00104-1)
- Castrillo, D. (2018). Estudio de la diversidad de levaduras en uva de cultivo ecológico y convencional en Galicia: Patrones biogeográficos e influencia en las características químicas y sensoriales del vino. (Tesis doctoral, Universidad de León). Repositorio de tesis de la Universidad de León.
- Comba, L., Biglia, A., Ricauda Aimonino, D., Tortia, C., Mania, E., Guidoni, S., & Gay, P. (2020). Leaf Area Index evaluation in vineyards using 3D point clouds from UAV imagery. *Precision Agriculture*, 21(4), 881–896. <https://doi.org/10.1007/s11119-019-09699-x>
- Coombe, B.G. & Dry, P.R. (2001). *Viticulture*, vol. 2. Practices, (7th ed). Winetitles.
- Devaux, N., Crestey, T., Leroux, C., & Tisseyre, B. (2019). Potential of Sentinel-2 satellite images to monitor vine fields grown at a territorial scale. *OENO One*, 53(1). <https://doi.org/10.20870/oenone.2019.53.1.2293>
- Diago, M. P., Correa, C., Millán, B., Barreiro, P., Valero, C., & Tardaguila, J. (2012). Grapevine Yield and Leaf Area Estimation Using Supervised Classification Methodology on RGB Images Taken under Field Conditions. *Sensors*, 12(12), 16988–17006. <https://doi.org/10.3390/s121216988>
- Drumonde-Neves, J., Franco-Duarte, R., Lima, T., Schuller, D., & Pais, C. (2016). Yeast Biodiversity in Vineyard Environments Is Increased by Human Intervention. *PLOS ONE*, 11(8), e0160579. <https://doi.org/10.1371/journal.pone.0160579>

- Easlon, H. M., & Bloom, A. J. (2014). Easy Leaf Area: Automated digital image analysis for rapid and accurate measurement of leaf area. *Applications in Plant Sciences*, 2(7), 1400033. <https://doi.org/10.3732/apps.1400033>
- Fountas, S., Anastasiou, E., Balafoutis, A., Koundouras, S., Theoharis, S. & Theodorou, N. (2014). The influence of vine variety and vineyard management on the effectiveness of canopy sensors to predict winegrape yield and quality. In *Proceedings of the International Conference of Agricultural Engineering*, Zurich, Switzerland, 6–10 July 2014.
- Fuentes, S., Poblete-Echeverría, C., Ortega-Farias, S., Tyerman, S., & De Bei, R. (2014). Automated estimation of leaf area index from grapevine canopies using cover photography, video and computational analysis methods: New automated canopy vigour monitoring tool. *Australian Journal of Grape and Wine Research*, 20(3), 465–473. <https://doi.org/10.1111/ajgw.12098>
- Hall, A., Lamb, D. W., Holzapfel, B. P., & Louis, J. P. (2010). Within-season temporal variation in correlations between vineyard canopy and winegrape composition and yield. *Precision Agriculture*, 12(1), 103–117. <https://doi.org/10.1007/s11119-010-9159-4>
- Hall, A., Louis, J., & Lamb, D. (2008). Low-resolution remotely sensed images of winegrape vineyards map spatial variability in planimetric canopy area instead of leaf area index. *Australian Journal of Grape and Wine Research*, 14(1), 9–17. <https://doi.org/10.1111/j.1755-0238.2008.00002.x>
- Hidalgo, J. (2006). *La calidad del vino desde el viñedo*. Mundi-Prensa.
- Jackson, R. (2020). *Wine Science: Principles and Applications*, 5th ed. Elsevier.
- Johnson, L. F. (2003). Temporal stability of an NDVI-LAI relationship in a Napa Valley vineyard. *Australian Journal of Grape and Wine Research*, 9(2), 96–101. <https://doi.org/10.1111/j.1755-0238.2003.tb00258.x>
- Johnson, L. F., & Pierce, L. L. (2004). Indirect Measurement of Leaf Area Index in California North Coast Vineyards. *HortScience*, 39(2), 236–238. <https://doi.org/10.21273/hortsci.39.2.236>
- Kalisperakis, I., Stentoumis, C., Grammatikopoulos, L., & Karantzalos, K. (2015). Leaf Area Index estimation in vineyards from UAV hyperspectral data, 2D image mosaics and 3D canopy surface models. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL-1/W4, 299–303. <https://doi.org/10.5194/isprsarchives-xl-1-w4-299-2015>
- Keller, M. (2015). *The Science of Grapevines: Anatomy and Physiology*. (2nd edition). Elsevier/AP, Academic Press.
- López-Lozano, R., & Casterad, M. (2013). Comparison of different protocols for indirect measurement of leaf area index with ceptometers in vertically trained vineyards. *Australian Journal of Grape and Wine Research*, 19(1), 116–122. <https://doi.org/10.1111/ajgw.12005>
- López-Lozano, R., Duveiller, G., Seguini, L., Meroni, M., García-Condado, S., Hooker, J., Leo, O., & Baruth, B. (2015). Towards regional grain yield forecasting with 1km-resolution EO biophysical products: Strengths and limitations at pan-European level. *Agricultural and Forest Meteorology*, 206, 12–32. <https://doi.org/10.1016/j.agrformet.2015.02.021>

- Mathews, A., & Jensen, J. (2013). Visualising and Quantifying Vineyard Canopy LAI Using an Unmanned Aerial Vehicle (UAV) Collected High Density Structure from Motion Point Cloud. *Remote Sensing*, 5(5), 2164–2183. <https://doi.org/10.3390/rs5052164>
- McClellan, R. C., McCool, D. K., & Rickman, R. W. (2012). Grain yield and biomass relationship for crops in the Inland Pacific Northwest United States. *Journal of Soil and Water Conservation*, 67(1), 42–50. <https://doi.org/10.2489/jswc.67.1.42>
- Mirasi, A., Mahmoudi, A., Navid, H., Valizadeh Kamran, K., & Asoodar, M. A. (2021). Evaluation of sum-NDVI values to estimate wheat grain yields using multi-temporal Landsat OLI data. *Geocarto International*, 36(12), 1309–1324. <https://doi.org/10.1080/10106049.2019.1641561>
- Panek, E., & Gozdowski, D. (2020). Analysis of relationship between cereal yield and NDVI for selected regions of Central Europe based on MODIS satellite data. *Remote Sensing Applications: Society and Environment*, 17, 100286. <https://doi.org/10.1016/j.rsase.2019.100286>
- Panek, E., Gozdowski, D., Stępień, M., Samborski, S., Ruciński, D., & Buszke, B. (2020). Within-Field Relationships between Satellite-Derived Vegetation Indices, Grain Yield and Spike Number of Winter Wheat and Triticale. *Agronomy*, 10(11), 1842. <https://doi.org/10.3390/agronomy10111842>
- Pérez M.A. (2002). Densidad de plantación y riego: Aspectos ecofisiológicos, agronómicos y calidad de la uva en cv. Tempranillo (*Vitis vinifera* L.). (Tesis Doctoral, Universidad Politécnica de Madrid). Repositorio de tesis de la Universidad Politécnica de Madrid.
- Remison, S. U., & Akinleye, D. (1979). A Note on the Relationship Between Leaf Area and Yield of Maize Varieties. *East African Agricultural and Forestry Journal*, 45(2), 124–129. <https://doi.org/10.1080/00128325.1979.11663033>
- Reynolds, A.G. (2010). *Managing Wine Quality. Volume 1: Viticulture and wine quality*. Woodhead Publishing.
- Santesteban, L.G., Urretavizcaya, I., Miranda, C. & Royo, J.B. (2014). Delineación de unidades de manejo diferenciado (UMD) del viñedo e interpretación desde un punto de vista enológico. *ACE, Revista de enología*. 144.
- Tan, C., Zhou, X., Zhang, P., Wang, Z., Wang, D., Guo, W., & Yun, F. (2020). Predicting grain protein content of field-grown winter wheat with satellite images and partial least square algorithm. *PLOS ONE*, 15(3), e0228500. <https://doi.org/10.1371/journal.pone.0228500>
- Tisseyre, B., Mazzoni, C., & Fonta, H. (2008). Within-field temporal stability of some parameters in Viticulture: potential toward a site specific management. *OENO One*, 42(1), 27–39. <https://doi.org/10.20870/oeno-one.2008.42.1.834>
- Towers, P. C., Strever, A., & Poblete-Echeverría, C. (2019). Comparison of Vegetation Indices for Leaf Area Index Estimation in Vertical Shoot Positioned Vine Canopies with and without Grenbiule Hail-Protection Netting. *Remote Sensing*, 11(9), 1073. <https://doi.org/10.3390/rs11091073>

White, W. A., Alsina, M. M., Nieto, H., McKee, L. G., Gao, F., & Kustas, W. P. (2018). Determining a robust indirect measurement of leaf area index in California vineyards for validating remote sensing-based retrievals. *Irrigation Science*, 37(3), 269–280. [https://doi.org/10.1007/s00271-018-0614-](https://doi.org/10.1007/s00271-018-0614-8)

8



CONCLUSIONES

CONCLUSIONES

El potencial de la teledetección se basa en la versatilidad de sus aplicaciones. De este modo, en cada Capítulo se dio respuesta a problemáticas específicas:

i) En el Capítulo I, el uso de las imágenes del satélite Sentinel-2 para clasificar viñedos, separados por una distancia de hasta 3,5 km, demostró ser útil, puesto que, con una sola imagen, se captaron todos los viñedos simultáneamente. A su vez, se observó que cuanto mayor es el NDVI, mayor es el peso de madera de poda, actuando como un indicador del vigor. El aumento del vigor implica también un aumento de los demás parámetros agronómicos, incluido el rendimiento, aunque no se demostró una relación precisa con los parámetros de calidad.

ii) En el Capítulo II, se demostró que la reducción del NDVI calculado a partir de imágenes Sentinel-2, afectadas por el fenómeno de los píxeles mixtos, y la reducción de la vegetación dentro del píxel en un viñedo típico conducido en espaldera vertical, mantienen una correlación proporcional, siguiendo una relación lineal aproximada de 1:3. Es decir, existe una relación clara, demostrable y estable entre el NDVI del satélite y la vegetación contenida en el viñedo.

iii) En el Capítulo III, se desarrolló un método sencillo y eficaz para estimar el LAI en viñedos, basado en una buena planificación del vuelo de UAV para captar las sombras de las plantas proyectadas sobre el suelo y el uso de algoritmos de clasificación. Este método alcanza una fuerte relación positiva entre el área sombreada y el área foliar de las vides, permitiendo una buena precisión en la estimación del LAI. Los resultados del estudio son interesantes porque el LAI es un parámetro esencial para la gestión del viñedo, así como para su zonificación. Además, esta metodología es totalmente compatible con otras basadas en la teledetección, y permite trabajar en momentos del día distintos a los usualmente utilizados por técnicas similares.

iv) En el Capítulo IV, se demostró que las metodologías empleadas en viñedo son aplicables a otros cultivos leñosos. De este modo, el NDVI es un buen índice para clasificar las diferentes zonas de parcelas de pistacho según su capacidad productiva.

v) En el Capítulo V, se constata que el análisis funcional combinado con métodos de reducción de la dimensionalidad (f-PCA, f-PLS) es una herramienta prometedora para extraer información de las series temporales de NDVI Sentinel-2 en viñedo, otorgando mejores resultados que el empleo de una imagen de enero. Los componentes del f-PCA fueron capaces de explicar la variabilidad espacial de varios parámetros clave del cultivo, destacando la necesidad de analizar cada componente por separado, lo que añade información complementaria y valiosa.

vi) En el Capítulo VII se exploró el uso potencial de imágenes multiespectrales de satélite para detectar diferencias en el terruño (*terroir*) y la población de levaduras. Los resultados sugieren que es posible utilizar la teledetección para la delimitación de DO y que el NDVI está relacionado positivamente con las levaduras, ya que cuanto más alto es el NDVI, más alta es la

riqueza de especies de levadura durante el mismo año, probablemente vinculado a la presencia de una mayor vegetación en el área del píxel. Los resultados son interesantes y con gran potencial, no obstante, debido a que el estudio es original en su concepto, sería necesario estudiar estas relaciones con experimentos diseñados específicamente para tal fin.

En general, para desarrollar el potencial de la teledetección, se deben adaptar i) los métodos de campo, realizando un manejo adecuado del viñedo (laboreo, herbicidas, etc.), controlando su variabilidad para asegurar un cultivo de vid sano en el que analizar desviaciones, así como un suelo libre de malas hierbas que no produzca interferencias en las lecturas del cultivo; ii) los métodos de procesamiento y análisis a las resoluciones y características de la información espectral disponible, seleccionando los más convenientes con el fin de extraer información agronómica relevante. De este modo, las imágenes de satélite requieren construir series temporales para que su resolución temporal compense su baja resolución espacial; sin embargo, las imágenes de alta resolución requieren su combinación con algoritmos de clasificación para estimar parámetros agronómicos de forma precisa.

En la presente tesis doctoral, se dio respuesta a los objetivos propuestos, aportando conocimientos y herramientas tecnológicas para la caracterización de los viñedos según su heterogeneidad. En cuanto a los objetivos específicos, se cumplieron todos ellos: i) las soluciones planteadas permiten cuantificar la relación entre la información espectral obtenida de las imágenes y los parámetros del viñedo, ii) permiten implementar herramientas para establecer unidades de manejo diferenciado en viñedo, incluyendo aquellas derivadas de imágenes Sentinel-2, iii) se verificó que las diferencias se trasladan a los vinos elaborados de esas unidades diferenciadas, iv) las herramientas empleadas permiten monitorizar el viñedo de forma dinámica, v) son herramientas basadas en teledetección, accesibles para los productores y de bajo coste y vi) aportan conocimiento práctico, que puede ser empleado por el sector. Además, los experimentos de campo incluyeron diversos cultivares de vid, en diferentes localidades, y en distintas situaciones de cultivo, reforzando la validez de los resultados a nivel global, respecto a la aplicación de teledetección en viticultura.

Por todo ello, se justifica que la teledetección es una herramienta valiosa para monitorizar y gestionar eficientemente el viñedo. Además, posibilita la creación de unidades de manejo diferenciado de diversos modos, bien a nivel de parcela completa, a nivel de subparcela o incluso a nivel de planta. Para el empleo de esta herramienta, quizá la idea más relevante de la presente tesis doctoral es la recogida en Capítulo VI: el gran reto de esta "era digital en la viticultura" es disponer de profesionales con la suficiente formación para aprovechar las enormes oportunidades que brinda este tipo de tecnología y ofrecer soluciones prácticas a los viticultores, técnicos, elaboradores y al conjunto del sector vitivinícola.



CONCLUSIONS

CONCLUSIONS

The potential of remote sensing is based on the versatility of its applications. Therefore, in each chapter, specific problems were addressed:

i) In Chapter I, the use of Sentinel-2 satellite imagery to classify vineyards spaced up to 3.5 km apart was helpful because a single image covered all vineyards simultaneously. The higher the NDVI, the higher the pruning wood weight, as an indicator of vigour. Increased vigour also implies an increase in the other agronomic parameters, including yield, although no precise relationship with quality parameters was observed.

ii) In Chapter II, it was analysed the relationship between the reduction of NDVI calculated from Sentinel-2 images, affected by the mixed pixel phenomenon, and the reduction of vegetation within the pixel in a typical vertically trellised vineyard. It was found a proportional correlation, following an approximately linear relationship of 1:3. Therefore, there is a clear and stable relationship between the satellite NDVI and the vegetation contained in the vineyard.

iii) In Chapter III, a simple and effective method for estimating LAI in vineyards was developed, based on good UAV flight planning to capture plant shadows projected on the ground and the use of classification algorithms. A strong positive relationship was observed between the shaded area and the leaf area of the vines, allowing a good accuracy in the LAI estimation. The results of the study are interesting because LAI is an essential parameter for vineyard management as well as for vineyard zoning. Moreover, this methodology is fully compatible with other remote sensing methodologies and allows working at different times of the day than those usually used by similar techniques.

iv) In Chapter IV, it was shown that the methodologies used in vineyards apply to other woody crops. Thus, NDVI is a good index for classifying the different pistachio plots according to their productive capacity.

v) In Chapter V, functional analysis combined with dimensionality reduction methods (f-PCA, f-PLS) was found to be a promising tool for extracting information from NDVI Sentinel-2 time series in vineyards. The f-PCA components were able to explain the spatial variability of several key crop parameters, highlighting the need to analyse each component separately, which adds complementary and valuable information.

vi) Chapter VII explored the potential use of multi-spectral satellite imagery to detect differences in *terroir* and yeast population. The results suggest that it is possible to use remote sensing to delineate AOPs. Moreover, NDVI is related to yeast species richness, as the higher the NDVI, the higher the yeast species richness during the same year, probably linked to the higher vegetation in the pixel area. This study is original and, although the results are interesting, they need to be validated in experiments specifically designed to study these correlations.

In order to develop the potential of remote sensing, it is necessary to adapt i) field methods, carrying out adequate vineyard management (tillage, herbicides, etc.), controlling its variability to ensure a healthy vineyard crop to analyse deviations, as well as a soil free of weeds that do not interfere with vineyard vegetation; ii) processing and analysis methods to the resolutions and characteristics of the available spectral information, selecting the most suitable ones in order to extract relevant agronomic information. Thus, satellite images require building time series so that their temporal resolution balances their low spatial resolution; however, high-resolution images require their combination with classification algorithms to estimate agronomic parameters accurately.

The proposed objectives were met in this PhD thesis, providing knowledge and tools for the characterisation of vineyards according to their heterogeneity. Regarding the specific objectives, all of them were met, given that the solutions proposed in this thesis allow i) quantifying the relationship between the spectral information obtained from the images and the vineyard parameters, ii) implementing tools to establish differentiated vineyard management units, including those derived from Sentinel-2 images, iii) it was verified that the differences are transferred to the wines produced from these differentiated units, iv) the tools allow vineyard dynamic monitoring, v) they are low-cost remote sensing-based tools, accessible to producers, and vi) they provide knowledge and present a valuable product for the sector. Furthermore, the field experiments consisted of different vine cultivars in different locations and growing situations, reinforcing the validity of the results regarding the use of remote sensing in viticulture.

Therefore, it is concluded that remote sensing is a valuable tool for vineyard monitoring and management. Moreover, it enables the creation of differentiated management units in various ways, either at the whole vineyard level, the plot level or even at the plant level. In order to use this tool, perhaps the most relevant idea of this doctoral thesis is the one presented in Chapter VI: the great challenge of this "digital era in viticulture" is to have professionals with sufficient training to take advantage of the immense opportunities offered by this technology and to offer practical solutions to winegrowers, technicians, winemakers and the wine sector as a whole.

