



**UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA**

**Programa de Doctorado en Diseño, Fabricación y Gestión de
Proyectos Industriales**

TESIS DOCTORAL

**Estudio y desarrollo de soluciones mecanizadas
automatizadas mediante la aplicación de sensores y
nuevas tecnologías para la producción de cítricos**

María Gyomar González González

Directores:

Dra. Patricia Chueca Adell

Prof. Dr. José Blasco Ivars

Valencia, febrero 2022

Dra. Patricia Chueca Adell, Doctora en Ingeniería Agrónoma y Licenciada en Ciencias Ambientales por la Universidad Politècnica de Valencia y Responsable del Àrea de Mecanización del Centro de Agroingeniería del Instituto Valenciano de Investigaciones Agrarias (IVIA)

Prof. Dr. José Blasco Ivars, Doctor en Informática por la Universidad Politècnica de Valencia y Coordinador del Centro de Agroingeniería del Instituto Valenciano de Investigaciones Agrarias (IVIA)

CERTIFICAN:

Que la Ingeniería Industrial Dña. María Gyomar González González ha realizado bajo nuestra dirección la Tesis Doctoral titulada **“Estudio y desarrollo de soluciones mecanizadas automatizadas mediante la aplicación de sensores y nuevas tecnologías para la producción de cítricos”** de la que es autora, que se presenta en esta memoria en calidad de TESIS DOCTORAL, correspondiente al programa de doctorado de Diseño, Fabricación y Gestión de Proyectos Industriales; y cumple los requisitos académicos exigidos por la Legislación vigente para optar al título de Doctora por la Universidad Politècnica de Valencia.

Y para que conste a los efectos oportunos, firman el presente informe.

Valencia, febrero 2022

**PATRICIA
CHUECA
ADELL**
Firmado digitalmente por PATRICIA|CHUECA|ADELL
Fecha: 2022.02.14 06:41:20 +01'00'

Fdo.: Dra. Patricia Chueca Adell

**RJUÒÁ
ÓŠŒJÒUÁ
XŒJÙÄ
PŒGJÍ JFÌ
FÓ**
Øā(œā[Á
āā āā(^) œÁ
] |; RJUÒÁ
ÓŠŒJÒUÁ XŒJÙÄ
PŒGJÍ JFÌ FÓ
Ø^ & œāŒŒŒŒŒH
€JK FÉŒFŒ€

Fdo.: Prof. Dr. José Blasco Ivars

*A todos aquellos que no tuvieron una
despedida memorable, siendo
grandísimas personas
C.S.V*

*Adriana Rudling – “Fui a ver Spiderman No Way Home y les dejo esta
preocupación nueva: cantidad de villanos con doctorado”*

*Un Luis navideño más – “Es que para terminar un doctorado hay que
tener un problema mental o directamente ser malvado”*

*“Nunca confundas educación con inteligencia,
puedes tener un doctorado y seguir siendo idiota”*

Richard Feynman



Agradecimientos

Deseo expresar mi gratitud y reconocimiento sincero a todas las personas y entidades que han hecho posible, de una u otra manera, que yo haya podido realizar este Trabajo de Investigación:

A la Dra. Patricia Chueca Adell, doctora Ingeniera Agrónoma y Licenciada en Ciencias ambientales por la Universidad Politécnica de Valencia y responsable del área de mecanización del Centro de Agroingeniería del Instituto Valenciano de Investigaciones Agrarias (IVIA), y codirectora de esta Tesis.

Al Prof. Dr. José Blasco Ivars, doctor en Informática por la Universidad Politécnica de Valencia y Coordinador del Centro de Agroingeniería del Instituto Valenciano de Investigaciones Agrarias (IVIA), y codirector de esta Tesis.

A la Prof. Dra. Nuria Aleixos Borrás, doctora en Informática por la Universidad Politécnica de Valencia y Catedrática de Universidad del Departamento de Ingeniería Gráfica, y tutora de esta Tesis.

Al Dr. Emilio Soria Olivas y al Dr. Juan Gómez Sanchis del Intelligent Data Analysis Laboratory (IDAL) en la Escuela Técnica Superior de Ingeniería de la Universitat de València, supervisor y tutor en mi estancia de investigación.

A todos mis compañeros del centro de Agroingeniería, tanto a los que aún están como los que estuvieron, con mención especial a Enrique, Sergio, Iván, Alberto, Juanjo, José Ramón y Guillermo.

A todos los trabajadores del resto de centros y administración del IVIA, y al personal de limpieza, de garita y de VAERSA, TRAGSA y STT, con mención especial a mis Anas, Manolo, Jesús, Mónica, Luis, Santi, Carme y al clan DinoIVIA.

A todas esas personas que he conocido a lo largo de esta tesis por todo lo bueno y lo malo que he aprendido de ellas.



Al Instituto Nacional de Investigaciones y Tecnología Agraria y Alimentaria (INIA), por la financiación recibida a través del contrato predoctoral FPI INIA (CPD2016-0007, #42).

A la Universidad Politécnica de Valencia (UPV), al Instituto Valenciano de Investigaciones Agrarias (IVIA), al Intelligent Data Analysis Laboratory (IDAL), a la Universidad de Valencia (UV), al Taller Luis Pradas, a Bonanza y a todos los dueños de las diferentes parcelas no pertenecientes al IVIA.



A los pedazos de soles que se han unido a mi comunidad del anillo Virginio, Jessica, Santi, Vicente y Carlos Bataller, por TODO.

A mi familia y amigos de la comunidad del anillo, tanto a los que aún están como los que estuvieron. Con mención especial a mis padres, Paco y Cande, por quererme siempre incondicionalmente; a Sánchez y Josema, por haber aguantado tantos años y los que nos quedan; y, en especial, a ti Roberto, por emprender lo más importante en la vida juntos.

¡OS QUIERO A TODOS!

Por último, no quiero despedirme sin pedir PERDÓN a todos y cada uno, no sólo de los nombrados sino de todas aquellas personas que se hayan podido sentir ofendidas o molestas por alguna de mis acciones o decisiones. Pido disculpas de todo corazón.

Aunque no esté relacionado directamente con mi trabajo de tesis, nunca estaré suficientemente agradecida al personal, sanitario y no sanitario, que ha trabajado dejándose la piel durante la pandemia, a todas aquellas personas que dieron su vida por ofrecer un respirador a personas con “más probabilidades de vivir”, a todos aquellos que ya no están.

Por último, quiero recordar también a las personas que trabajan en las distintas entidades relacionadas con la investigación que, en la aprobación de la Ley de la Ciencia, se eliminó el antiguo y nefasto sistema de becas doctorales. Ahora el personal investigador pre y posdoctoral tiene contratos y, por lo tanto, derechos laborales. Aún falta un largo camino por recorrer en la lucha por la igualdad de derechos de los predoctorales y, sobre todo, de todos los becarios y personas en formación que hay ejerciendo en la sombra funciones de trabajador sin contratos y sin derechos.

#sinciencianohayfuturo



Tabla de Contenidos

TABLA DE CONTENIDOS

TABLA DE CONTENIDOS	2
ABREVIATURAS Y ACRÓNIMOS	7
RESUMEN	10
ABSTRACT	13
RESUM	16
PREFACIO.....	19
1. Marco de la tesis	19
2. Estructura de la memoria.....	20
CAPÍTULO I - INTRODUCCIÓN.....	22
1. Nuevas tecnologías en la agricultura de precisión.....	22
2. AgTech aplicadas en cultivos cítricos	25
2.1. Recolección mecanizada de cítricos.....	25
2.2. Confección de mapas digitales de rendimiento en cítricos	27
2.3. Sistemas avanzados para detección temprana de plagas y enfermedades en cítricos	28
CAPÍTULO II - OBJETIVOS.....	31
1. Objetivo General	31
2. Objetivos específicos.....	31
CAPÍTULO III – PROTOTIPO DE PLATAFORMA DE ASISTENCIA A LA RECOLECCIÓN. IMPLEMENTACIÓN DE MEJORAS Y AVANCES. RENDIMIENTOS DEL PROCESO DE RECOLECCIÓN ASISTIDA	34
Resumen.....	34
1. Introducción	34
2. Objetivos	35
3. Prototipo de plataforma móvil de asistencia a la recolección de cítricos	36
3.1. Descripción del prototipo.....	36
3.2. Funcionalidades del prototipo en campo	38
3.3. Sistema de inspección automática de la fruta recolectada	38
3.4. Mandos de control del prototipo.....	40
3.5. Sistemas de posicionamiento.....	41
3.6. Identificación de necesidades y áreas de mejora en el prototipo	41
4. Identificación de riesgos y medidas de prevención y seguridad implementadas en el prototipo	42
4.1. Elementos de seguridad activa	42
4.2. Elementos de seguridad pasiva.....	46

5.	Identificación de áreas de mejora para asegurar la calidad de la fruta a su paso por el prototipo e implementación de mejoras	48
5.1.	Materiales y métodos.....	48
5.2.	Resultados	49
5.3.	Conclusiones.....	50
5.4.	Identificación de áreas de mejora.....	51
5.5.	Implementación de mejoras	51
6.	Avances en el sistema de inspección y en el control y automatización de las funciones del prototipo	56
6.1.	Avances en el sistema de inspección automática	56
6.2.	Mejoras en el control y la automatización del prototipo y sus funciones	58
7.	Evaluación del funcionamiento del prototipo y determinación del rendimiento de la operación de recolección asistida.....	60
7.1.	Materiales y métodos.....	60
7.1.1.	Parcela experimental.....	60
7.1.2.	Recolección con la plataforma de asistencia	60
7.1.2.1.	Comprobación de la cantidad de fruta recolectada según el sistema de inspección respecto a la cantidad real recolectada por el prototipo	62
7.1.2.2.	Cálculo del rendimiento del proceso de recolección con el prototipo	63
7.1.2.3.	Evaluación del sistema de clasificación del prototipo	63
7.1.2.4.	Evaluación de daños en la fruta	64
7.1.3.	Recolección manual tradicional	65
7.1.3.1.	Cálculo del rendimiento del proceso de recolección manual tradicional	65
7.2.	Resultados y discusión	66
7.2.1.	Recolección con la plataforma de asistencia	66
7.2.1.1.	Incidencias en el prototipo durante la recolección.....	66
7.2.1.2.	Comprobación de la cantidad de fruta recolectada según el sistema de inspección respecto a la cantidad real recolectada por el prototipo	67
7.2.1.3.	Cálculo del rendimiento del proceso de recolección con el prototipo	68
7.2.1.4.	Evaluación del sistema de clasificación del prototipo	69
7.2.1.5.	Evaluación de daños en la fruta	69
7.2.2.	Recolección manual tradicional	69
8.	Conclusiones.....	70
CAPÍTULO IV - CITRUSYIELD: HERRAMIENTA DIGITAL PARA VISUALIZACIÓN GRÁFICA DEL RENDIMIENTO Y LA CALIDAD DE LOS CÍTRICOS		72
Resumen.....		72
1.	Introducción	72

2.	Objetivos	73
3.	Creación de la herramienta digital a modo de cuadro de mando <i>CitrusYield</i>	74
3.1.	Arquitectura e interfaz de <i>CitrusYield</i>	74
3.2.	Método de adquisición de datos.....	74
3.3.	Funcionalidades implementadas en <i>CitrusYield</i>	76
3.3.1.	Variables de entrada en el cuadro de mando <i>CitrusYield</i>	76
3.3.2.	Creación de la base de datos.....	77
3.3.3.	Mapas de producción y calidad.....	78
3.3.4.	Información en los gráficos interactivos	79
3.3.5.	Análisis exploratorio de los datos	80
3.3.6.	Parámetros de rendimiento y eficiencia	83
3.4.	Diagrama de flujo	84
4.	Evaluación del funcionamiento de <i>CitrusYield</i>	85
4.1.	Materiales y métodos.....	85
4.1.1.	Ensayo en campo.....	85
4.1.2.	Entradas en el cuadro de mando <i>CitrusYield</i>	85
4.2.	Resultados y discusión	86
5.	Conclusiones.....	91
CAPÍTULO V - DETECCIÓN AUTOMÁTICA DE <i>TETRANYCHUS URTICAE</i> KOCH EN HOJAS DE CÍTRICOS MEDIANTE IMÁGENES EN COLOR E IMÁGENES HIPERESPECTRALES VIS/NIR.....		93
Resumen.....		93
1.	Introducción	93
2.	Objetivos	95
3.	Materiales y métodos	96
3.1.	Muestreos de hojas.....	96
3.2.	Detección de daños causados por <i>T. Urticae</i> mediante imágenes en color	97
3.2.1.	Adquisición y segmentación de imágenes en color	97
3.2.2.	Definición de los parámetros de discriminación.....	98
3.3.	Detección de daños causados por <i>T. Urticae</i> mediante imágenes hiperespectrales.....	99
3.3.1.	Adquisición de imágenes hiperespectrales.....	99
3.3.2.	Análisis de datos multivariados.....	100
3.3.3.	Evaluación de la eficacia del modelo	101
4.	Resultados y discusión	102
4.1.	Detección de daños causados por <i>T. Urticae</i> mediante imágenes en color	102
4.1.1.	Parámetros de discriminación.....	102

4.1.2. Detección de los daños	103
4.2. Detección de daños causados por T. Urticae mediante imágenes hiperespectrales.....	104
4.2.1. Detección de daño causado por T. Urticae	104
4.2.2. Detección de la antigüedad del daño causado por T. Urticae	106
4.2.3. Discriminación entre daños causados por T. Urticae y otros daños	108
5. Conclusiones.....	112
CAPÍTULO VI - CONCLUSIONES.....	114
CAPÍTULO VII – CONSIDERACIONES FINALES Y RECOMENDACIONES PARA FUTUROS TRABAJOS I+D	119
CAPÍTULO VIII – PRODUCCIÓN CIENTÍFICA Y DIFUSIÓN.....	122
CAPÍTULO IX – BIBLIOGRAFÍA.....	126
ANEXO I – ARTÍCULOS CIÉNTIFICOS	139



Abreviaturas y Acrónimos

ABREVIATURAS Y ACRÓNIMOS

(*) Traducido al castellano.

%	Tanto por ciento	HMI	Interfaz humano-máquina (*)
&	y	ICC	Índice de Color de Cítricos
3D	Tres Dimensiones	IDAL	Intelligent Data Analysis Laboratory
AEI-AGRI	Asociación Europea para la Innovación en materia de productividad y sostenibilidad Agrícolas	IFAPA	Instituto de Investigación y Formación Agraria y Pesquera de Andalucía
AgTech	Tecnología en la Agricultura (*)	INIA	Instituto Nacional de Investigaciones y Tecnología Agraria y Alimentaria
ANOVA	Análisis de Varianza (*)	IoT	Internet de las Cosas (*)
AP	Agricultura de precisión	IRD	Dispositivo electrónico de Grabación de Impacto (*)
C	Calibración	ISBN	Número Estándar Internacional del Libro (*)
CCD	Dispositivo de Carga Acoplada (*)	ISPA	Sociedad Internacional de la Agricultura de Precisión (*)
CV	Validación Cruzada (*)	IVIA	Instituto Valenciano de Investigaciones Agrarias
CC.AA.	Comunidades Autónomas	I+D	Investigación más Desarrollo
DOI	Identificador de Objetos Digitales (*)	JCR	Informes sobre Citas en Revistas Científicas (*)
EPI	Equipos de Protección Individual	KPI	Indicadores Clave de Rendimiento (*)
Etc.	Etcétera	LCD	Pantalla de Cristal Líquido (*)
Et al.	Et alters (y colaboradores)	LDA	Análisis Discriminante Lineal (*)
FAO	Organización de las Naciones Unidas para la Agricultura y la Alimentación (*)	LED	Diodo Emisor de Luz (*)
Fe	Hierro	LSD	Diferencia Menos Significativa (*)
FEADER	Fondo Europeo Agrícola de Desarrollo Rural	LV	Variables Latentes (*)
FEDER	Fondos Europeos de Desarrollo Regional	MAPA	Ministerio de Agricultura, Pesca y Alimentación
FPI	Formación del Personal Investigador	Mn	Manganeso
G	Aceleración gravitacional	N	Nitrógeno
GIP	Gestión Integrada de Plagas	NIR	Infrarrojo cercano (*)
GNSS	Sistema Global de Navegación por Satélite (*)	NP/NND	No plaga/no deficiencia nutricional (*)
GPS	Sistema de Posicionamiento Global (*)	P	Predicción
GRAP	Grupo de Investigación en Agrótica y Agricultura de Precisión	PC	Componentes Principales (*)
GVA	Generalitat Valenciana	PCA	Análisis de Componentes Principales (*)
HDPE	Polietileno de Alta Densidad (*)	PLA	Ácido Poliláctico (*)
HLB	Huanglongbing	PLS	Mínimos Cuadrados Parciales (*)

PLS-DA	Mínimos Cuadrados Parciales Análisis Discriminante (*)	SIG	Sistemas de Información Geográfica
PRL	Prevención de Riesgos Laborales	SSM	Manejo Específico Localizado (*)
P/ND	Plaga/Deficiencia Nutricional (*)	TIC	Tecnologías de la Información y la Comunicación
<i>P.citrella</i>	<i>Phyllocnistis citrella</i>	<i>T.urticae</i>	<i>Tetranychus urticae</i>
Q1	Cuartil 1 (*)	UCO	Universidad de Córdoba
RF	Radiofrecuencia	UE	Unión Europea
RGB	Rojo Verde y Azul (*)	UAV	Vehículos Aéreos no Tripulados (*)
RMSE	Error Cuadrático Medio (*)	UPV	Universidad Politécnica de Valencia
ROI	Región de Interés (*)	UV	Universidad de Valencia
RTA	Recursos y Tecnologías Agrarias	VIS	Visible
RTK	Posicionamiento Cinemático en Tiempo real (*)	VNIR	Visible e infrarrojo cercano (*)
R²	Coefficiente de determinación	VRT	Tecnologías de actuación variable (*)
SI	Sistema Internacional de Unidades	WGS	Sistema Geodésico Mundial (*)
SIMCA	Soft Independent Modelling of Class Analogy	Zn	Zinc



Resumen

RESUMEN

El sector de la citricultura, de gran importancia económica y social a nivel mundial, se enfrenta al desafío de satisfacer la creciente demanda de cítricos en un mercado globalizado, asegurando los requerimientos de calidad, seguridad alimentaria y sostenibilidad de las explotaciones. Para incrementar la producción, la agricultura de precisión impulsa el uso de herramientas para la mecanización, la automatización y la digitalización de procesos mediante la tecnificación de las operaciones agrícolas. Mientras que otros cultivos como la vid, el almendro y el olivar han avanzado en el desarrollo de sistemas productivos intensivos lo que ha permitido la implementación de estas tecnologías, los cítricos, con sistemas productivos tradicionales, presentan aún un bajo grado de tecnificación.

El objetivo de esta Tesis Doctoral es generar conocimiento y tecnología que permitan desarrollar soluciones mecanizadas y automatizadas mediante la aplicación de sensores para monitorizar, optimizar tareas y aumentar la productividad en los cultivos de cítricos y, por ende, la competitividad del sector cítrico. Con este fin, se ha trabajado en la aplicación de tecnologías en algunas de las operaciones más importantes y costosas en la citricultura.

En el ámbito de la recolección, con el objetivo de facilitar y optimizar el proceso de recolección de cítricos para consumo en fresco, se implementaron mejoras estructurales y funcionales en un prototipo de plataforma autopropulsada de asistencia para garantizar la seguridad de los trabajadores y minimizar los riesgos laborales, asegurar la calidad de la fruta recolectada y clasificarla adecuadamente en función de su calidad por un sistema de visión artificial. Tras la implementación de estos avances, se evaluó su funcionalidad en condiciones reales de campo y se determinó el rendimiento de la operación de recolección asistida. Los resultados mostraron que el rendimiento operativo teórico en el proceso de recolección con la asistencia del prototipo fue de $36,50 \text{ h}\cdot\text{ha}^{-1}$, un 17% menor que en la recolección manual tradicional, que fue de $44,12 \text{ h}\cdot\text{ha}^{-1}$.

Asimismo, con la finalidad de generar de manera automática mapas de rendimiento en cítricos accesibles al agricultor, se creó una nueva herramienta digital a modo de cuadro de mando, denominada *CitrusYield*. Esta herramienta es capaz de obtener mapas que muestran la variabilidad de las características medidas por los sensores instalados en el prototipo, haciendo uso de la información proporcionada al inspeccionar cada fruta y de los datos obtenidos por los dispositivos de geolocalización, permitiendo también conocer el rendimiento de la producción a nivel intraparcilario. Se evaluó el funcionamiento de *CitrusYield* con datos reales obtenidos por el prototipo en campo. El cuadro de mando analizó los datos y generó diferentes tipos de mapas georreferenciando la información de la fruta con su punto de recolección. A través de estos mapas, *CitrusYield* demostró su capacidad para reflejar la heterogeneidad de la producción dentro de la parcela. Estas diferencias de producción entre zonas dentro del cultivo también se cuantificaron en las tablas y gráficos generados por la herramienta. Los indicadores de calidad, rendimiento del sistema de inspección por visión artificial y la productividad, calculados por *CitrusYield*, revelaron el grado de efectividad y eficiencia del proceso de recolección con la asistencia del prototipo.

En el ámbito de la detección temprana de plagas y enfermedades, se llevó a cabo la investigación del potencial de la imagen en color y de la imagen hiperespectral para la detección automática de daños causados por la plaga *Tetranychus urticae* en hojas de cítricos. Además, se diferenciaron en función de la antigüedad y de otros problemas que puede tener el árbol causados por deficiencias nutricionales o por otras plagas. En el análisis para identificar el daño causado por esta plaga, se obtuvo una tasa de éxito del 92,5% en las imágenes en color. No obstante, no se pudo discriminar la edad del daño con este método. En las imágenes hiperespectrales, el éxito fue del 100% en la detección del daño y del 92% en la discriminación de la edad. En cuanto a la

discriminación de daños de *T. urticae* respecto a otros daños, en las imágenes en color se obtuvo una tasa de éxito del 100% en la discriminación de *Phyllocnistis citrella* en el envés de las hojas. Las deficiencias de N no pudieron discriminarse correctamente y las deficiencias de Fe, Mn o Zn se detectaron acertadamente en el 50% de los casos. En las imágenes hiperespectrales, los daños por *P. citrella* se discriminaron con éxito en el 100% de los casos, tanto en el haz como en el envés de las hojas. Las deficiencias por N se discriminaron correctamente en más del 65% de los casos también en ambos lados de la hoja. No obstante, las deficiencias de Fe, Mn o Zn no pudieron ser discriminadas correctamente, siendo el porcentaje de daño clasificado acertadamente inferior al 50%.

Las conclusiones de esta Tesis Doctoral ponen de manifiesto el gran potencial de implementar estas tecnologías para monitorizar, optimizar tareas y digitalizar los procesos en las labores llevadas a cabo en los campos de cítricos, de manera que se logra aumentar la eficiencia, productividad y, también, la competitividad en el sector.

Las principales contribuciones de esta investigación se reflejan en la transferencia tecnológica a través de la creación de la herramienta digital inscrita en el registro de propiedad intelectual y en la publicación de los resultados en revistas científicas indexadas en el JCR, en revistas técnicas y de divulgación, en congresos nacionales e internacionales y en capítulos de libros de carácter internacional.



Abstract

ABSTRACT

The citriculture has great economic and social importance worldwide. Nowadays, it faces the challenge of providing the increasing demand of citrus fruits in a global market while ensuring the quality, food safety requirements and the sustainability of farms. In order to increase production in this scenery, precision agriculture promotes the use of tools for the mechanisation, automation and digitisation of processes through the introduction of novel and intelligent technology in agricultural operations. While crops such as vineyards, almond trees and olive groves have advanced in the development of intensive production systems, which has allowed the implementation of these technologies, citrus crops, with traditional production systems, still have a low technological level.

This PhD dissertation aims to generate knowledge and technology to develop mechanised and automated solutions to monitor processes, optimise tasks and increase the productivity of citrus crops and, therefore, the competitiveness of the citriculture sector. For this purpose, this thesis has focused on the development of technologies in some of the most important and costly operations in the citrus sector.

To facilitate and optimise the harvesting of citrus fruits for the fresh market, structural and functional improvements were implemented in a prototype of a self-propelled assistance platform. The research has focused on guaranteeing the operator safety, ensuring the quality of the harvested fruit and classifying it properly based on its quality by an artificial vision system in real-time. The functionality was evaluated in-field conditions and performance was assessed. The results showed that the assisted harvesting process with the platform was more efficient than traditional manual harvesting. A theoretical operation yield of 36,50 h·ha⁻¹ was obtained with the prototype, 17% lower than in conventional manual harvesting, which was 44,12 h ha⁻¹.

Furthermore, in order to automatically generate citrus yield maps accessible for the farmer, a new digital tool was created as a dashboard, called *CitrusYield*. This tool is capable of obtaining maps showing the variability of the features measured by the sensors installed in the prototype, using the information provided during the fruit inspection at harvest and the data obtained by the geolocation device, and also allowing to know the performance of the production at the intra-orchard level. The *CitrusYield* functionality was evaluated with real field data obtained by the prototype. The dashboard analysed the data and generated different types of maps georeferencing the information of the fruit with its harvesting point. Through these maps, the ability of *CitrusYield* to show the heterogeneity of production within the orchard was demonstrated. The production variability was also quantified in the tables and graphs generated by the tool. The indicators of fruit quality obtained by the artificial vision system and the productivity calculated by *CitrusYield* revealed the degree of effectiveness and efficiency of the harvesting process with the prototype.

In the context of early citrus pests and diseases detection, the potential of colour and hyperspectral imaging, as a fast and automatic methods to detect the presence and the age of the damage caused by the *Tetranychus urticae* pest on citrus leaves, were investigated. Another goal was to discriminate this damage from that caused by other pests and from nutritional deficiencies. In the analysis of identifying the damage caused by *T. urticae*, a success rate of 92,5% was obtained in the colour images. However, the age of the damage could not be discriminated with this method. In hyperspectral images, the success rate was 100% in damage detection and 92% in age discrimination. Regarding the discrimination of *T. urticae* damages from others, in the colour images, a success of 100% was obtained in the discrimination of *Phyllocnistis citrella* on the underside of the leaves. N deficiencies could not be correctly discriminated and Fe, Mn or Zn deficiencies were correctly detected in 50% of cases. In the hyperspectral images, *P. citrella* damage was successfully discriminated in 100% of cases, both on the upper and under sides of

the leaves. N deficiencies were correctly discriminated in more than 65% of cases on both sides of the leaf. However, Fe, Mn or Zn deficiencies could not be correctly discriminated, being the percentage of correctly classified damage less than 50%.

The conclusions of this Thesis show the potential of implementing these technologies to monitor, optimize tasks and digitize agricultural processes in the operations usually done in citrus crops. Therefore, the efficiency, productivity and competitiveness of the sector can increase when these technologies are used.

The main contributions of this research on the application of new mechanised and automated solutions in the citriculture are reflected in the technology transfer through the registration of the digital tool *Citrusyield* and the publication of the results in two scientific journals indexed in the JCR, in technical and extension magazines, in book chapters and in national and international conferences.



Resum

RESUM

El sector de la citricultura, de gran importància econòmica i social a nivell mundial, s'enfronta al desafiament de satisfer la creixent demanda de cítrics en un mercat globalitzat, assegurant els requeriments de qualitat, seguretat alimentària i sostenibilitat de les explotacions. Per a incrementar la producció, l'agricultura de precisió impulsa l'ús de ferramentes per a la mecanització, l'automatització i la digitalització de processos per mitjà de la tecnificació de les operacions agrícoles. Mentre que altres cultius com la vinya, l'ametler i l'oliverar han avançat en el desenvolupament de sistemes productius intensius el que ha permès la implementació d'estes tecnologies, els cítrics, amb sistemes productius tradicionals, presenten encara un baix grau de tecnificació.

L'objectiu d'esta Tesi Doctoral és generar coneixement i tecnologia que permeten desenvolupar solucions mecanitzades i automatitzades mitjançant l'aplicació de sensors per a monitoritzar, optimitzar tasques i augmentar la productivitat en els cultius de cítrics i, per tant, la competitivitat del sector cítricol. Amb este fi, s'ha treballat en l'aplicació de tecnologies en algunes de les operacions més importants i costoses de la citricultura.

Amb l'objectiu de facilitar i optimitzar el procés de recol·lecció de cítrics per a consum en fresc es van implementar millores estructurals i funcionals en un prototip de plataforma autopropulsada d'assistència per a garantir la seguretat dels treballadors i minimitzar els riscos laborals, assegurar la qualitat de la fruita recol·lectada i classificar-la adequadament en funció de la qualitat estimada pel sistema de visió artificial. Després de la implementació d'estos avanços, es va avaluar la seua funcionalitat en condicions reals de camp i es va determinar el rendiment de l'operació de recol·lecció assistida. Els resultats van mostrar que el rendiment operatiu teòric en el procés de recol·lecció amb l'assistència del prototip va ser de $36,50 \text{ h}\cdot\text{ha}^{-1}$, un 17% menor que en la recol·lecció manual tradicional, que va ser de $44,12 \text{ h}\cdot\text{ha}^{-1}$.

Així mateix, amb la finalitat de generar de manera automàtica mapes de rendiment en cítrics accessibles a l'agricultor, es va crear una nova eina digital a manera de quadre de comandament, denominada *CitrusYield*. Esta eina és capaç d'obtenir mapes que mostren la variabilitat de les característiques mesurades pels sensors instal·lats en el prototip, fent ús de la informació proporcionada pel sistema de visió artificial i de les dades obtingudes pels dispositius de geolocalització, permetent també conèixer el rendiment de la producció a nivell intraparcelleri. El quadre de comandament va analitzar les dades i va generar diferents tipus de mapes georeferenciant l'informació de la fruita amb el seu punt de recol·lecció. A través d'estos mapes, *CitrusYield* va demostrar la seua capacitat per a reflectir l'heterogeneïtat de la producció dins de la parcel·la. Estes diferències de producció entre zones dins del cultiu també es van quantificar en les taules i gràfics generats per la eina. Els indicadors de qualitat, rendiment del sistema d'inspecció per visió artificial i la productivitat calculats per *CitrusYield* van revelar el grau d'efectivitat i eficiència del procés de recol·lecció amb l'assistència del prototip.

En l'àmbit de la detecció de plagues i malalties de cítrics, es va dur a terme la investigació del potencial de la imatge en color i de la imatge hiperespectral, per a la detecció automàtica de danys causats per la plaga *Tetranychus urticae* en fulls de cítrics. A més, es van discriminar en funció de l'antiguitat i d'altres problemes que pot tindre l'arbre causats per deficiències nutricionals o per altres plagues. En l'anàlisi per a identificar el dany causat per esta plaga, es va obtenir una taxa d'èxit del 92,5% en les imatges en color. No obstant això, no es va poder discriminar l'edat del dany amb este mètode. En les imatges hiperespectrals, l'èxit va ser del 100% en la detecció del dany i del 92% en la discriminació de l'edat. En quan a la discriminació de danys de *T. urticae* respecte a altres danys, en les imatges en color es va obtenir una taxa d'èxit del 100% en la discriminació de *Phyllocnistis citrella* en el revés dels fulls. Les deficiències de N no van poder discriminar-se correctament i les deficiències de Fe, Mn o Zn es van detectar

encertadament en el 50% dels casos. En les imatges hiperespectrals, els danys per pugué *P. citrella* es van discriminar amb èxit en el 100% dels casos, tant en el feix com en el revés dels fulls. Les deficiències per N es van discriminar correctament en més del 65% dels casos també en ambdós costats del full. No obstant això, les deficiències de Fe, Mn o Zn no van poder ser discriminades correctament, sent el percentatge de dany classificat encertadament inferior al 50%.

Les conclusions de esta Tesi Doctoral posen de manifest el gran potencial d'implementar estes tecnologies per a monitoritzar, optimitzar tasques i digitalitzar els processos en les labors dues a terme en els camps de cítrics, de manera que s'aconsegueix augmentar l'eficiència, productivitat i la competitivitat en el sector.

Les principals contribucions d'esta investigació realitzada sobre l'aplicació de noves solucions mecanitzades i automatitzades en la citricultura es reflectixen en la transferència tecnològica a través de la creació de la eina digital inscrita en el registre de propietat intel·lectual i en la publicació dels resultats en revistes científiques indexades en el JCR, en revistes tècniques i de divulgació, en congressos nacionals i internacionals i en capítols de llibres de caràcter internacional.



Prefacio

PREFACIO

1. Marco de la tesis

Esta Tesis Doctoral es el resultado del trabajo de investigación realizado por la autora durante el período 2017-2022, como miembro del Centro de Agroingeniería del Instituto Valenciano de Investigaciones Agrarias con una subvención para la formación de personal investigador en agroalimentación en los centros de investigación agraria y alimentaria INIA-CC.AA. (FPI-INIA CPD2016-0007, #42), otorgada por el Instituto Nacional de Investigaciones y Tecnología Agraria y Alimentaria, con el apoyo parcial de los Fondos FEDER 2014-2020. En concreto, se corresponde con la plaza número cuarenta y dos (42) denominada como “Reto 15: Desarrollo de nuevas tecnologías aplicables al sector agrario y forestal”.

En esta Tesis Doctoral se han realizado investigaciones en el marco de dos proyectos de investigación en los que he participado, uno financiado por el INIA con el apoyo de fondos FEDER y uno financiado por la GVA-IVIA. También se ha realizado parte de mi investigación en el marco de un proyecto de innovación de interés general por grupos operativos supraautonómico de la AEI-AGRI, en el marco del programa nacional de desarrollo rural 2014-2020 cofinanciado por fondos FEADER en un 80% y el Ministerio de Agricultura, Pesca y Alimentación en un 20%:

- **Aplicación de nuevas tecnologías para una estrategia integral de la recolección mecanizada de cítricos (CITRUSREC) (RTA2014-00025-C05-00).**
Proyecto coordinado de 5 subproyectos en el que he participado en dos de ellos:
 - o El **subproyecto 1** centrado en el **desarrollo y evaluación de una plataforma de asistencia a la recolección** (RTA2014-00025-C05-01) donde mi contribución ha estado presente en los tres objetivos definidos: (i) El diseño de una plataforma de asistencia a la recolección adaptada a plantaciones tradicionales cítricas, (ii) el desarrollo de sistemas de preclasificación automática de fruta en campo y (iii) la incorporación de un sistema de posicionamiento geográfico para la geolocalización individualizada de la fruta recolectada asociada a su calidad.
 - o El **subproyecto 5** sobre la **generación de herramientas de ayuda para la toma de decisiones** (RTA2014-00025-C05-05) donde mi participación se centró en el objetivo asociado con la creación de herramientas para visualizar mapas de producción y calidad de la fruta a partir de los datos generados por las diferentes tecnologías de recolección.
- **Desarrollos de ingeniería para el aseguramiento de una agricultura rentable, sostenible y competitiva del campo a la mesa (GVA-IVIA proyecto 51918).**
Dentro de este proyecto, mi investigación se ha enmarcado principalmente en el estudio de la detección de daños causados por la plaga *Tetranychus urticae* en hojas de cítricos mediante imagen en color e hiperespectral frente al actual método de detección basado en la inspección visual de las hojas.
- Grupo Operativo "**Avances tecnológicos para la modernización y la sostenibilidad en la producción de cítricos (GO CITRUSTECH)**".
En este proyecto he colaborado en la demostración y difusión de los resultados de investigación al sector agroalimentario de las nuevas tecnologías desarrolladas para la mecanización de la recolección de cítricos.

Las investigaciones realizadas en mi Tesis Doctoral dentro del marco de estos proyectos se han enfocado en generar conocimiento que permita desarrollar soluciones mecanizadas automatizadas mediante la aplicación de sensores y nuevas tecnologías para monitorizar y

aumentar la productividad de los campos de cítricos y, por ende, la competitividad del sector cítrico y en su difusión y transferencia.

2. Estructura de la memoria

Esta Tesis Doctoral se ha estructurado en los siguientes capítulos:

- El capítulo 1 se centra en el estado del arte de la investigación relacionada con los diferentes estudios realizados en el marco de esta Tesis Doctoral.
- El capítulo 2 expone los objetivos generales y específicos de esta Tesis Doctoral.
- El capítulo 3 versa sobre la implementación y evaluación de la funcionalidad de las mejoras estructurales y funcionales llevadas a cabo en un prototipo de plataforma autopropulsada de asistencia a la recolección de cítricos para consumo en fresco con el fin de garantizar la seguridad de los trabajadores y minimizar los riesgos laborales, asegurar la calidad de la fruta que transita por el prototipo y clasificarla adecuadamente en función de la calidad de la misma. También se trata en este capítulo la determinación del rendimiento de la operación de recolección asistida.
- El capítulo 4 trata acerca de la creación y evaluación de una herramienta digital a través de un cuadro de mando, denominada *CitrusYield*, para la generación de mapas accesibles al agricultor mostrando la información clave obtenida del cultivo mediante los sensores utilizados en el prototipo durante el proceso de recolección.
- El capítulo 5 describe el potencial de las imágenes en color e hiperespectrales, como un método rápido, automático y no destructivo para la detección de daños causados por la plaga *Tetranychus urticae* en hojas de cítricos, además de para discriminar el daño en función de su antigüedad y poder diferenciar estos daños de otros problemas que puede tener el árbol causados por deficiencias nutricionales o por otras plagas.
- El capítulo 6 recapitula las conclusiones más relevantes obtenidas en el trabajo presentado en esta Tesis Doctoral.
- El capítulo 7 contiene las consideraciones finales y recomendaciones para futuros trabajos de I+D.
- El capítulo 8 refleja las principales contribuciones científicas y tecnológicas aportadas por el trabajo desarrollado en esta Tesis Doctoral, así como su difusión y transferencia.
- El capítulo 9 recoge toda la bibliografía citada en este trabajo.
- El Anexo I donde se presentan los dos artículos científicos publicados en revistas recogidas en el JCR.



Capítulo I

Introducción

CAPÍTULO I - INTRODUCCIÓN

Según las proyecciones previstas por la FAO, el sector agroalimentario afrontará profundos cambios y desafíos a nivel global, pues se prevé que la población mundial supere los 9000 millones de habitantes para 2050 frente a los actuales casi 8000 millones (Statista, 2022). Este aumento de población provocará un incremento en la demanda de productos agroalimentarios (FAO, 2009), lo que ejercerá una presión creciente sobre los recursos agrícolas disponibles. La mayor parte del incremento de producción para abastecer esta demanda se estima que procederá del aumento del rendimiento y la intensificación de los cultivos y en menor medida de la expansión en superficie de tierras cultivables (FAO, 2011). La agricultura se enfrenta, por tanto, al reto de aumentar la eficiencia y sostenibilidad de los actuales métodos de producción mediante el desarrollo de nuevos enfoques y líneas estratégicas en un entorno ambientalmente desfavorable, enfocándose en la sostenibilidad de la agricultura, la seguridad alimentaria y la innovación para mejorar el sector agroalimentario, todo ello haciendo uso eficiente de los recursos naturales y adaptándose a la volatilidad del mercado al tiempo que se contribuye a la mitigación del cambio climático (FAO, 2018).

Para responder a estas demandas en condiciones de competitividad, calidad y seguridad alimentaria, las empresas y organizaciones, los agricultores y el entorno científico llevan a cabo las actuaciones necesarias que contribuyan a redibujar el papel de la agricultura en el futuro. De acuerdo con la FAO, estas actuaciones serán posibles mediante el desarrollo de nuevas tecnologías (herramientas biotecnológicas, TICs, etc.) y los avances científicos en la agroalimentación, junto con la inversión económica necesaria y la aplicación de políticas que favorezcan la producción agrícola. Además, la innovación en TICs junto con la formación de profesionales en la agricultura digital ayudará a combatir el escaso relevo generacional al que actualmente se enfrenta la agricultura, aprovechando con ello las habilidades tecnológicas de las nuevas generaciones.

1. Nuevas tecnologías en la agricultura de precisión

Desde 1994, diferentes autores hicieron referencia al concepto e interpretación del término agricultura de precisión (Pierce et al., 1994; Stafford, 1996; National Research Council, 1997; Whelan y McBratney, 2000; US Code, House of Representatives, 2002; Fountas et al., 2016). En la actualidad, la definición académica oficial, consensuada por la ISPA, define la AP como una estrategia de gestión que recoge, procesa y analiza datos temporales, espaciales e individuales y los combina con otras informaciones para respaldar las decisiones de manejo de acuerdo con la variabilidad estimada, y así mejorar la eficiencia en el uso de recursos, la productividad, la calidad, la rentabilidad y la sostenibilidad de la producción agrícola (ISPA, 2019). Esta estrategia, que aúna conocimiento y tecnología, permite disminuir la unidad de manejo a escalas más pequeñas, pasando de la gestión tradicional uniforme en toda parcela al manejo de áreas concretas dentro del campo teniendo en cuenta la variabilidad temporal y espacial y la heterogeneidad intraparcularia, esto es, la variación natural o las diversas necesidades existentes dentro de una parcela (González-González et al., 2020a), permitiendo así una gestión diferenciada por zonas mediante el manejo específico localizado.

Con el SSM se pueden tomar decisiones mejor fundamentadas a la hora de aplicar insumos o llevar a cabo trabajos agrícolas, reportando con ello un gran beneficio a los agricultores y productores pues reduce los costes, mejora la rentabilidad de las explotaciones, disminuye el tiempo de trabajo, mejora la calidad de las producciones, aumenta la productividad, mejora el rendimiento del cultivo, reduce los riesgos de las operaciones y permite realizar la trazabilidad de estas operaciones y de la producción. Todo ello, incrementa la sostenibilidad de la explotación a

la vez que se contribuye a reducir el impacto ambiental provocado por todas estas actividades agrarias (Pierce y Sadler, 1997; Lowenberg-DeBoer y Swinton, 1997; Robert, 2000; Plant, 2001).

El SSM es posible gracias a la aplicación de las tecnologías de la información y comunicación en el sector agrícola o agroTICs. Estas tecnologías permiten disponer de datos georreferenciados de las características del cultivo y de su medio (suelo, clima, fertilizante, riego, fitosanitarios, prácticas de cultivo, presencia de plagas y enfermedades, etc.). Estos datos se procesan extrayendo la información útil para ayudar a los técnicos en las actuaciones y operaciones necesarias en el lugar concreto y momento preciso de la manera adecuada con la cantidad justa (Figura 1). Con ello, el agricultor es capaz de cuantificar la variabilidad de su explotación, recogiendo toda la información útil y práctica para posteriormente realizar un manejo espacial georreferenciado de forma eficiente y, a la vez, sostenible (Arnó y Martínez-Casasnovas, 2018a).



Figura 1. Ciclo de las cuatro etapas de la Agricultura de Precisión (GRAP, 2020).

Entre las tecnologías en agricultura (AgTech) para la adquisición de datos destacan (i) el uso de sensores que permiten la medición de características importantes del cultivo y/o el entorno, como cámaras multiespectrales, hiperspectrales o térmicas, (ii) el uso de diversas plataformas que transportan los sensores en función de las diferentes necesidades como satélites, aeronaves tripuladas, UAV o drones, vehículos o robots agrícolas, entre otros y (iii) sistemas de navegación y geoposicionamiento que permiten asociar la información con el punto exacto donde se ha obtenido. Además, la geoestadística y los SIG permiten analizar y visualizar todos estos datos para extraer la información práctica y alcanzar así una alta eficiencia de la explotación. Entre las aplicaciones de las AgTech en el presente y el futuro resaltan (González-González et al., 2020a):

- Optimización del riego y la fertilización. La información relacionada con el vigor y estado del cultivo en las diferentes etapas de crecimiento extraída mediante sensores térmicos y espectrales se puede utilizar para planificar la aplicación de fertilizantes y distribución del riego, reduciendo con ello el consumo excesivo de insumos al mismo tiempo que se contribuye a mejorar la calidad y producción del cultivo.
- Planificación de la recolección. Mediante modelos de predicción de cosecha mejorados con la incorporación de datos obtenidos en etapas de crecimiento concretas se puede establecer un calendario de recolección en función de las estrategias de comercialización definidas. El uso de estos métodos junto a técnicas de inteligencia artificial permitirá predecir la información relacionada con la producción y la calidad del cultivo.

- Dinamización de los procesos de producción mediante sistemas de asistencia. El uso de sensores y maquinaria para asistir a los operarios permite mejorar sus condiciones laborales al mismo tiempo que reduce tiempos de trabajo y aumenta el rendimiento y la producción. A modo de ejemplo, la aplicación de estas tecnologías en el proceso de recolección en ciertos cultivos supondría un beneficio considerable pues se reduce el trabajo físico llevado a cabo por los operarios, se maximiza la eficiencia del proceso y se rentabilizan los costes asumidos por el agricultor.
- Creación de mapas digitales de información. Presentar en dispositivos móviles o tabletas en forma de mapas interactivos la información extraída por diferentes sensores relacionada con la presencia de plagas y/o enfermedades, estrés hídrico y/o necesidad de riego, fertilización y abono, entre otras características del cultivo y su entorno, permite al técnico agrícola obtener la información que más le interese según el período de la campaña. Además, en función de la configuración disponible, se podrá consultar la evolución del cultivo en función de series temporales y también a modo predictivo conocer el estado del cultivo para determinar la dosificación de tratamientos y/o adoptar estrategias de manejo.
- Inspección, vigilancia y protección de los cultivos. El uso de estas tecnologías proporciona una visión conjunta del crecimiento y el estado vegetativo del cultivo, lo que permite a los productores, por ejemplo, la detección rápida, temprana y geolocalizada de enfermedades o plagas. Además, gracias al almacenamiento y análisis de los datos obtenidos en varias campañas se podrá realizar una mejor planificación.

A pesar de los beneficios que pueden reportar, la implantación comercial de las AgTech en las explotaciones agrícolas tradicionales es desigual, siendo aún escasa en aquellos campos de tamaño medio y pequeño. Dependiendo del tipo de cultivo y su extensión, hay casos en los que a día de hoy únicamente se hace uso de maquinaria agrícola básica con bajo o nulo nivel de digitalización para el desempeño de las labores, lo que hace compleja la aplicación de la AP para la toma de decisiones sin una tecnificación previa. La AP suele asociarse con equipos costosos y de alta tecnología (García y Flego, 2008). No obstante, es posible implementar la AP con mucha de la tecnología ya existente y aplicada en otros sectores, incluso con sus versiones de bajo precio, con una inversión inicial relativamente baja. Un ejemplo de ello son los dispositivos vinculados a la ayuda al guiado con sistemas relativamente simples y asequibles (Wilson, 2000; Kise et al., 2005; Modesti y Mateus, 2008; Li et al., 2009; Rovira-Más, 2009; Mousazadeh, 2013; Shalal et al., 2013), cuya implantación fue de la mano con la generalización en el uso de estos elementos en los vehículos no agrícolas.

En España, la mayoría de aplicaciones AgTech se dan en cultivos extensivos y en grandes extensiones de viña (Zarco-Tejada et al., 2005; Montero et al., 2007; Arnó et al., 2009; Gil, 2009; Llorens et al., 2011; Blasco et al., 2014; Bonilla et al., 2015; Rovira-Más et al., 2015; Diago et al., 2016; Sanz et al., 2018; Roman et al., 2020; Gomes et al., 2021; Saiz-Rubio et al., 2021) y olivar (Alcalá y Álamo, 1998; López-Granados et al., 2004; Ramos et al., 2007; Torres et al., 2008; Pérez-Ruiz et al., 2011; Álamo et al., 2012; Fernández et al., 2016, 2020; Lima-Cueto et al., 2019), pero tienen poca penetración en los cultivos frutícolas. Ello se debe a que esta tecnificación agrícola se enfrenta a diversas barreras físicas, económicas y sociales, de manera que suele considerarse rentable únicamente si se hace a gran escala. Por ejemplo, el 49,7% de las explotaciones de la Comunidad Valenciana tiene una superficie inferior a 1 ha (Martin y Pérez, 2004), lo que implica un elevado grado de parcelación que dificulta la implantación de AgTech en nuestra agricultura. A diferencia de los cultivos extensivos, en frutales es complejo representar por ejemplo un mapa de rendimiento de la recolección, ya que al no pesarse la fruta árbol a árbol o por metro lineal, sino que se considera la producción en su conjunto, no se puede cuantificar ni representar la variabilidad espacial de los diversos pesos, maduraciones y calibres (Fruticultura, 2021).

2. AgTech aplicadas en cultivos cítricos

Los cítricos son uno de los cultivos más importantes del mundo. Según datos de la FAO, en 2017 había un total de 148 países productores de cítricos (FAO, 2017) y la producción mundial alcanzó casi 50 millones de toneladas de naranjas (Statista, 2017a) y casi 30 millones de mandarinas, clementinas y satsumas (Statista, 2017b). España se posiciona como el primer país productor cítrico de la Unión Europea y es el principal exportador mundial de estos frutos para el mercado en fresco, con un 25% de las exportaciones mundiales (MAPA, 2022a).

Por tanto, para alcanzar un nivel de producción competitivo, a la vez que se garantiza una gestión sostenible medioambientalmente, la citricultura española se enfrenta a nuevos desafíos que requieren la implementación de las tecnologías AgTech y de medidas para su consecución. Estas acciones además han de estar respaldadas de manera conjunta tanto por los productores como por las entidades comercializadoras y las administraciones públicas. En la actualidad, esta tecnificación de las operaciones supone un paso necesario no solo para incrementar la productividad sino también para aumentar la eficiencia, mejorar las condiciones de trabajo de los operarios, reducir costes de producción y minimizar el impacto ambiental. Pese a la importancia económica y social de la citricultura, el grado de tecnificación de las labores agrícolas comparado con otros cultivos, como los extensivos, es muy bajo y/o poco eficiente. En esta Tesis Doctoral, se ha avanzado en el desarrollo de tecnologías en tres áreas de aplicación relevantes en cítricos: la recolección mecanizada, la generación de mapas de rendimiento y la detección de plagas y enfermedades. A continuación, se presentan los antecedentes que existen a nivel global para cada una de las aplicaciones.

2.1. *Recolección mecanizada de cítricos*

Dentro del proceso de producción cítrica, la recolección tiene especial importancia económica debido a su elevado coste, llegando a suponer según la variedad y forma del cultivo mínimo un cuarto de los costes finales de la producción (Juste et al., 2000). A día de hoy, en los cítricos la recolección manual sigue siendo el método más utilizado, tanto para frutos con destino a fresco e industria, por lo que se requiere de una importante cantidad de mano de obra. La labor manual ejercida por estos operarios es dura y precaria, requiriendo de gran esfuerzo físico, por lo que la incorporación de equipos de asistencia en la recolección supone un paso hacia delante en la mejora de las condiciones de trabajo, mientras se aumenta con ello la eficiencia, la productividad y la competitividad frente a mercados exteriores y se abaratan los costes en el medio plazo (Ferreira et al., 2018). A la hora de seleccionar un método de asistencia para la recolección es fundamental tener en cuenta el uso que se vaya a dar a la fruta recolectada, pues la fruta destinada al consumo en fresco no debe presentar ningún tipo de daños mientras que la fruta destinada a industria admite la presencia de ciertos tipos de daños exteriores (Mateu et al., 2017). Actualmente, existen equipos que pueden facilitar y mejorar la operación de recolección, aunque su implantación es escasa.

Los equipos con menor nivel de mecanización son las carretillas motorizadas. Se desarrollaron en la década de los 80, con el fin de mecanizar la operación de transporte de cantidades importantes de fruta, del orden de 500 kg, desde el árbol hasta el camión por un solo operario (Gracia y Bernad, 1988). Con el mismo objetivo, en algunas plantaciones, se están usando carretillas estibadoras y los tractores provistos con horquillas estibadoras. Las carretillas motorizadas, al tener dimensiones reducidas y ser de pequeño tamaño, presentan la ventaja de poder utilizarse en cualquier tipo de explotación, mientras que los tractores con horquillas requieren de mayor amplitud de paso, pero también permiten mover cargas mayores a mayor velocidad (Chueca et al., 2019).

Con el fin de evitar el uso de las tradicionales escaleras de mano para árboles grandes y así facilitar a los operarios el alcance a las frutas superiores, a partir de los años 50, se empezaron a desarrollar las primeras máquinas de asistencia (Jutras y Coppock, 1958). Estas máquinas sin motor estaban compuestas de plataformas móviles donde se sitúan los operarios a diferentes niveles. La versión motorizada de estas plataformas ya se utiliza de manera habitual en otros cultivos frutales con destino a fresco con disposición en espaldera y/o con amplios marcos de plantación (Lu et al., 2016; Blok et al., 2016; Zhang et al., 2018). Según Zhang et al. (2017b) estas plataformas móviles de asistencia facilitan la recolección manual e incrementan la eficiencia en más de un 50%. En España, Gutiérrez et al. (2012) desarrollaron un primer prototipo de plataforma de asistencia para cítricos que permite a los operarios acceder a las partes más altas del árbol, recogiendo los frutos y depositándolos en cintas transportadoras instaladas en el prototipo que conducen la fruta hacia los contenedores. Una de las principales ventajas en el uso de estas plataformas es que permiten la incorporación de otras tecnologías AgTech para realizar simultáneamente tareas complementarias como la inspección y preclasificación en campo de los frutos en función de determinadas propiedades físicas como el tamaño, el color y/o la presencia de podredumbres, ofreciendo además la posibilidad de georreferenciar esta información relacionada con su calidad externa con el punto exacto de recolección mediante la instalación de un GNSS (Cubero et al., 2014). Para aumentar la eficiencia en la operación de recolección con estas plataformas de asistencia, se requieren unas condiciones concretas respecto al marco de plantación y la altura de los árboles, teniendo una separación mínima entre filas de 5m y una altura máxima por árbol de 4m. Además, las cabeceras han de ser espaciosas para permitir el giro de estas plataformas incluso cuando llevan remolques enganchados y el terreno debe estar nivelado o con pendientes poco pronunciadas.

Los sistemas vibratorios, de tronco o de ramas, son otros de los equipos mecanizados para asistencia en la recolección (Whitney y Wheaton, 1987; Whitney, 2003; Torregrosa et al., 2009; Ortiz et al., 2011; Moreno et al., 2015). Esta maquinaria se presenta como una opción rápida y automática para desprender los frutos del árbol, aumentando así la capacidad de trabajo durante la recolección. Estos vibradores llegan a derribar hasta un 80% de la fruta. Mientras que el vibrador de ramas es un equipo manual donde el operario carga con su peso, el vibrador de troncos es una máquina autopropulsada o directamente acoplada en el tractor, lo que beneficia la salud del operario al evitar que reciba en su cuerpo las vibraciones de manera directa. Según Ortiz et al. (2011), utilizando superficies como telas plásticas o lonas que recojan los cítricos antes de caer al suelo e inspeccionando la fruta en campo o posteriormente en almacén para cortar los pedúnculos y retirar los frutos dañados, los vibradores de tronco pueden utilizarse para frutas con destino a fresco. No obstante, para el uso de estas máquinas se requieren plantaciones adaptadas y que el tronco de los árboles tenga entre 60 y 80 cm de altura, quedando libre de ramas para facilitar el acceso y agarre de la máquina al tronco.

Para cítricos destinados exclusivamente a industria se han desarrollado los sacudidores de copa para seto ancho y los sacudidores cabalgantes para seto estrecho (Sumner, 1970; Ebel et al., 2010; Roka et al., 2014; Arenas-Arenas, 2018; Castro García et al., 2018; Aragón-Rodríguez, 2021). Son máquinas compuestas por un sistema de varas que mueven la copa del árbol produciendo un número bajo de impactos a los frutos y con una frecuencia inferior a 5Hz, lo que provoca finalmente el desprendimiento de los frutos sin romper las ramas. Al igual que los vibradores de tronco, estos sistemas pueden ser autopropulsados o remolcados por un tractor. Estos equipos, al igual que el resto de maquinaria, requiere de unas condiciones particulares para su uso en lo que a marco de plantación y altura de los árboles se refiere, existiendo requisitos particulares para cada tipo de seto. Como las plataformas, esta maquinaria tiene unas dimensiones considerables por lo que necesita cabeceras anchas para poder realizar los giros dentro de la explotación y un terreno que presente un desnivel mínimo.

Al igual que la maquinaria anterior, los robots para asistir en el proceso de recolección cuentan con un alto nivel de mecanización en la recolección de cítricos. En España, el primer robot se desarrolló en la década de los 80 en el marco de un proyecto hispano-francés y constaba de un brazo automático capaz de recolectar la fruta de manera similar a la recolección manual y descargarla en una tolva de forma autónoma (Juste y Sevilla, 1991). Desde entonces, la bibliografía muestra que se ha continuado con el desarrollo de sistemas robóticos (Recce et al., 1996; Muscato et al., 2005; Bulanon et al., 2009; Mehta y Burks, 2014; Qiang et al., 2014). A su vez, se ha avanzado en los estudios relacionados con los sistemas de visión y la inteligencia artificial para solucionar uno de los principales problemas que se dan en este tipo de sistemas robóticos y es la dificultad para detectar la fruta en el árbol, bien por la semejanza de color entre la misma fruta y las hojas o por la oclusión parcial o total de la fruta (Annamalai et al., 2004; Kurtulmus et al., 2011; Sengupta y Lee, 2014; Choi et al., 2015; Chen et al., 2017; Peng et al., 2018; Tao et al., 2018; Pérez-Ruiz et al., 2021).

2.2. *Confección de mapas digitales de rendimiento en cítricos*

Los mapas son una de las herramientas clave de la AP gracias a los cuales el agricultor visualiza la información agrícola de su explotación de una manera sencilla y visual. A partir de la disposición para uso civil de los GNSS por parte del Departamento de Defensa de Estados Unidos en la década de los 90, se comenzaron a utilizar estos sistemas en vehículos particulares y en máquinas agrícolas (Bornschlegel, 2009). La disponibilidad en nuestros días de tecnología GNSS relativamente económica combinada con diversos sensores que extraen información sobre el estado vegetativo del cultivo, las necesidades de agua, las características del suelo, abono, fertilización, siembra, recolección, presencia de malezas y/o de plagas y enfermedades, etc., ofrecen la oportunidad de registrar la información según su posicionamiento georreferenciado. Con ayuda de los SIG, esta información se representa espacialmente en forma de mapas digitales registrando los rendimientos de la cosecha georreferenciados en función de los diversos condicionantes que afectan a la producción, aplicando la interpolación geoestadística según el caso (Arnó y Casasnovas, 2018b). Con estos mapas de rendimiento se obtiene información clave de todo el ciclo de producción de un cultivo, permitiendo reconocer áreas dentro del cultivo con diferente producción, de manera que se puedan diagnosticar y corregir in situ las causas del bajo rendimiento en estas zonas afectadas (González-González et al., 2020b). Estos mapas de rendimiento pueden combinar información de diferentes factores que influyen en la cosecha, como registro del terreno, variedades de cultivos y suelos, climatología, afección de plagas, entre otros, conteniendo así todos los datos relativos a la explotación y su rendimiento, ya sea con todos estos datos en un mismo mapa o en un conjunto de mapas interconectados. Combinar además mapas con información de campañas anteriores permite estudiar la variabilidad espacio-temporal para optimizar aún más el manejo de la parcela, pues permiten identificar patrones de rendimiento (Kleinjan et al., 2007).

La información contenida en estos mapas de rendimiento es útil, entre otras cosas, para optimizar procesos en las diversas fases de la producción, reducir el tiempo de trabajo, mejorar el desempeño y la dosificación de los insumos y reducir el uso de los fertilizantes y productos químicos, disminuyendo con ello el impacto ambiental. Por ello, del análisis de estos mapas se pueden inferir estrategias de actuación a aplicar en el manejo del cultivo, como puede ser la definición de patrones óptimos de fertilización e irrigación, la planificación del control de la flora espontánea a partir de los mapas de vegetación y la detección de árboles estresados en función del mapa de estrés hídrico o árboles que puedan estar afectados por alguna plaga gracias al mapa de control de plagas y enfermedades (González-González et al., 2020a). Este conjunto de actuaciones se define en un nuevo mapa, denominado mapa de actuación, que refleja las acciones

a acometer en cada zona de la parcela. Estas acciones se pueden llevar a cabo mediante tecnología VRT conectada a vehículos con GNSS incorporado para facilitar la obtención de información durante la aplicación de las soluciones reflejadas en el mapa de actuación. Un ejemplo sería la aplicación mediante un equipo de pulverización dotado de un sistema GNSS de productos fitosanitarios a partir de un mapa de actuación que muestra las zonas donde se ha de aplicar la dosis y la cantidad precisa de ésta en función de la presencia de una determinada plaga para realizar una gestión eficiente y obtener también la trazabilidad de las operaciones.

Sin embargo, a pesar de su enorme utilidad, las herramientas para la generación de mapas de rendimiento en cítricos están poco desarrolladas (Schueller et al., 1999; Molin et al., 2007; Qiao et al., 2005; Kohno et al., 2011; Ampatzidis et al., 2016) debido a que la recolección se realiza de manera manual y, por tanto, los productores obtienen el rendimiento mediante la producción por hectárea. Con este dato se carece de información acerca de la variabilidad intraparcularia. La información precisa de rendimiento en función de la zona de la parcela se puede obtener en tiempo real mediante la utilización de dispositivos acoplados en las máquinas de asistencia a la recolección descritas en el apartado anterior. Entre estos dispositivos, la tecnología GNSS ofrece la información sobre posicionamiento, mientras que los sensores ópticos facilitan el conteo de la fruta. De esta manera, se podría mostrar al agricultor en mapas digitales la producción árbol a árbol, o incluso por zonas dentro de los árboles. Estos mapas del rendimiento de recolección proporcionarían información para adoptar estrategias de manejo con la finalidad de conseguir uniformizar lo máximo posible la producción en la plantación (Fruticultura, 2021). Además, si se cuenta con sensores de inspección para extraer información de la calidad de la fruta a la vez que se recolecta, permitiría la creación de mapas asociados tanto al rendimiento como a la calidad y estado del cultivo, de manera que se podría percibir con ello la presencia de problemas como estrés hídrico, estado vegetativo y plagas y enfermedades en el cultivo. Por tanto, la obtención del rendimiento y la calidad mediante la inspección de la fruta asociado con su punto exacto de recolección aporta un valor añadido a estos mapas (Cubero et al., 2014).

Esta tecnología de inspección instalada en la maquinaria de recolección se puede combinar con otros sensores para la confección de mapas en tiempo real relacionados con la calidad del suelo, la predicción del cultivo, la presencia de malezas, etc.

2.3. Sistemas avanzados para detección temprana de plagas y enfermedades en cítricos

Una de las posibles aplicaciones que permiten los mapas confeccionados con datos agrícolas es el control de la presencia de plagas y enfermedades. Se estima que cada año a nivel mundial se pierde entre 20-40% del rendimiento de los cultivos a causa de los daños por plagas y enfermedades (FAO, 2019). Con la detección temprana en hojas o frutos mediante las tecnologías AgTech se pueden gestionar las actuaciones a llevar a cabo para evitar la propagación, e incluso erradicar a tiempo la plaga y/o enfermedad, evitando que llegue a provocar daños en los frutos.

Una herramienta gratuita y accesible que puede llegar a ser útil para detectar zonas afectadas son las imágenes de satélite, como las obtenidas a través del satélite Sentinel 2, que proporcionan información a resoluciones espaciales y espectrales relativamente bajas. El inconveniente es que en esa escala de medida las zonas visibles afectadas por daños suelen estar en niveles avanzados de gravedad (González-González et al., 2020a). En cítricos, Li et al. (2015) utilizaron imágenes multispectrales de satélite con una resolución espacial de 2m con la finalidad de investigar la viabilidad de esta tecnología para detectar campos infectados con HLB, enfermedad sumamente destructiva que afecta sobremanera a estos cultivos. Esta técnica mostró ser factible para detectar la afección de esta enfermedad en zonas de gran extensión.

Las imágenes adquiridas desde aviones tripulados, drones y UAV se presentan como una alternativa frente a las imágenes de satélite, pues permiten obtener información con una resolución óptima espacial y espectral a gran escala pudiendo llegar incluso a nivel de árbol. La detección de estrés vegetativo a nivel de zona y/o cultivo ya figura entre sus aplicaciones. Moriya et al. (2019) descubrieron a partir de imágenes de alta resolución que la presencia de enfermedades como el HLB en cítricos se pueden detectar a través de algunas estimaciones de estrés fisiológico. Por su parte, García-Ruiz et al. (2013) mostraron tras realizar una comparativa entre imágenes adquiridas desde una avioneta tripulada y desde un UAV que con las primeras se obtenía menor precisión en la detección, con tasas más altas de falsos negativos a causa de la resolución espacial.

Para acceder a información a nivel de árbol e incluso de hoja una buena opción es el uso de sensores instalados en vehículos o robots agrícolas capaces de recopilar información espectral con alta resolución espacio-temporal llegando a resoluciones cercanas al centímetro (Rey et al., 2019). Una limitación a considerar es que para conocer el estado de las áreas próximas se ha de extrapolar la información obtenida con estos sensores ya que los datos adquiridos son puntuales y localizados. Algunos de estos sensores utilizados en campo ofrecen además de la posibilidad de la adquisición de datos, la toma de decisiones en tiempo real y la realización de acciones in situ mientras el vehículo se va desplazando por la parcela, siempre y cuando se cuente con el equipo VRT instalado. A diferencia de los mapas de actuación, en este caso la gestión y las estrategias de acción se toman en tiempo real basándose en los datos adquiridos por los sensores (GRAP, 2020). De esta forma, se podría por ejemplo realizar la aplicación de fitosanitarios y herbicidas en áreas concretas, proceder a una recolección selectiva o eliminar malas hierbas. Pourreza et al. (2015) crearon un sistema portátil de detección de HLB con capacidad para distinguir los daños causados por esta infección de los ocasionados por deficiencia de zinc, cuyos síntomas son similares.

Aunque la mayoría de las investigaciones recientes se han centrado en la detección de HLB por su carácter profundamente dañino, las tecnologías AgTech también se han estudiado para la detección de otras enfermedades como, por ejemplo, la cancrrosis. Abdulridha et al. (2019) utilizaron imágenes hiperespectrales adquiridas desde un UAV para la detección de árboles infectados con *Xantomonas* patógenas, obteniendo más de un 95% de acierto en la detección de cancrrosis.

Además, la detección de plagas a través de métodos basados en las imágenes en color permite al agricultor el uso de herramientas del día a día como son los dispositivos móviles. Berger et al. (2019) desarrollaron las primeras herramientas capaces de analizar fotografías de hojas de cítricos almacenadas en un servidor, determinando mediante el uso de algoritmos de inteligencia artificial la afección por HLB en las hojas.

En general, los resultados obtenidos hasta el momento con la aplicación de las AgTech en cultivos cítricos son prometedores, siendo necesario continuar investigando con la finalidad de buscar métodos robustos que puedan ser aplicables a diversas variedades y estructuras de árbol y puedan utilizarse en condiciones ambientales desfavorables.

Esta tesis doctoral avanza en la generación de nuevo conocimiento científico basado en el desarrollo de soluciones mecanizadas y automatizadas para incrementar la productividad y la competitividad en los cultivos de cítricos y se enmarca en los trabajos realizados en el Centro de Agroingeniería del IVIA, para desarrollar nuevos sistemas de mecanización, automatización, electrónica, robótica e informática en los procesos de producción y comercialización de los frutos.



Capítulo II

Objetivos

CAPÍTULO II - OBJETIVOS

1. Objetivo General

El objetivo principal de esta Tesis Doctoral es la generación de conocimiento que permita desarrollar soluciones mecanizadas y automatizadas mediante la aplicación de sensores y nuevas tecnologías para monitorizar, optimizar tareas y aumentar la productividad de los campos de cítricos y, por ende, la competitividad del sector cítrico.

2. Objetivos específicos

Los objetivos específicos de esta Tesis Doctoral son:

1. Análisis e identificación de las necesidades en un prototipo de plataforma autopropulsada de asistencia, con el fin de facilitar y optimizar el proceso de recolección de cítricos para consumo en fresco minimizando los riesgos laborales, implementación de mejoras en el prototipo y evaluación de la funcionalidad tras la realización de estas mejoras mediante ensayos de recolección e inspección en una parcela comercial de cítricos (Capítulo III).

- Identificación de los riesgos laborales para los operarios e implementación de medidas correctivas de seguridad y prevención en el prototipo.
- Identificación de áreas de mejora susceptibles de producir daños a los frutos a su paso por el prototipo e implementación de mejoras estructurales y funcionales.
- Avances en el sistema de inspección y en el control y automatización de las funciones del prototipo.
- Evaluación del funcionamiento del prototipo de plataforma de asistencia a la recolección en condiciones reales de campo y determinación de los rendimientos de la operación.

2. Creación de una herramienta digital a modo de cuadro de mando para la generación automática de mapas accesibles al agricultor mostrando la información clave obtenida del cultivo mediante los sensores instalados en el prototipo de plataforma (Capítulo IV).

- Creación de un cuadro de mando para visualizar mapas de producción y calidad de la fruta a partir de los datos obtenidos por los diferentes sensores instalados en la plataforma móvil durante el proceso de recolección.
- Evaluación del funcionamiento de la herramienta digital con los datos obtenidos en un ensayo de recolección realizado en una parcela experimental.

3. Investigación del potencial de la imagen en color y la imagen hiperespectral para la detección automática de daños causados por la plaga *Tetranychus urticae* en hojas de cítricos (Capítulo V).

- Evaluación de la capacidad de ambas técnicas de visión artificial, color e imagen hiperespectral, en condiciones de laboratorio, para detectar el daño causado por esta plaga como una alternativa rápida, automática y no destructiva frente al actual método de detección basado en la inspección visual de las hojas.
- Evaluación de la facultad de ambas técnicas para detectar la antigüedad del daño por *T. urticae* con la finalidad de conocer si se trata de un daño causado en la hoja recientemente o no.
- Estudio y comparación de las posibilidades de un sistema de visión tradicional y un sistema hiperespectral más avanzado para discriminar esta plaga de otras, como *Phyllocnistis citrella*, así como de otros problemas foliares como los provocados por deficiencias nutricionales.



Capítulo III

Desarrollo e implementación de avances en el prototipo de plataforma de asistencia a la recolección

CAPÍTULO III – PROTOTIPO DE PLATAFORMA DE ASISTENCIA A LA RECOLECCIÓN. IMPLEMENTACIÓN DE MEJORAS Y AVANCES. RENDIMIENTOS DEL PROCESO DE RECOLECCIÓN ASISTIDA

Resumen

La recolección de cítricos para consumo en fresco se realiza de manera manual y es la operación que supone un mayor coste representando más de un 25% de los costes totales de producción. Con el objetivo de aumentar la eficiencia del proceso y facilitar la recolección a los operarios, en el IVIA se desarrolló un prototipo de plataforma de asistencia a la recolección de cítricos para consumo en fresco. Este prototipo permite también realizar una clasificación previa de la producción en campo en función del tamaño y/o color, de modo que los productores pueden gestionar en el propio campo las frutas clasificadas de manera independiente decidiendo sobre su destino, industria o almacén hortofrutícola, y en este último sobre el almacenamiento y envasado poscosecha, logrando así un mayor ahorro de costes.

En este trabajo se presentan los avances y mejoras realizadas en el prototipo, las implementaciones estructurales de seguridad y prevención, las medidas incorporadas para garantizar la calidad de la fruta que transita por el prototipo y las implementaciones funcionales llevadas a cabo para garantizar el funcionamiento, la operatividad y la capacidad de trabajo.

Tras estas mejoras, se evaluó el funcionamiento del prototipo en un ensayo de recolección en condiciones reales de campo y se determinó el rendimiento del proceso de recolección asistida.

1. Introducción

Actualmente, España se posiciona como el primer exportador mundial de cítricos para consumo en fresco (Statista, 2020a), siendo esta fruta un producto clave para la economía agraria española cuya producción se concentra principalmente en la Comunidad Valenciana, la Región de Murcia y Andalucía (MAPA, 2022a). En los cultivos cítricos con producción para consumo en fresco, la recolección se sigue realizando como hace más de 50 años, esto es, cortando la fruta a mano con alicates o tijeras para evitar separar el pedúnculo del fruto y transportándola en cestas o capazos desde el árbol hasta el contenedor (Chueca et al., 2019). El nivel de mecanización en España para asistir estas labores sigue siendo muy bajo. La incorporación de tecnologías y procesos mecanizados en la recolección para facilitar el trabajo de los operarios permite aumentar la eficiencia, reducir costes e incrementar la productividad, mejorando asimismo la competitividad y las condiciones de trabajo de los operarios durante la recolección (Ferreira et al., 2018).

El uso de máquinas para asistir en la recolección se inició en la década de 1950 en Estados Unidos (Whitney et al., 2012). Entre las tecnologías para la asistencia en la recogida de cítricos para consumo en fresco figuran máquinas que incorporan plataformas móviles a diferentes niveles, sobre las que se colocan los recolectores, para reemplazar las tradicionales escaleras utilizadas para recoger los frutos más altos (Jutras y Coppock, 1958; Seamount y Opitz, 1973; Davey y Lahiff, 1978), carretillas motorizadas que permiten transportar cantidades ingentes de fruta de forma cómoda y con un solo operario para su manejo (Gracia y Bernad, 1988) y tractores con horquillas estibadoras para mover las pilas de cajas o los contenedores por el interior de las calles (Mateu et al., 2017).

Un paso más allá en estas tecnologías son las plataformas de asistencia a la recolección que permiten realizar tareas complementarias. Kohno et al., (2011) desarrollaron una plataforma

móvil de pequeño tamaño propulsada manualmente que integraba sistemas de visión capaces de inspeccionar la fruta en campo de manera individual. No obstante, carecía de sistema de clasificación por lo que su utilidad era limitada. Una mejora considerable fue propulsar estas máquinas con motor e incorporar tarimas para transportar recolectores, facilitándoles el acceso a las zonas altas de los árboles de manera segura sin necesidad de escaleras y depositando los frutos en cintas transportadoras para llenar automáticamente los contenedores (Zhang et al., 2017a, 2018). Su aplicación ya se da en cultivos con disposición en espaldera y/o con marcos de plantación amplios, por ejemplo, en manzanas (Lu et al., 2016, 2017). Estas plataformas permiten la realización combinada de labores como la clasificación previa en campo en función del tamaño, color y/o calidad de los frutos, aportando además un valor añadido con la generación de información georreferenciada de la producción (Cubero et al., 2014), disminuyendo un 15% el tiempo de recolección (Zhang, 2015) y aumentando la eficiencia de los trabajos hasta en un 60% (Zhang et al., 2017b).

El Centro de Agroingeniería del IVIA desarrolló un prototipo de plataforma móvil autónoma para asistir en la recolección de cítricos para consumo en fresco, combinando funciones de asistencia a los operarios y tareas de inspección y clasificación individualizada de la fruta en campo. Uno de los puntos clave en este tipo de maquinaria es que su diseño garantice unos requisitos mínimos de eficacia agronómica y de seguridad y ergonomía en el trabajo para los operarios (MAPA, 2022b). A su vez, también es importante garantizar el manejo cuidadoso de la fruta para evitar dañarla durante el transporte en la plataforma entre el punto de recolección, el de inspección y el depósito en los contenedores ya que, al estar destinada a consumo en fresco, debe alcanzar los estándares de calidad establecidos (Hernández, 2000). Para cumplir adecuadamente con tales funciones, así como para recopilar datos de producción, la versión disponible del prototipo presentaba una serie de carencias por lo que requería una actualización.

2. Objetivos

Los objetivos principales de este trabajo fueron el análisis e identificación de las necesidades en el prototipo de plataforma para una recolección más eficaz, segura y que garantice un adecuado manejo e inspección de la fruta para consumo en fresco, la introducción de las mejoras en la plataforma y la evaluación de la funcionalidad tras la implementación de estas mejoras mediante ensayos de recolección e inspección en una parcela comercial de cítricos. Para ello, se fijaron los siguientes objetivos específicos:

1. Identificación de los riesgos laborales para los operarios e implementación de medidas correctivas de seguridad y prevención en el prototipo.
2. Identificación de áreas de mejora susceptibles de producir daños a los frutos a su paso por el prototipo e implementación de mejoras estructurales y funcionales.
3. Avances en el sistema de inspección y en el control y automatización de las funciones del prototipo.
4. Evaluación del funcionamiento del prototipo en condiciones de campo durante el proceso de recolección. Determinación del rendimiento de la operación de recolección asistida.

3. Prototipo de plataforma móvil de asistencia a la recolección de cítricos

3.1. Descripción del prototipo

El Centro de Agroingeniería del IVIA desarrolló un prototipo de plataforma móvil autónoma para asistir en la recolección de cítricos, que puede inspeccionar y clasificar la fruta en campo (Figura 1). Durante el proceso de recolección, el prototipo circula entre las calles del cultivo a muy baja velocidad con un motor de combustión diésel y dirigido por control remoto. En la versión actual (Figura 1b), en la parte delantera de la máquina hay una tolva donde los recolectores depositan la fruta desde sus bolsas o capazos a nivel de suelo. Además, el prototipo cuenta con cuatro tarimas, dos por lado, a diferentes alturas (1,25 m y 1,90 m) que permiten el posicionamiento sobre ellas de los trabajadores para recolectar los frutos ubicados en las partes más altas de los árboles. Estas tarimas se extienden lateralmente mediante un sistema hidráulico para aproximarse al árbol y así facilitar el trabajo de los recolectores. Este prototipo está ideado para que trabajen de cuatro a seis operarios a nivel de suelo y de cuatro a ocho operarios situados sobre las tarimas. Las frutas recogidas por los trabajadores ubicados en las tarimas se depositan en unos volcadores metálicos que colocan la fruta, por efecto de la fuerza de gravedad gracias a su inclinación respecto al suelo, en las cintas transportadoras diseñadas con material plástico para su uso en condiciones exteriores. Las cintas de las tarimas superiores cuentan con bandas longitudinales, mientras que las inferiores tienen dedos de goma termosellados con una longitud de 30 mm y con una separación entre filas de dedos de 100 mm. Las cintas de las tarimas inferiores dirigen toda esta fruta a la tolva delantera del prototipo.

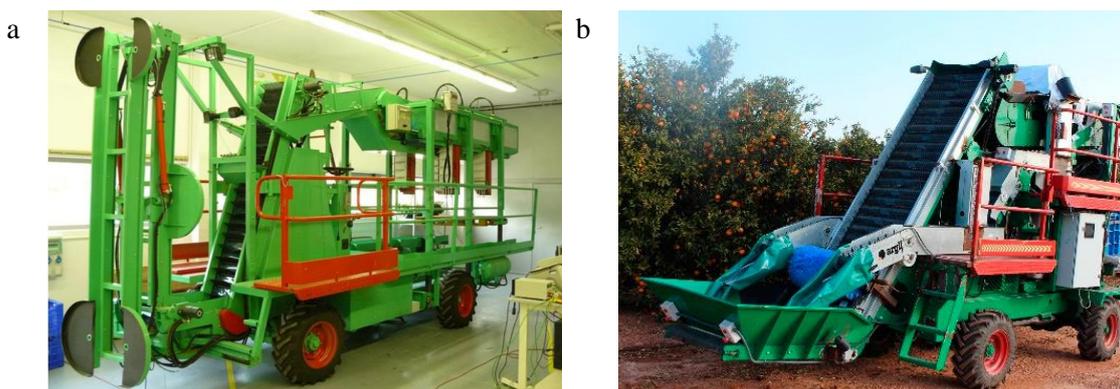


Figura 1. a) Primer prototipo. **b)** Prototipo actual de plataforma móvil de asistencia a la recolección de cítricos.

Una vez la fruta llega a la tolva, bien sea desde las tarimas o por parte de los operarios a nivel de suelo, se deposita sobre una cinta transportadora que presenta bandas transversales al avance para llevar a la fruta hasta otra cinta transportadora de elevación con dedos de goma termosellados de 80 mm de longitud y cuya separación entre filas de dedos es de 100 mm. Esta cinta elevadora transporta la fruta hasta el sistema de clasificación ubicado en la parte superior y fue diseñada para extender los frutos por todo el ancho de la misma, con la intención de que la fruta llegara distribuida a los individualizadores situados en la cabecera del área de clasificación. Estos individualizadores posicionan la fruta en cuatro carriles de transporte compuestos por rodillos giratorios bicónicos con palancas expulsoras integradas (Figura 2). Estos rodillos mueven la fruta a gran velocidad a través del campo de visión de dos cámaras de visión artificial, que se detallan más adelante, cada una de las cuales cubre dos carriles. Los rodillos permiten que la fruta gire mientras la cámara adquiere las imágenes, de modo que se pueda inspeccionar la mayor parte de la superficie de la fruta. Cada carril tiene 60 rodillos y todos ellos funcionan de manera síncrona. Además, se cuenta con un codificador para identificar y rastrear la posición exacta de cada fruta individualmente. Una vez inspeccionada, la fruta se puede separar en dos categorías diferentes.

Esta clasificación se basa en unos parámetros o umbrales que pueden ser seleccionados por el usuario a través del ordenador central del prototipo.

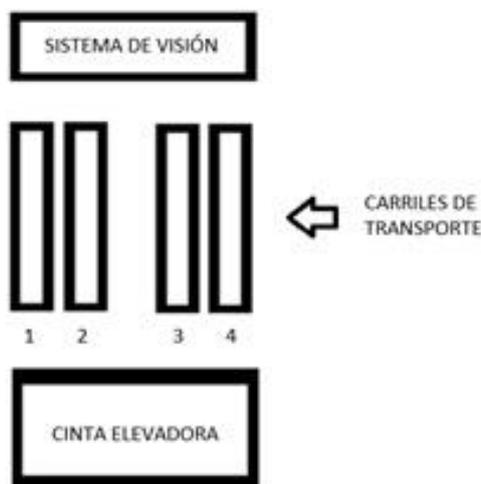


Figura 2. Esquema simplificado de la parte superior del prototipo antes del sistema de visión.

En función de la clasificación de la fruta, y mediante el accionamiento de las palancas expulsoras situadas entre los rodillos, la fruta se deposita en uno de los dos contenedores. Los contenedores están fabricados con material plástico HDPE de 1200 x 1000 mm de dimensiones y con una altura de 750 mm. Uno de los contenedores se encuentra ubicado en la zona posterior del prototipo (contenedor 1), y el otro está ubicado en la zona central del prototipo (contenedor 2). Para dirigir la fruta al contenedor 1, el prototipo cuenta con una cinta transportadora vertical de material plástico con dedos de goma de configuración cóncava para sostener la fruta, con una separación entre filas de dedos de 150 mm, y depositarla suavemente sobre un dispositivo giratorio o corona hecha de acero cuya misión es decelerar el fruto, suavizando el impacto en la base del contenedor. Esta corona, cuyo movimiento es continuo, tiene un diámetro de 900 mm y cuenta con una tela plástica blanda para amortiguar la caída de frutos en el contenedor. Está seccionada en 8 cuadrantes, cada uno de los cuales tiene una estera blanda de 1 mm de grosor con forma de gota, de modo que cuando está girando las naranjas caen sobre estos trozos de tela deslizándose hasta colocarse uniformemente en el contenedor. Además, el contenedor al inicio de llenado se mantiene en una posición elevada y a medida que se llena se va bajando para evitar el amontonamiento y los golpes bruscos entre frutos (Figura 3).

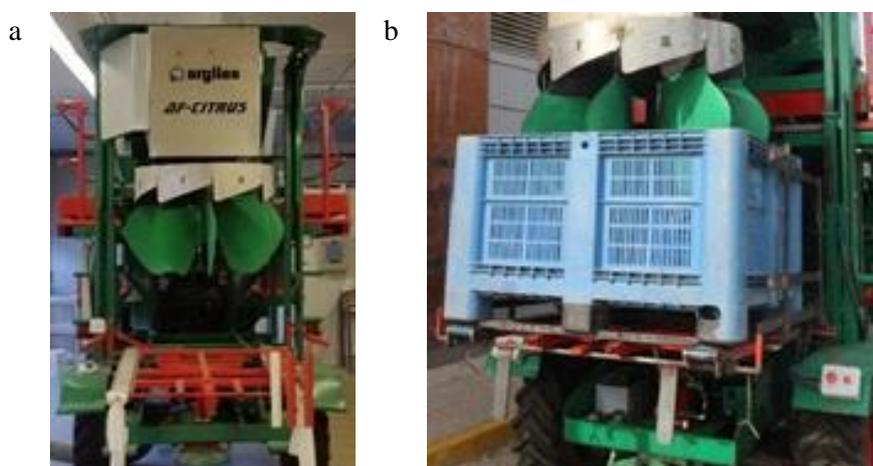


Figura 3. Área de llenado del contenedor situado en la parte posterior del prototipo.
a) Sin el contenedor. b) Con el contenedor dispuesto a media altura.

El prototipo dispone de un remolque auxiliar enganchado en la parte posterior de la máquina (Figura 4) cuya función es, por un lado, transportar contenedores vacíos para su posterior inserción en el prototipo cuando sea necesario y, por otro lado, asistir en la descarga a suelo de los contenedores llenos de fruta. Cuando un contenedor del prototipo está lleno, las guías inferiores del remolque facilitan que éste sea depositado en el suelo y una vez queda libre el área donde se ubica dicho contenedor, con las guías superiores del remolque se inserta un nuevo contenedor vacío. Estas acciones se ejecutan hidráulicamente puesto que el remolque está conectado al circuito hidráulico del prototipo y se accionan mediante un mando a distancia individual.



Figura 4. Prototipo de plataforma móvil con remolque auxiliar.

3.2. Funcionalidades del prototipo en campo

El sistema de clasificación por visión artificial permite separar la fruta en dos categorías. Actualmente, dicha clasificación puede realizarse bien por tamaño en función del diámetro ecuatorial del fruto o bien por color en función del ICC, explicado en detalle en el apartado siguiente. Al inicio de la temporada de recolección, puede ser de gran interés la clasificación por color con la finalidad de aplicarle en poscosecha diferentes tratamientos de desverdización (o ningún tratamiento), dependiendo del ICC en la recolección. Conforme avanza la temporada, puede ser de mayor utilidad la separación en campo de los frutos que no alcanzan el calibre o la calidad mínima requerida para el mercado de fruta en fresco, depositando esta fruta no comercial en el contenedor interno (contenedor 2), mientras que la fruta de mayor calidad se almacena en el contenedor exterior (contenedor 1). Estos frutos de menor calibre, se pueden enviar a destrío o a la industria de procesamiento de alimentos directamente desde el campo con el consiguiente ahorro económico que ello supone (Blasco et al., 2019).

3.3. Sistema de inspección automática de la fruta recolectada

El prototipo consta de un sistema de inspección automática de visión por computador ubicado en el parte superior y totalmente cubierto para evitar la influencia de las variaciones de las condiciones lumínicas, ambientales y meteorológicas durante la adquisición de imágenes. Este sistema de visión consta de dos cámaras industriales de color (Manta G-125C, Allied Vision Technologies GmbH, Alemania), una para cada dos líneas de rodillos de transporte de fruta, y un

sistema de iluminación basado en tiras de LED. Las imágenes se adquieren con una resolución de 1292 x 964 píxeles y se procesan en un ordenador industrial (NUVO 5006E-POE, Neousys Technology Inc., Taiwán) que ejecuta los algoritmos de análisis de imagen y transfiere el resultado para su clasificación.

Para iluminar la escena, el prototipo incluye un sistema de iluminación de bajo consumo compuesto por un total de cuatro tiras de leds de 500 mm por carril, dos arriba y dos laterales. Cada una de las tiras contiene 50 diodos leds con una potencia de 0,3 W cada uno y una temperatura de color de 6000 °K. Debido a la energía limitada del prototipo, los LED se alimentan en modo estroboscópico sincronizado con la adquisición de la imagen, lo que permite un ahorro de alrededor del 93% de la energía consumida por los LED (Blasco et al., 2019). El encendido del sistema de iluminación se sincroniza con el avance de los rodillos y con el sistema de evacuación de la fruta. Se utilizan filtros polarizadores en la lente de la cámara y en las lámparas para lograr la polarización cruzada y evitar la aparición de brillos que pudieran ocultar defectos o alterar el color natural de la fruta.

Durante el proceso de inspección, cada cámara captura una escena compuesta por ocho frutas (cuatro en cada carril). Las imágenes se capturan cada vez que una fruta avanza la distancia equivalente entre dos rodillos, por lo tanto, siempre se conoce la posición exacta de la fruta, puesto que dicha distancia es fija. Para lograr esto, el disparador de las cámaras se sincroniza con la iluminación y con el avance de los rodillos de transporte mediante un codificador (Figura 5). La primera escena capturada por las cámaras presenta la fruta 1 en la posición que se ve en la imagen. En la siguiente escena capturada, las frutas habrán avanzado una posición por lo que la fruta 1 ahora está ubicada en la posición 2 mostrando otra parte de la superficie gracias al giro llevado a cabo por el rodillo al desplazarla. Y así sucesivamente hasta que la fruta salga del marco de la imagen. A medida que las frutas giran mientras avanzan, las cámaras capturan cuatro imágenes con la finalidad de mostrar diferentes superficies de la fruta. Aunque el movimiento de rotación está controlado, no se puede garantizar que se pueda observar el 100% de la superficie de la fruta pues la rotación está influenciada por los movimientos del prototipo durante el transporte por los rodillos y por el propio tamaño/forma de la fruta. No obstante, la superficie capturada es lo suficientemente amplia para lograr los objetivos de una clasificación previa en campo (Blasco et al., 2019).

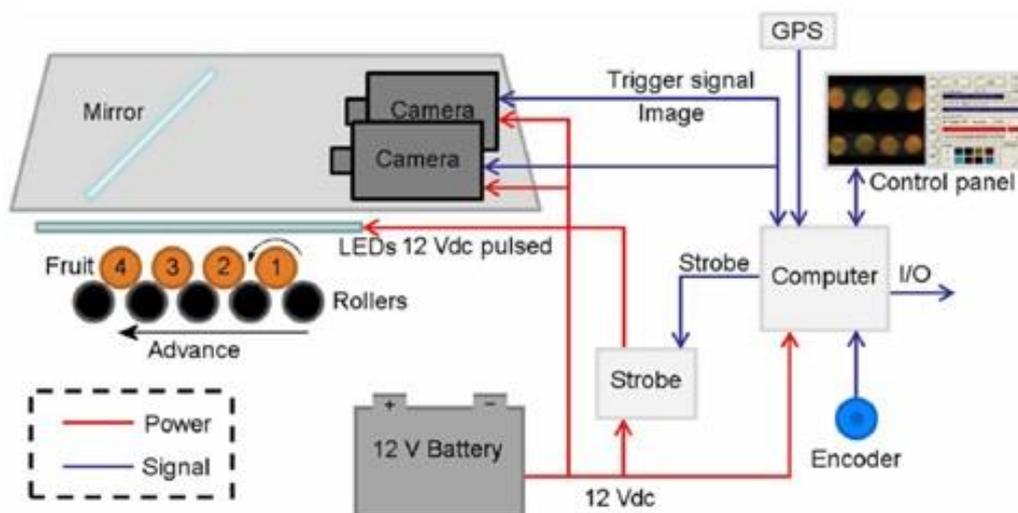


Figura 5. Esquema del equipo que compone el sistema de visión artificial. Los números dentro de las frutas representan las cuatro posiciones en las que el sistema adquiere las imágenes de cada una (Cubero et al, 2012).

En las imágenes, la escena se divide en una sección para cada fruta presente en la imagen por lo que se tiene un total de ocho secciones. La segmentación de la imagen se basa en una técnica supervisada que necesita un entrenamiento previo utilizando imágenes de prueba. Este entrenamiento se realizó de forma manual, seleccionando las regiones de interés y asociando el color de los píxeles de su interior a las diferentes clases en las que se dividió la imagen y que fueron: el fondo, piel naranja (clara y oscura) y piel verde (claro y oscuro). Para separar en las imágenes la fruta del fondo, se utilizó una relación de bandas verde y azul, basada en el valor RGB de cada píxel. Solo aquellos píxeles con un valor mayor que el umbral se consideraron pertenecientes a la fruta. Esta proporción se eligió debido a los valores relativamente bajos de azul y verde de la fruta en todas las etapas de madurez.

A partir de la selección y asignación manual de las clases, se realiza un análisis discriminante lineal bayesiano para obtener funciones que permitan clasificar cualquier color posible dentro de una de las clases predefinidas (Blasco et al., 2009b). Una vez completado este paso, se clasifican todos los posibles valores de color de la imagen y esta clasificación se almacena en una tabla. Durante la inspección en línea de la fruta recolectada, el algoritmo de segmentación solo tiene que obtener el color de un píxel y comprobar la clase a la que pertenece en la tabla, siendo este un proceso extremadamente rápido.

Después de la segmentación, la imagen se divide en varias regiones de interés, correspondientes a las diferentes clases encontradas. A continuación, se realiza un análisis dentro de cada una de las ocho secciones en que se había dividido la escena para encontrar los frutos (suma de todas las clases, excepto el fondo). Para estimar el color estándar de la fruta se utilizó el ICC (Jiménez-Cuesta et al., 1981) calculado según la Ecuación (1), donde L, a y b son las coordenadas del espacio de color de Hunter Lab. El valor de RGB promedio de cada vista parcial de la fruta se calculó durante el proceso de segmentación anterior. Luego, se convirtió en coordenadas HunterLab para obtener el ICC parcial. El ICC de la fruta se calculó como la media del ICC obtenido en cada una de las cuatro imágenes de la misma fruta (Vidal et al., 2013).

$$ICC = (1000 \times a) / (L \times b), \quad (1)$$

donde L, a y b son las coordenadas de color en el espacio de color HunterLab.

Para optimizar y agilizar el proceso, se estimó el tamaño del fruto a partir de la suma de todos los píxeles, considerados como pertenecientes al fruto al segmentar la imagen. Luego, se calculó el diámetro usando la Ecuación (2) para el área:

$$d = 2 \times \sqrt{(A/\pi)}, \quad (2)$$

donde d es el diámetro (tamaño) estimado de la fruta y A es el área calculada como el número de píxeles en la fruta. Finalmente, el diámetro de la fruta se calculó como la media de los diámetros parciales obtenidos en cada una de las cuatro imágenes de la misma fruta (Cubero et al., 2014).

3.4. Mandos de control del prototipo

Para la conducción del prototipo se cuenta con un mando de control remoto por RF. Este mando permite variar la velocidad, la dirección de la máquina y demás acciones típicas de control y manejo de un vehículo.

Para el accionamiento de los dispositivos de carga y descarga de contenedores se cuenta con otro mando secundario desde el que se pueden accionar los sistemas hidráulicos de la plataforma

y del remolque. Las acciones incluyen el movimiento de las cintas transportadoras, el movimiento de las guías sobre las que se apoyan los contenedores dentro del prototipo y el funcionamiento de todas las acciones del remolque para el movimiento auxiliar de entrada y salida de contenedores por medio de guías. A modo de seguridad, estas acciones también están configuradas en el mando principal.

Para el funcionamiento de manera inalámbrica, se ha diseñado un protocolo personalizado de comunicación a través de módulos de RF de 868 MHz. Con ello, la centralita ubicada en la plataforma recibe la información de las acciones de ambos mandos y actúa sobre el módulo de entradas/salidas de diseño propio para activar las electroválvulas o los circuitos necesarios según la acción presionada en cualquiera de los mandos. Este protocolo permite además a la centralita recibir la información seleccionada para accionar los distintos elementos del sistema de visión. Esta centralita también gestiona los datos recibidos desde la placa de control del sistema de inspección.

Además, cada una de las cuatro tarimas donde se posicionan los recolectores cuenta con un mando individual de control de las acciones para poder ajustar su posición en función de las necesidades. Al igual que en el mando secundario, estas acciones están también implementadas en el mando principal.

3.5. Sistemas de posicionamiento

El prototipo incorpora un GNSS (Hiper SR, Topcon Positioning Systems, Tokio, Japón) para obtener información sobre la ubicación geográfica de la plataforma. De esa manera, entre otras posibilidades, se puede conocer la trayectoria que sigue el equipo y la velocidad de avance. El usuario establece la frecuencia de geolocalización, registrándose la hora exacta, junto con otros parámetros, con una precisión de milisegundos. Este receptor utiliza un RTK para mejorar la precisión de los datos de ubicación obtenidos. De esta forma, se consigue una precisión de 10 mm H y 15 mm V (González-González et al., 2020).

3.6. Identificación de necesidades y áreas de mejora en el prototipo

A pesar de ser un prototipo funcional, el equipo tenía grandes carencias tanto estructurales como de funcionalidad que afectaban a la seguridad de los trabajadores, a la calidad de la fruta durante su manejo y al funcionamiento de la inspección por visión artificial. Por ello, se propuso un conjunto de mejoras con la finalidad de hacerlo más seguro, eficaz y operativo.

En cualquier tipo de maquinaria el análisis para detectar deficiencias y riesgos es un factor esencial para garantizar (i) la integridad y la seguridad de la máquina y de los individuos que se encuentren cerca durante el ejercicio de sus funciones, (ii) la calidad del producto con el que opere y (iii) su óptimo funcionamiento. Con ello, se pretende aumentar la productividad, la eficiencia y el buen cumplimiento de las operaciones que realiza la maquinaria en condiciones de seguridad.

Para la identificación de los riesgos para los operarios, se realizó una inspección de los elementos de seguridad activa y pasiva. Tras la identificación de riesgos, se conformaron e implementaron un conjunto de medidas correctivas para la adecuación de los sistemas de seguridad y prevención en el prototipo y la minimización de estos riesgos (Objetivo I).

En base a varias experiencias de funcionamiento del prototipo y a la evaluación de los daños producidos a la fruta mediante la medición de impactos con fruto electrónico se implementaron

mejoras estructurales y funcionales para asegurar la calidad de la fruta inspeccionada por el prototipo a su paso por el mismo (Objetivo II).

Para optimizar la funcionalidad y aumentar la capacidad de trabajo, se realizaron mejoras en el sistema de inspección y en la automatización y control del prototipo (Objetivo III y Capítulo IV).

Por último, para evaluar el funcionamiento del prototipo en campo tras estas modificaciones y determinar el rendimiento de la operación de recolección asistida se llevó a cabo un ensayo del proceso de recolección en condiciones reales de campo (Objetivo IV).

4. Identificación de riesgos y medidas de prevención y seguridad implementadas en el prototipo

Con ayuda del responsable de PRL del IVIA se realizó una inspección de los elementos de seguridad activa y pasiva del prototipo (BOE, 1997; INSST, 2021) y se elaboró un informe en el que se remarcaba la presencia de riesgos potenciales para los trabajadores durante el funcionamiento del prototipo y la ausencia de elementos de seguridad. En base a ello, se idearon e implementaron un conjunto de medidas correctivas en los elementos de seguridad activa y pasiva.

4.1. Elementos de seguridad activa

A continuación, se presentan los riesgos detectados y las soluciones llevadas a cabo en los elementos de seguridad activa inspeccionados:

- Riesgo de caída y accidentes de conducción por la disposición de la columna de dirección.
Solución: automatización del sistema de conducción.

La columna de dirección estaba situada en el paso de los operarios a las tarimas de uno de los lados de la plataforma, de modo que ocupaba parte de la escalera de acceso y de la tarima (Figura 6). Además, con este tipo de conducción se hacía indispensable que el encargado del manejo del prototipo estuviera sobre la plataforma, reduciendo con ello el espacio de trabajo de los operarios colocados en la tarima y, sobre todo, impidiéndole la visualización al completo del prototipo durante la conducción. Por ello, se decidió automatizar los sistemas mecánicos de control del motor diésel, instalando actuadores lineales controlados por la centralita a través del módulo de salidas en el acelerador hidráulico y el sistema de cambio de marchas. Con esta nueva automatización quedó inoperativa la antigua columna de dirección, por lo que se eliminaron tanto el volante como las distintas palancas mecánicas que ejercían acciones en la conducción, minimizando así el riesgo de caídas en la zona de tránsito a las tarimas.

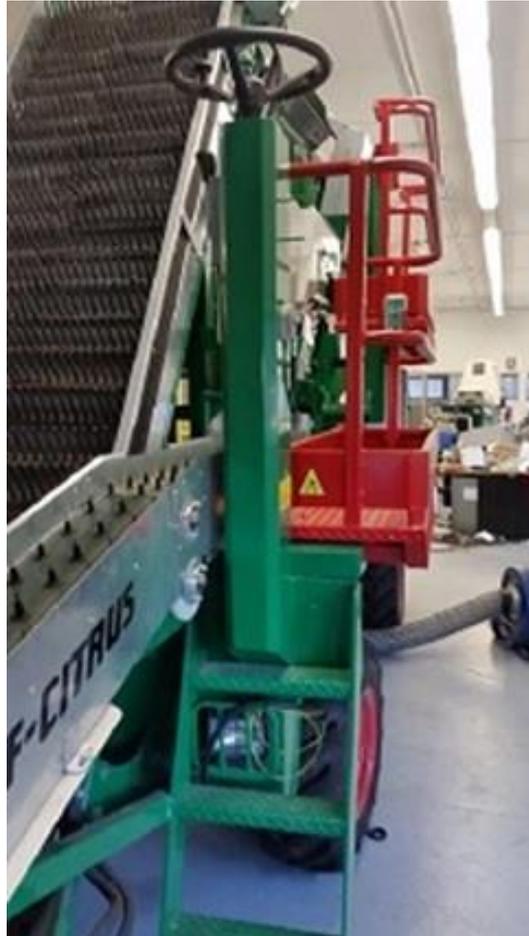


Figura 6. Antigua columna de dirección para la conducción del prototipo.

- Riesgo de volcado por inestabilidad del prototipo.
Solución: adecuación del centro de gravedad, modificación de la dirección delantera y sustitución del actuador lineal.

Para asegurar la estabilidad, se decidió rellenar las ruedas con poliuretano y evitar así posibles pinchazos que puedan desestabilizar el prototipo durante su funcionamiento en campo.

Por otro lado, durante la conducción del prototipo se comprobó que en los giros en segunda velocidad la estabilidad de la máquina quedaba comprometida debido a la velocidad invariable de giro en las ruedas delanteras. Para solucionar este inconveniente se instaló una electroválvula variable en el sistema de dirección delantera, de tal manera que la velocidad de actuación sobre las ruedas se reduce ahora proporcionalmente con la velocidad de marcha del prototipo, disminuyendo así los peligros generados por dicha inestabilidad y minimizando el riesgo de volcado del prototipo.

Por último, para conseguir que los cambios de relación de velocidad se realizaran de forma más segura y controlada y provoquen menos movimientos bruscos que ponen en riesgo la estabilidad del prototipo, se sustituyó el actuador lineal que automatiza el cambio de marcha por uno de mayor rango de trabajo (Figura 7).



Figura 7. Disposición del actuador lineal para control del cambio de marcha.

- Riesgo de accidentes por falta de iluminación de trabajo.
Solución: instalación de un sistema de iluminación.

En condiciones climáticas adversas donde se carece de iluminación adecuada, aumenta el riesgo de accidentes por parte de los operarios. Por este motivo, se decidió instalar un sistema de iluminación mediante focos de trabajo con posición regulable (Figura 8). De esta manera, los operarios pueden efectuar su trabajo en las horas del día de visibilidad reducida e incluso permite trabajar con el prototipo en horario nocturno.



Figura 8. Focos de trabajo instalados en el prototipo en posición de no encendido.

- Riesgo de caídas por pérdidas de fluidos en el prototipo.
Solución: reparación de fugas.

La presencia de fluido en el suelo puede provocar tropiezos y caídas de los operarios durante el trabajo, por lo que se inspeccionaron todos los circuitos de fluidos y se repararon las fugas halladas en el circuito hidráulico encargado de las acciones relativas al movimiento de las tarimas, del sistema de expulsión de los contenedores y de los movimientos del remolque.

- Riesgo de caídas por inactividad repentina y parada brusca del prototipo a causa de fallos de intercomunicación.
Solución: rediseño del sistema de RF.

El cese del movimiento del prototipo de manera brusca y repentina provocaba la inestabilidad de la posición de los operarios colocados sobre las tarimas, causando riesgo de posibles caídas. Estas paradas estaban originadas por fallos en la intercomunicación entre los dispositivos, lo que hacía actuar al sistema de seguridad cesando el funcionamiento al completo del prototipo. Con la finalidad de mejorar la calidad y alcance de señal de comunicación entre dispositivos para minimizar este riesgo y disminuir con ello los tiempos de fallo en la intercomunicación, se modificó por un lado la posición de la antena de emisión/recepción del sistema de RF y, por otro lado, se realizó un diseño más eficiente de este módulo electrónico que ahora consta de los siguientes componentes: (i) una centralita encargada de comunicarse con el mando de

conducción, el remolque y los mandos auxiliares que manejan las tarimas del prototipo, así como de recibir las señales procedentes de los sensores instalados en la máquina y realizar las acciones necesarias para los procesos llevados a cabo en el prototipo; (ii) módulo de salida, esclavo de la centralita, que gestiona las salidas de potencia del prototipo, alimentando los diferentes elementos actuadores como las electroválvulas y los actuadores lineales de acuerdo a las órdenes enviadas por la centralita; y (iii) cuadro de control con pantalla integrada (Figura 9) donde se recogen los distintos módulos y el cableado para poder gestionar más fácilmente los cambios futuros a implementar.

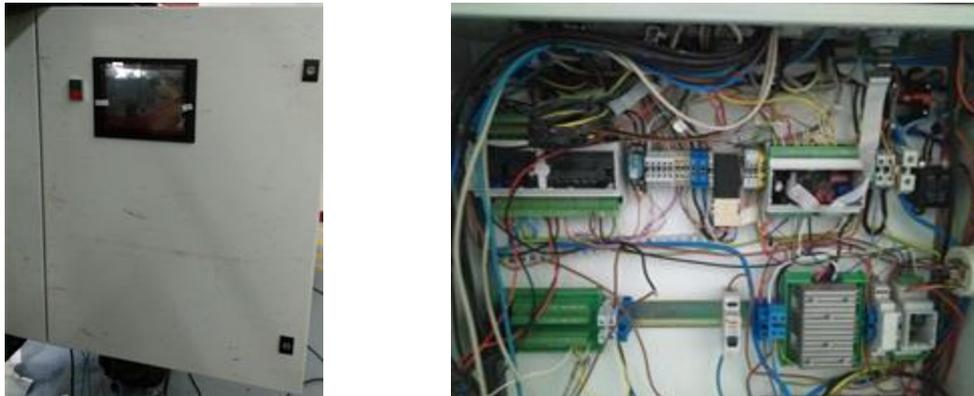


Figura 9. Cuadro de control del prototipo.

- Riesgo de accidente por funcionamiento deficiente de los elementos de frenado.
Solución: rediseño del sistema de frenado.

Tras la prueba visual de frenado (sin frenómetro) llevada a cabo junto al responsable de PRL, donde se simuló el rodaje a baja velocidad sobre asfalto y en campo seguido de frenadas de rudeza moderada, se determinó que existía una amplia capacidad de mejora en el funcionamiento de los elementos de frenado. Por ello, se llevaron a cabo modificaciones en toda la instalación del sistema de frenado (Figura 10) como (i) la modificación del sistema neumático para dotar al prototipo de mayor potencia de frenado, incluyendo un freno de servicio en cada rueda, además de un freno de estacionamiento que actúa sobre la transmisión y el reajuste de la presión de la bomba de servicio, (ii) la colocación de un acumulador de presión hidráulico para el funcionamiento del sistema de frenado de emergencia de manera que este sistema se halle siempre a plena carga aun no estando el prototipo en funcionamiento y (iii) la sustitución de los retenes y las zapatas de los frenos de tambor ubicados en las ruedas traseras y diseño de su accionamiento en base a la presión hidráulica, reduciendo así la distancia de frenado.



Figura 10. Parte de la instalación del sistema de frenado.

- Riesgo de altas temperaturas de trabajo por funcionamiento deficiente del motor.
Solución: reforma del bloque motor.

Debido al funcionamiento inadecuado del motor, este alcanzaba temperaturas considerablemente altas provocando la elevación de la temperatura ambiental en las tarimas inferiores. Para evitar este ascenso de la temperatura de trabajo de estos operarios, se reparó el bloque motor, se sustituyó el alternador por uno de mayor potencia y se diseñó un sistema de ventilación adicional para el motor que ayudara a refrigerar más rápidamente.

- Riesgo de atrapamiento de dedos en el sistema de acoplado prototipo-remolque.
Solución: colocación de una rueda de enganche.

La precariedad en el antiguo sistema de enganche maximizaba el riesgo de atrapamiento de dedos al ejecutar la actividad. Para facilitar la maniobrabilidad se colocó una rueda de enganche en el remolque para el acoplado con el prototipo.

4.2. Elementos de seguridad pasiva

Con la finalidad de adecuar a las condiciones de seguridad para prevención y minimización de riesgos laborales para los trabajadores en maquinaria agrícola, se modificaron e instalaron una serie de medidas en los elementos de seguridad pasiva entre las que destacan:

- Riesgo de caída por desnivel.
Solución: modificación de la posición/eliminación de las escaleras de acceso y colocación de asideros.

Al final de las escaleras delanteras de acceso al prototipo se hallaba un desnivel que dificultaba el paso de los trabajadores con seguridad a las tarimas (Figura 11a), por lo que se desplazó la posición de las escaleras lateralmente para evitar este desnivel y se colocaron además asideros para poder subir al prototipo más fácilmente (Figura 11b). Respecto a las escaleras traseras, se eliminaron por el poco espacio disponible para ellas y su diseño ineficiente, pudiendo así gestionar adecuadamente y de manera segura el acceso al prototipo únicamente por la parte delantera del mismo.

a



b



Figura 11. Modificaciones llevadas a cabo en la sección de las escaleras de acceso a las tarimas del prototipo. **a)** Desnivel presente en la zona de paso de las escaleras. **b)** Asideros para facilitar la subida a las plataformas.

- Riesgo de lesiones y caídas en las tarimas por espacio de trabajo insuficiente cuando no están extendidas y por movimiento apertura/cierre.
Solución: adecuación de la zona de trabajo e instalación de limitadores de carrera.

Por un lado, el escaso espacio disponible de maniobra en las tarimas del prototipo cuando éstas no están extendidas podía provocar dislocaciones y torceduras de tobillo, por lo que se incrementó la superficie pisable del habitáculo para aumentar la zona de movimiento y maniobra del operario (Figura 12) y se modificó la posición de los mandos de actuación incorporados en las tarimas para facilitar su accesibilidad.



Figura 12. Aumento de la superficie pisable en las tarimas del prototipo.

Por otro lado, como medida de seguridad para evitar caídas al finalizar el movimiento de apertura/cierre de las tarimas, se han instalado limitadores de carrera (Figura 13).



Figura 13. Limitador de carrera colocado en una de las tarimas extensibles del prototipo.

- Ausencia de elementos de seguridad para paradas de emergencia.
Solución: instalación de botones pulsadores de seguridad.

Toda maquinaria que no sea de accionamiento manual requiere de botones de parada de emergencia para reducir los riesgos. Con la finalidad de poder detener el prototipo rápidamente cuando hay presente un riesgo, se instalaron pulsadores de parada de emergencia en el prototipo y el remolque, disponiendo uno en cada tarima extensible, dos en la parte delantera de la tolva (Figura 14), dos en la parte trasera del prototipo y dos en el remolque.



Figura 14. Botones pulsadores de seguridad instalados en la parte delantera de la tolva del prototipo.

- Ausencia de elementos de anclaje para los arneses de seguridad.
Solución: instalación de elementos de anclaje fijos en el prototipo.

Los operarios ubicados en las tarimas de la plataforma, al considerarse un trabajo de altura, deben llevar el arnés de seguridad para evitar accidentes y detener caídas como parte de los equipos de protección individual. Estos EPI anticaída se fijan a sistemas de anclaje instalados en la estructura que garantizan una resistencia adecuada para poder detener una caída y que cumplan la normativa (EN 795-A). Por ello, se instalaron unas argollas de seguridad de anclaje estructural. Estas argollas metálicas se soldaron a la estructura del prototipo proporcionando un sistema de anclaje seguro para los arneses utilizados por los operarios.

5. Identificación de áreas de mejora para asegurar la calidad de la fruta a su paso por el prototipo e implementación de mejoras

Pérez-Lluch (2018) evaluó los daños producidos a la fruta a su paso por las zonas transitables del prototipo, simulando que se recolectaba la fruta en los tres niveles (suelo y tarimas a nivel 1 y 2). Con la finalidad de profundizar en el estudio se evaluó el nivel de impacto producido en cada uno de los cuatro carriles con rodillos bicónicos situados bajo la zona de inspección y en la caída de la fruta en ambos contenedores.

5.1. Materiales y métodos

5.1.1. Descripción del fruto o sensor electrónico para evaluación de puntos críticos de impacto en el prototipo

Para evaluar estos puntos críticos susceptibles de producir daños en la fruta, se realizó un ensayo consistente en el estudio de la respuesta de un dispositivo electrónico de grabación de impacto o fruto electrónico (Tuberlog PTR 200, Martin Lishman, Lincolnshire, Reino Unido) a su paso por el prototipo. Este fruto electrónico habitualmente se utiliza para la realización de ensayos en los equipos de manipulación para fruta en fresco (Tennes et al., 1991; Miller y Wagner, 1991; Ortiz et al., 2011).

El dispositivo PTR 200 consta de una unidad de medición y transmisión (el sensor) y un receptor. En su interior contiene un acelerómetro triaxial que permite registrar impactos en las tres dimensiones XYZ. Presenta un rango de impacto entre 30 y 500 G. La energía se suministra por una batería de cloruro de tionilo de litio con un voltaje nominal de 3-6 V (Van Canneyt et al., 2003).

Este fruto electrónico registra la componente de aceleración, el tiempo de impacto y el tiempo desde el inicio de la toma de medida, entre otros parámetros. Estos datos se muestran y almacenan en una tableta con sistema operativo Android (Pérez Lluch, 2018).

5.1.2. Evaluación de impactos en el proceso de clasificación en el prototipo

Para evaluar estos puntos críticos, se realizó un ensayo consistente en el estudio de la respuesta de sensor PTR 200 a su paso por cada uno de los cuatro carriles de las cintas transportadoras de rodillos a una velocidad de avance uniforme establecida en $0,356 \text{ m}\cdot\text{s}^{-1}$ (González-González et al., 2018). Además, para este ensayo se fijó en el ordenador central del sistema de visión el contenedor en el que debía depositarse el fruto electrónico. Se realizaron tres repeticiones para cada carril y para cada contenedor. Este ensayo se llevó a cabo sin fruta y con los contenedores vacíos, por lo que el fruto electrónico era el único elemento que transitaba por el prototipo.

En base a estudios previos, el valor máximo de impacto que no produce daño es 30 G (Bentini et al., 2006). En cítricos, según Miller y Wagner (1991) y Ortiz et al. (2011), el valor considerado es superior a 40 G. Igualmente, dado que el umbral inferior del sensor está en 30 G, se consideró este valor como el umbral inferior para este ensayo, aumentando así el coeficiente de seguridad.

Se realizaron los gráficos representando los valores de la aceleración de impacto obtenidos en las diferentes repeticiones para cada carril y contenedor en función del tiempo.

5.2. Resultados

En la Figura 15 se muestran los gráficos de los impactos registrados por el fruto electrónico durante su paso por cada canal o carril de transporte de fruta hacia el sistema de visión artificial del prototipo y para cada contenedor donde fue depositado el fruto. Para esta comparación, se tomó como referencia el tiempo correspondiente al mayor valor de aceleración de impacto (en todos los casos este impacto se correspondía con la caída al contenedor). Este valor se estableció como origen de coordenadas. Los puntos situados a la derecha del eje Y se corresponden con los rebotes tras el impacto de la caída mientras que los puntos situados a la izquierda de este eje Y se corresponden con los impactos originados durante el proceso evaluado en el prototipo antes de su caída al contenedor.

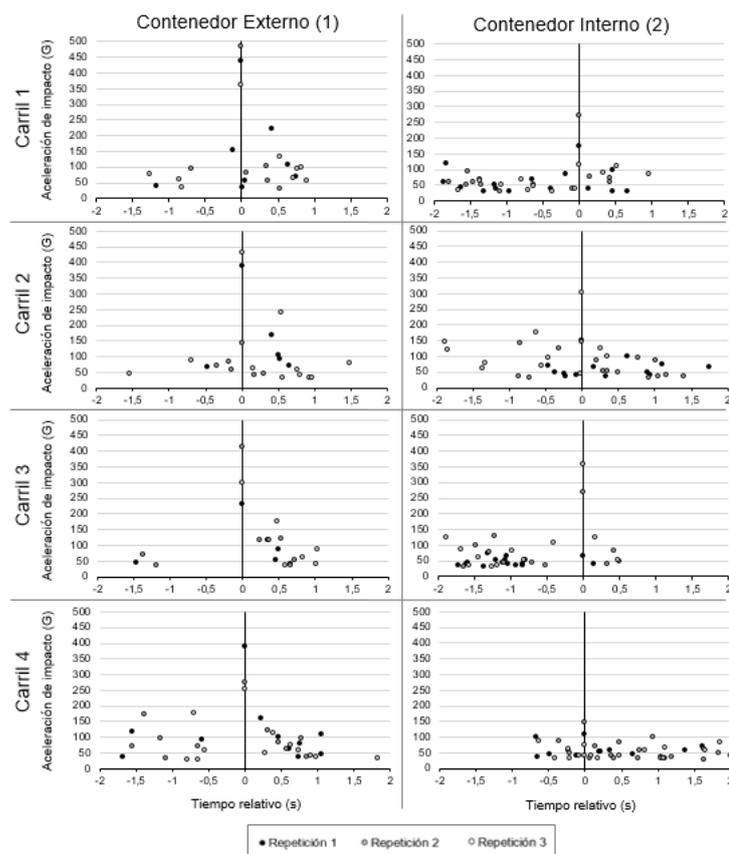


Figura 15. Impactos registrados según contenedor y canal o carril de transporte. Se tomó como referencia el valor de aceleración de impacto más alto (impacto de caída en el contenedor). Los puntos a la derecha del eje Y se corresponden con los rebotes después del impacto de la caída en el contenedor, mientras que los puntos a la izquierda del eje Y corresponden a los impactos previos a la caída en el contenedor.

En el caso del contenedor externo, a excepción del carril 4, se registraron pocos impactos con una aceleración inferior a 100 G (de uno a tres para cada repetición). Se registró también un impacto de caída al contenedor muy alto, entre 300 y 500 G, y unos rebotes que, en algunos casos, fueron de alrededor de 200 G.

Por el contrario, en el contenedor interno, a excepción de nuevo del carril 4, se localizaron varios impactos medios para cada repetición (entre 100 y 200 G). Además, se produjo un impacto de caída alto, entre 150 y 300 G y unos rebotes de bajo impacto tras la caída.

En el carril 4, los impactos antes de la caída en el contenedor externo fueron más numerosos y de un valor considerablemente superior (cerca de 200 G, en algunos casos) que los registrados en el resto de carriles. El impacto de caída registrado en el contenedor interno fue considerablemente menor (inferior a 150 G en todos los casos) que el registrado en el resto de carriles.

5.3. Conclusiones

En la evaluación de los impactos en el proceso de clasificación, el valor del impacto más alto se corresponde siempre con el valor del impacto de caída en los contenedores, siendo claramente mayores los valores registrados en el contenedor externo, esto se debe a que el dispositivo en

forma de corona dispuesto para amortiguar y desacelerar la fruta en la caída al contenedor no está desempeñando las funciones para las que fue diseñado.

Por otro lado, el comportamiento del carril 4 antes de la caída de la fruta en el contenedor externo se debe a la disposición de los elementos estructurales circundantes. En ocasiones, la fruta impacta con la chapa metálica dispuesta al final del carril perteneciente a la estructura del prototipo.

Para el caso del contenedor interno, a excepción del carril 4, los numerosos impactos previos y el valor de impacto de caída (siempre superior a 150 G) se debe a que la fruta proveniente de estos tres carriles se desliza por unos canales metálicos dispuestos en forma de zigzag en los que se golpea la fruta además de acelerar su velocidad de caída antes de depositarse en el contenedor.

5.4. Identificación de áreas de mejora

Este trabajo junto con el de Pérez-Lluch (2018) concluyeron que los puntos críticos con posibilidad de producir daño en la fruta se hallaban en las siguientes secciones:

- Volcadores de fruta.
- Zona de transición entre la cinta transportadora proveniente de las tarimas inferiores y la tolva delantera.
- Zona de transición entre la tolva delantera y la cinta elevadora.
- Zona de transición entre la cinta elevadora y las cintas de rodillos que transportan la fruta hacia el sistema de visión.
- Carril 4 de las cintas de rodillos que transportan la fruta hacia el sistema de visión.
- Zona de transición entre las cintas de rodillos que transportan la fruta hacia el sistema de visión y el depósito en el contenedor interno.
- Depósito en los contenedores, siendo la caída al contenedor exterior la que refleja el mayor valor de impacto.

Además, en varias experiencias de funcionamiento del prototipo en procesos de recolección en condiciones reales donde se recolectaba una cantidad considerable de fruta se detectaron aplastamientos, estancamientos y acumulaciones de fruta y daños como roces y cortes en las siguientes secciones:

- Volcadores de fruta
- Tolva delantera
- Cinta elevadora
- Zona de transición entre la cinta elevadora y las cintas de rodillos que transportan la fruta hacia el sistema de visión.

5.5. Implementación de mejoras

Para solventar estas vicisitudes que causan daños a la fruta se estudiaron diversas opciones a implementar, escogiendo las siguientes para cada sección:

- Volcadores de fruta
 - o Área de mejora: Los anteriores tubos corrugados eran poco manejables y se deformaban al no soportar el peso de la fruta, lo que provocaba amontonamientos de fruta dentro de estos tubos e impactos en la fruta en la curva ocasionada por el peso en la caída. Además, no poseían un sistema de sujeción apropiado por lo que el

trabajador tenía dificultades a la hora de trabajar en la plataforma y su ergonomía era limitada.

- Solución: se rediseñaron los volcadores, implementando unas bancadas metálicas extensibles que se adecúan a la plataforma y cuentan con un sistema de recogida y sujeción adaptado para que permita el paso de personal por el habitáculo una vez finalizada la recolección (Figura 16).

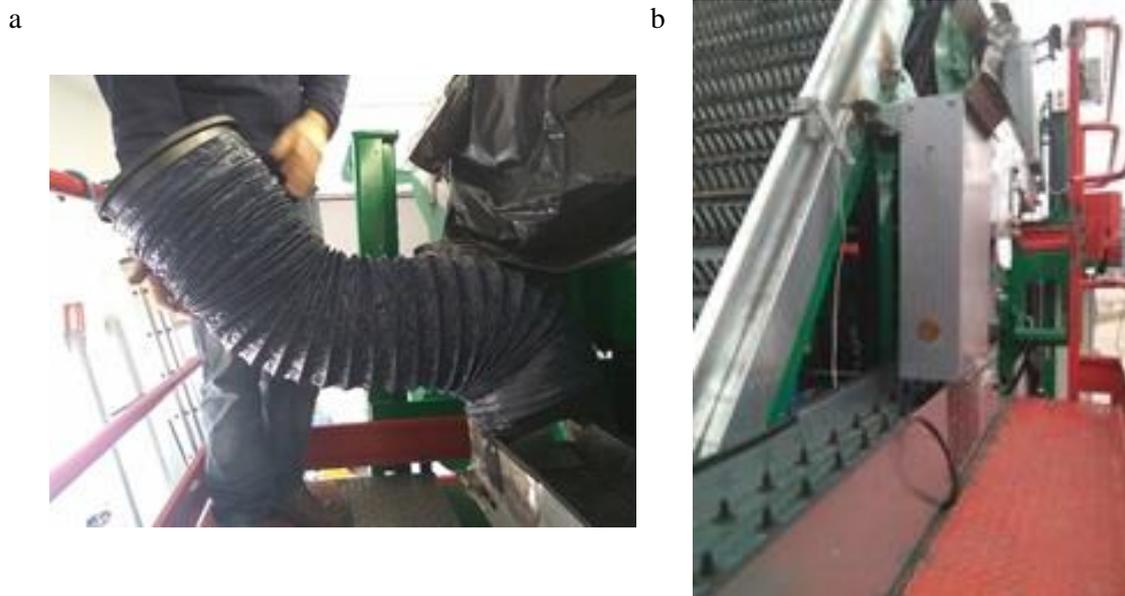


Figura 16. Volcadores de fruta de las tarimas superiores del prototipo. **a)** Diseño anterior. **b)** Diseño actual.

- Tolva delantera y zonas de transición adyacentes
 - Área de mejora 1: en las zonas de transición enlazadas con la tolva se producían aglomeraciones, impactos y, en algunos casos, cortes y daños a la piel de las frutas.
 - Solución 1: se redujo la longitud de los dos brazos donde se encuentran las cintas transportadoras que alimentan a la tolva desde las tarimas con la finalidad de evitar que las frutas se amontonen bajo ellos y aumentar además el espacio de volcado de fruta para los operarios ubicados en el suelo.
 - Solución 2: se modificaron los elementos presentes en la tolva que provocaban estancamiento o daños en la fruta tales como las lonas que fueron recortadas para evitar atrapamientos de la misma con la cinta transportadora y se configuró con una pendiente suave para disminuir el valor del impacto. Además, se redujo la inclinación de la placa metálica inferior con forma de peine situada entre la cinta transportadora de la tolva y la cinta elevadora elevándola pues se colaban frutos por el espacio que quedaba entre el peine y la cinta elevadora cayendo directamente al suelo. Asimismo, se suavizaron todas las chapas y elementos cortantes o punzantes dándoles forma redondeada.
 - Área de mejora 2: en la propia tolva se producían amontonamientos de fruta, quedándose parte de esta sin ascender a la zona de inspección.
 - Solución 1: se modificó su posición, elevando la parte delantera de la misma para favorecer el arrastre de los frutos hacia la cinta transportadora elevadora que hace llegar la fruta a la parte superior del prototipo.

- Solución 2: se diseñó, fabricó e integró un sistema de control en la cinta transportadora colocada en la tolva. Su finalidad es la regulación de la velocidad de dicha cinta en función de la fruta depositada en la tolva, graduando la subida de fruta por la cinta elevadora y evitando así que se produzcan acumulaciones de fruta en la parte superior. Este sistema está compuesto por una placa electrónica, un motor eléctrico independiente y un sensor de llenado (Figura 17). Se trata de un sensor de infrarrojos ajustable en altura gracias a las estructuras diseñadas a tal efecto. Estas estructuras están impresas en impresora 3D con material PLA. La placa electrónica y el sensor están conectados mediante señal a la centralita, de manera que se puede controlar la velocidad y parada de esta cinta transportadora.

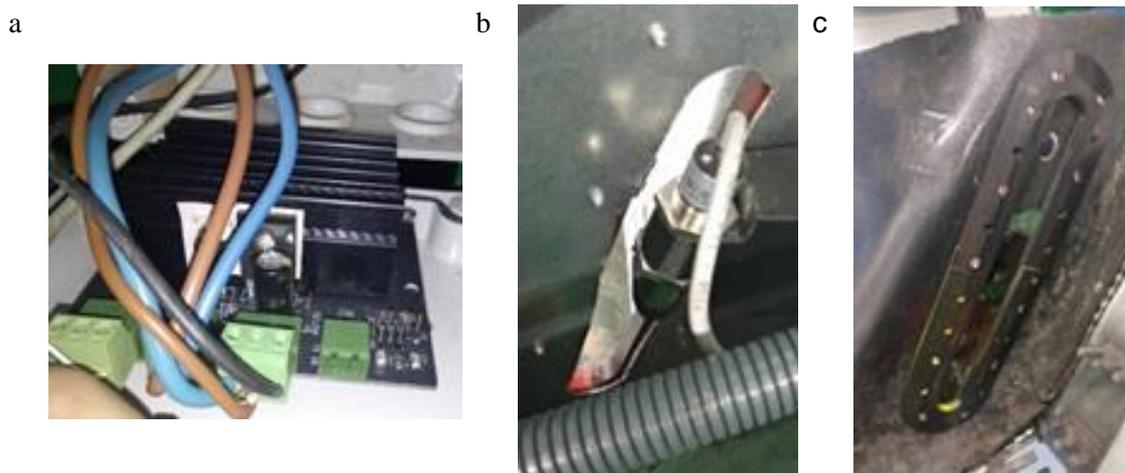


Figura 17. Elementos del sistema de control de la cinta transportadora de la tolva del prototipo.
a) Placa electrónica. **b)** Sensor. **c)** estructura para regular la altura del sensor.

- Cinta elevadora
 - Área de mejora: se producían amontonamientos de fruta, haciendo llegar una cantidad excesiva de frutos a la zona de inspección lo que provocaba fallos en la detección de los parámetros por mal posicionamiento de la fruta en los rodillos.
 - Solución 1: se colocó un rodillo de nylon con cerdas abiertas en la punta en la parte baja de la cinta elevadora (Figura 18). Hubo que quitar este elemento pues no disminuía considerablemente la cantidad de fruta que ascendía.



Figura 18. Rodillo de nylon.

- Solución 2: se modificó el diseño de la cinta elevadora disminuyendo la longitud de los dedos de goma que la componen hasta la mitad y eliminando todos los dedos de la parte central de la misma.
- Solución 3: se diseñó un dispositivo para disminuir la cantidad de fruta que asciende por la cinta elevadora. El primer diseño se basaba en elementos rectangulares, pero por su condición plana la fruta quedaba retenida y no llegaba a ascender. Posteriormente, se rediseñaron colocando unos dispositivos de material plástico PLA con forma semicircular fabricados con impresora 3D (Figura 19).



Figura 19. Dispositivos para reducir el ascenso de fruta al sistema de visión. **Izq.)** Diseño metálico anterior con superficie plana. **Dcha.)** Diseño plástico actual con superficie redondeada.

- Zona de transición entre la cinta elevadora y las cintas de rodillos que transportan la fruta hacia el sistema de visión.
 - Área de mejora 1: los frutos se quedaban atrapados, se aplastaban o directamente según el tamaño se caían por el espacio presente entre el peine colocado tras la cinta elevadora y las cintas de rodillos, además de sufrir impacto por la altura de caída.

- Solución: al igual que para el otro peine metálico, se disminuyó su inclinación reduciendo así el espaciado entre cintas logrando disminuir con ello la altura de caída.
- Área de mejora 2: la fruta no se colocaba correctamente entre los rodillos.
 - Solución: para alinear e individualizar la fruta de manera que se coloque una sola fruta por espacio entre rodillos se diseñaron dos dispositivos de material plástico PLA, uno para conjunto de dos cintas de rodillos (Figura 20).



Figura 20. Dispositivo de asistencia en la colocación de la fruta entre los rodillos.

- Cintas de rodillos que transportan la fruta hacia el sistema de visión
 - Área de mejora: la fruta sufría numerosos impactos de bajo valor en el último tramo del carril 4 y en la zona de transición para depositar la fruta en el contenedor interno.
 - Solución: con la finalidad de reducir los impactos se evaluaron distintos materiales que podrían ser colocados en las superficies de ambas zonas. González-González et al. (2018) evidenciaron la adecuación de un material con recubrimiento plástico y con alta capacidad de absorción de impactos para su uso en condiciones exteriores (Figura 21). Este material cuenta con una densidad de $146,87 \text{ kg}\cdot\text{m}^{-3}$ y un grosor de 3,10 mm.



Figura 21. Material absorbente de impactos.

- Contenedor exterior
 - Área de mejora: la fruta sufre un alto valor de impacto al depositarse en este contenedor.
 - Solución 1: se eliminó la corona cuya función era amortiguar y desacelerar la fruta en la caída al contenedor pues no ejecutaba adecuadamente la función para la que fue diseñada. Además, no disponía los frutos equitativamente en el interior del contenedor lo que provocaba un desplazamiento del centro de masas de la máquina cuando el contenedor estaba a plena capacidad (Figura 22).

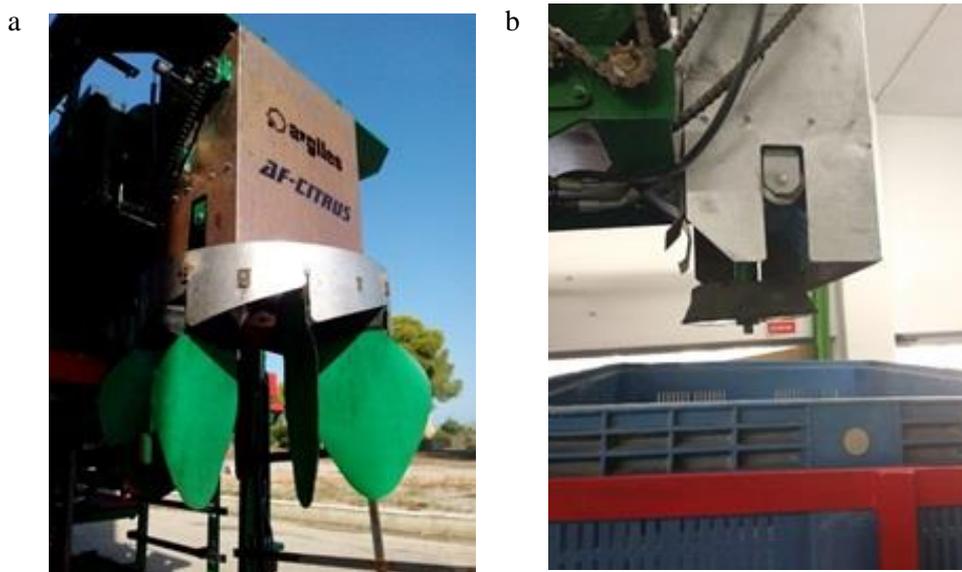


Figura 22. Corona de deposición de fruta situada en la parte trasera del prototipo. **a)** Versión con corona. **b)** Versión sin corona.

- Solución 2: se configuró el dispositivo de elevación de este contenedor para poder regular la altura automáticamente desde el mando principal conforme se va llenando y lograr así disminuir el valor del impacto sufrido por los frutos.

6. Avances en el sistema de inspección y en el control y automatización de las funciones del prototipo

Con la finalidad de aumentar la capacidad de trabajo durante el proceso de recolección y optimizar la funcionalidad del prototipo, se incorporaron además avances y mejoras relacionadas con el sistema de inspección automática de la fruta y con el control y la automatización del prototipo y sus funciones.

6.1. Avances en el sistema de inspección automática

Entre las implementaciones para aumentar la productividad del sistema automático de inspección figuran:

- Mejoras en los algoritmos de detección de calidad.
 - o Área de mejora: el sistema de inspección obtenía las características externas relacionadas con el diámetro ecuatorial y el ICC de la fruta, pero no detectaba defectos.
 - Solución: con la finalidad de dar un paso más en la extracción de características externas de la fruta, se implementaron algoritmos adicionales para la detección de defectos en la fruta (Figura 23). La configuración de estos algoritmos en el programa permite poder estimar el número de daños encontrados en la fruta, el porcentaje de área dañada sobre el total de la fruta y el ICC de cada daño.

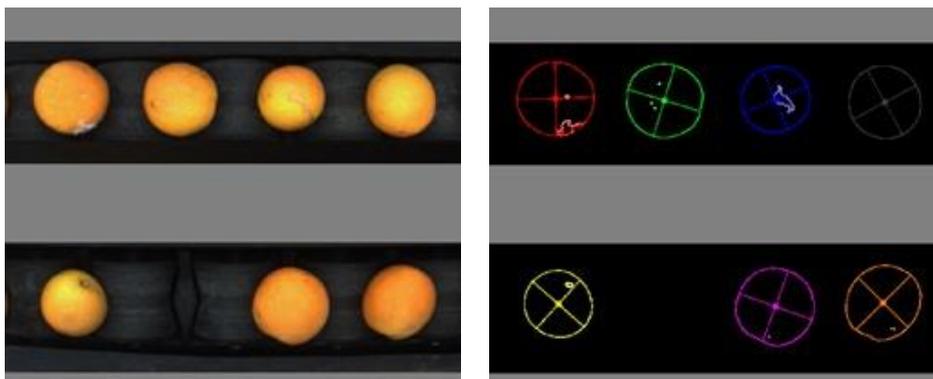


Figura 23. Detección de defectos en la fruta.

- Implementación de algoritmos de detección de posicionamiento de la fruta.
 - o Área de mejora: el sistema de inspección presentaba errores en la extracción de características externas y en la clasificación cuando una fruta se posiciona sobre otra u otras.
 - Solución: con la finalidad de evitar estos errores, se modificó el programa implementando algoritmos adicionales para la detección del posicionamiento de la fruta (Figura 24). Con esta nueva configuración, se puede detectar fruta posicionada sobre otra fruta evitando, por ejemplo, que dos frutas pequeñas juntas se confundan por una fruta más grande lo que conllevaba una adquisición errónea de características externas.

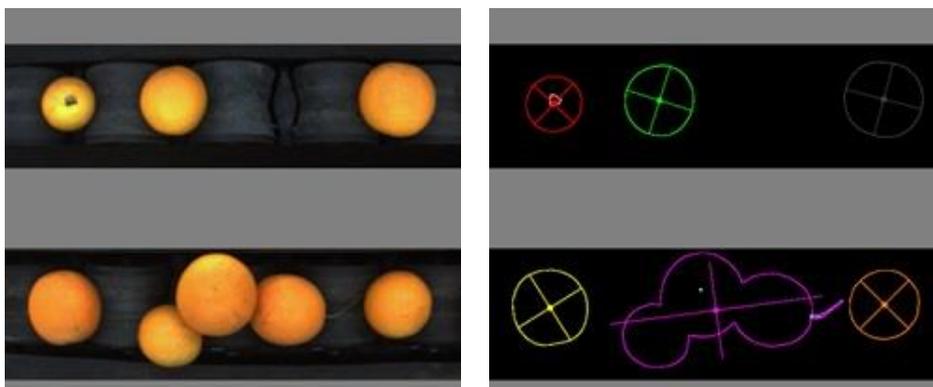


Figura 24. Detección de fruta montada.

- Rediseño del sistema de iluminación y nueva placa de control del sistema de inspección.
 - o Área de mejora: la anterior disposición carecía de suficiente potencia lumínica y no presentaba los requisitos necesarios para poder detectar nuevas características externas en las frutas.
 - Solución: para aumentar esta potencia se incrementó el número de tiras LED de color blanco y, además, con el fin de lograr detectar defectos, como presencia de podredumbres, sensibles a la luz en el espectro infrarrojo se instalaron tiras de luz infrarroja. Con esta nueva configuración lumínica, fue necesario crear una nueva placa de control del sistema de inspección que albergara el control individual de cada tipo de iluminación (Figura 25).



Figura 25. Nueva placa de control.

6.2. Mejoras en el control y la automatización del prototipo y sus funciones

En cuanto al control y la automatización del prototipo y sus funciones, se solucionaron algunas deficiencias detectadas en varias experiencias relacionadas con la funcionalidad, además de implementar soluciones prácticas para mejorar así la eficiencia de funcionamiento.

- Rediseño del mando de conducción del prototipo.
 - o Área de mejora: el anterior mando de conducción presentaba inconvenientes en su uso en condiciones exteriores como la presencia de reflejos con luz solar directa, una pantalla de reducido tamaño que dificultaba la visibilidad de la información, continuas interrupciones de la señal por RF y un gran desgaste por el uso en su diseño de materiales inadecuados para trabajos en exteriores.
 - Solución: se rediseñó la configuración externa del mando, eliminando la repetitividad de funciones en la botonera, colocando una pantalla LCD con posibilidad de retroiluminación para evitar reflejos bajo la luz solar y mejorando su ergonomía y usabilidad (Figura 26). Asimismo, se modificó también el firmware para proveerlo de mayor robustez frente a posibles interrupciones de la señal por RF.



Figura 26. Nuevo diseño del mando del prototipo.

- Incorporación, diseño de interfaz y puesta en funcionamiento de una pantalla con HMI táctil en la parte exterior del cuadro de control.
 - o Área de mejora: la pantalla anterior mostraba los parámetros de funcionamiento básicos configurados en el ordenador del prototipo para su visualización desde el exterior. Al carecer esta pantalla de funcionamiento táctil, para modificar o visualizar información alternativa sobre el funcionamiento del prototipo era necesario abrir el cuadro de mando y operar directamente con el ordenador central y sus dispositivos (teclado y ratón). Al tener que abrir el cuadro de mando para operar directamente con el ordenador del prototipo, se perdía la estanqueidad quedando expuesto su interior ante las inclemencias e incidencias en campo debidas, por ejemplo, a la condensación de agua, el golpe de ramas de los árboles, etc.
 - Solución: se sustituyó por una pantalla con HMI táctil configurada para la visualización y control de los parámetros de clasificación de fruta (Figura 27), conectada directamente a la centralita. Entre las funcionalidades configuradas se encuentran la regulación y selección del sistema de iluminación, la selección del método de clasificación y sus umbrales y la configuración del llenado de contenedor y selección del mismo. También muestra por pantalla un resumen básico de parámetros estadísticos de la sesión de trabajo durante el proceso de recolección.



Figura 27. Pantalla HMI táctil.

- Modificación del firmware de la centralita.
 - o Área de mejora: con las nuevas modificaciones se hacía indispensable poder incorporar protocolos de comunicación con la nueva pantalla HMI y con la nueva placa de control de inspección.
 - Solución: se modificó el firmware de la centralita aprovechando además para insertar también el control de velocidad de la cinta transportadora de la tolva, así como las mejoras en la comunicación por RF con el mando inalámbrico principal.
- Creación de un cuadro de mando para visualizar la información en mapas, tablas y gráficas.
 - o Área de mejora: los sensores instalados en el sistema de inspección del prototipo adquieren una cantidad ingente de datos, pero carecen de un sistema de procesamiento y visualización de los mismos. Además, la falta de interconexión entre los datos relacionados con las características externas de la fruta adquiridos por este sistema de inspección y los datos de ubicación obtenidos por un GNSS no permitía poder georreferenciar la fruta y obtener parámetros y rendimientos relacionados con la localización.
 - Solución: se desarrolló una herramienta en forma de cuadro de mando, denominada *CitrusYield*, que asocia los parámetros de calidad de la fruta con su ubicación exacta, extrayendo y mostrando la información de rendimiento y calidad en forma de mapas, tablas y gráficos. El desarrollo y evaluación de esta herramienta aparece detallado en el capítulo IV.

7. Evaluación del funcionamiento del prototipo y determinación del rendimiento de la operación de recolección asistida.

7.1. Materiales y métodos

7.1.1. Parcela experimental

Para el ensayo se buscó una parcela de naranjas que cumpliera los requisitos mínimos para que el prototipo de asistencia a la recolección pudiera trabajar y que son: (i) amplitud de calle libre de vegetación de mínimo 3 m de ancho, (ii) espacio al final de la calle para permitir el giro del prototipo de mínimo 4 m de radio de giro y (iii) altura de los árboles de mínimo 3 m. La parcela que se seleccionó estaba plantada con naranjos 'Valencia' y situada en Lliria (Valencia, España) (WGS84 (Decker, 1984): W: 39.679603, N: -0.609973). La parcela tenía una distancia entre líneas de cultivo de 6 m y una distancia entre árboles de una misma línea de cultivo de 4 m. La superficie total de la parcela era de 1,56 ha y con una longitud media por calle de 92 m.

Días previos al ensayo, se dieron temperaturas muy bajas que provocaron la helada de los frutos más expuestos en la parte alta, por lo que dichos frutos se recolectaron previo al ensayo con el prototipo.

7.1.2. Recolección con la plataforma de asistencia

Para el ensayo se recolectaron con la asistencia del prototipo los frutos pertenecientes a los árboles de cuatro calles. En la Figura 28 se muestra el recorrido de la plataforma durante el ensayo, comenzando la recolección por la calle 1 (C1) y continuando por las calles 3 (C3) y 5 (C5)

realizando los giros mostrados en el esquema. La última calle recolectada fue la 2 (C2). En cada calle de cultivo se recolectaron los frutos posicionados en las caras de los árboles pertenecientes a las filas que limitan cada calle de cultivo por donde transita el prototipo. Los frutos recolectados se enviaron a almacén.

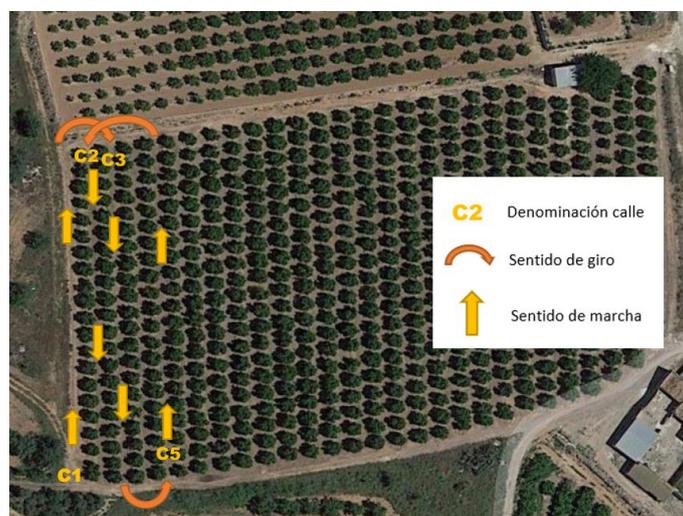


Figura 28. Esquema de desplazamiento del prototipo durante la recolección en la parcela.

Para la recolección con la plataforma se emplearon ocho operarios, de los cuales cuatro estuvieron fijos a nivel de suelo, dos fijos en el primer nivel de tarimas extensibles del prototipo y los otros dos alternaban su posición entre el suelo o las tarimas en función de la cantidad de fruta presente en los árboles y la altura a la que se encontraba. Los operarios a nivel de suelo iban dotados con bolsas recolectoras de 20 kg de capacidad, las cuales disponen de una abertura en su parte inferior para vaciar la fruta en la tolva del prototipo (Figura 29).



Figura 29. Operario descargando la bolsa recolectora en la tolva del prototipo.

Para la recolección se dispuso la frecuencia del GNSS instalado en el prototipo en 1 Hz. Además, se configuraron el GNSS y el sistema de inspección para registrar la hora exacta con una precisión de segundos con el fin de sincronizar posteriormente la información de ambos sistemas.

En el sistema de inspección y clasificación del prototipo se estableció el valor de diámetro mínimo de sección ecuatorial de 67 mm. De manera que aquella fruta cuyo diámetro fuera superior a 67 mm, se consideraba de categoría I, ubicándose en el contenedor exterior dispuesto

sobre la plataforma, y el resto, con diámetro igual o inferior a 67 mm se consideró de categoría II, enviándose al contenedor interior.

Durante la recolección, se anotaron las diversas contingencias observadas durante el proceso de trabajo del prototipo y se registraron las horas de inicio y fin (i) de la recolección total, (ii) de la recolección en cada calle, (iii) de cada giro entre calles, (iv) de la entrada y salida de contenedores en el prototipo, (v) de las pausas de descanso y (vi) de las incidencias producidas durante la recolección.

Los contenedores llenos de fruta que se expulsaban del prototipo y se posicionaban en el suelo de la parcela se etiquetaron anotando el número de contenedor, la categoría de la calidad de la fruta contenida, el número de calle donde se hallaba ubicado y la hora a la que se expulsó del prototipo.

Estos contenedores se enviaron a almacén para su pesaje.

7.1.2.1. Comprobación de la cantidad de fruta recolectada según el sistema de inspección respecto a la cantidad real recolectada por el prototipo

Se realizó una comparativa para verificar el cálculo de la cantidad de fruta recolectada según el sistema de inspección respecto a la cantidad real de fruta recolectada con el prototipo.

La cantidad de fruta total recolectada con el prototipo se calculó a partir del pesaje de los contenedores de fruta en la báscula industrial del almacén (Báscula monocélula con Columna, Abonir Ibérica, Castellón, España).

La cantidad de fruta recolectada según el sistema de inspección se calculó en base a los datos del diámetro estimado de los frutos obtenido por el sistema de visión del prototipo. A partir del diámetro de cada fruta se estimó su peso en base a una ecuación de regresión que relacionó ambos parámetros. Para obtener los coeficientes de dicha ecuación se realizó un ensayo con 449 frutos de naranjas 'Valencia' en el que se midió el diámetro de la sección ecuatorial de cada fruto mediante un calibrador electrónico (Serie LC, PCE Instruments, Albacete, España) y su peso con una balanza especial para industria agroalimentaria (BPA224 series, Mettler-Toledo, Leicester, Reino Unido). Posteriormente, se ajustaron los datos mediante una regresión polinomial cuadrática, obteniéndose un $R^2 = 0,934$ (Figura 30).

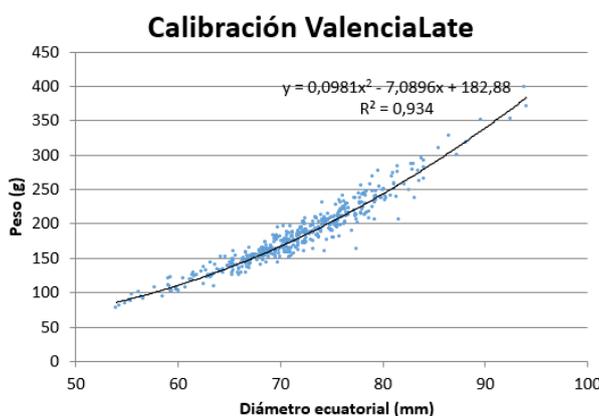


Figura 30. Curva de regresión diámetro-peso para naranjas 'Valencia'.

7.1.2.2. Cálculo del rendimiento del proceso de recolección con el prototipo

Para el cálculo del rendimiento se tuvieron en cuenta los tiempos registrados durante la recolección, detallados en el apartado 7.1.2. En base a ellos, se obtuvieron los siguientes tiempos:

- Tiempo muerto: tiempo que le lleva al prototipo realizar la maniobra de giro y situarse en la nueva calle. Durante este tiempo no se puede volcar fruta en la tolva del prototipo.
- Tiempo muerto recuperable: tiempo consumido por incidencias y paradas que pudieron ser evitadas por su carácter fortuito.

Los parámetros obtenidos en función de estos tiempos y que se definen posteriormente se denominan:

- Reales: parámetros obtenidos en base a los tiempos registrados durante el proceso de recolección, esto es, se tuvo en cuenta como base el tiempo que tardó el prototipo en recorrer cada calle, más el 'tiempo muerto' y el 'tiempo muerto recuperable'.
- Previstos: aquellos obtenidos sin tener en cuenta el 'tiempo muerto recuperable'.
- Teóricos: parámetros calculados sin tener en cuenta el 'tiempo muerto' y el 'tiempo muerto recuperable'.

Los siguientes parámetros, obtenidos a partir de todos estos tiempos, se calcularon para cada calle y se promediaron para obtener los valores medios.

- Velocidad de avance del prototipo ($\text{km}\cdot\text{h}^{-1}$): se calculó dividiendo la medida de la longitud de cada calle por el tiempo tardado en recorrerla. Para el caso de la primera calle, que sólo tenía árboles en uno de sus laterales:
 - o Se calculó el valor de la velocidad considerando el tiempo tardado en recolectar las naranjas correspondientes a la cara de los árboles de esta fila.
 - o Se estimó el valor de la velocidad para el supuesto caso de tener árboles en ambos laterales de la calle, como ocurre con el resto de calles por donde transitó el prototipo. Para ello, se consideró que el tiempo tardado en recorrerla es del doble al obtenido para el caso de recolectar un solo lateral de la calle.
- Rendimiento ($\text{h}\cdot\text{ha}^{-1}$): se calculó a partir de la inversa de la velocidad de avance entre el ancho de calle.
- Capacidad de trabajo ($\text{ha}\cdot\text{h}^{-1}$): se calculó como la inversa del rendimiento y cuantifica la superficie recolectada por unidad de tiempo.

Al carecer el prototipo de sensor de nivel de combustible, para la estimación de consumo del mismo durante el ensayo de recolección, antes de iniciar el ensayo, se llenó el depósito de combustible hasta su nivel máximo. Una vez finalizado el ensayo, se rellenó el depósito en condiciones similares y se obtuvo así la cantidad de combustible consumida. Para estimar el gasto económico del consumo de combustible por hectárea recolectada, se consideró un precio medio para el combustible gasóleo B de 0,87 € por litro (Statista, 2020b).

7.1.2.3. Evaluación del sistema de clasificación del prototipo

Después de la recolección, se realizó una prueba para evaluar el funcionamiento del sistema de clasificación del prototipo en condiciones de campo que consistió en comprobar si los diámetros de la fruta clasificada en las dos categorías según el sistema de clasificación eran correctos acorde al criterio de clasificación seleccionado en la plataforma durante la recolección. Este criterio establecía que los frutos con un diámetro igual o superior a 67 mm se clasificaban

como categoría I en el contenedor exterior; y los frutos con diámetro inferior a 67 mm se clasificaban como categoría II en el contenedor interior.

Para esta prueba, se seleccionaron un total de 1000 naranjas, 500 naranjas de cada categoría, cogiendo 100 naranjas al azar de cinco contenedores de cada una de las categorías seleccionadas también aleatoriamente.

En primer lugar, cada fruto se clasificó como 'correcto/no correcto' en función de si pasaban o no a través de un anillo de material plástico PLA con la medida del diámetro umbral creado con impresora 3D (Figura 31). Posteriormente, se contabilizaron el número de frutos en función de esta clasificación y en aquellos frutos clasificados como 'no correcto' se llevó a cabo una medición más precisa con un calibrador universal electrónico digital (Serie LC, PCE Instruments, Albacete, España).

Por último, se calculó el porcentaje de frutos correctamente clasificados respecto al número total de frutos observados según la categoría del contenedor.



Figura 31. Anillo de material plástico PLA para clasificar la fruta en función de su diámetro.

7.1.2.4. Evaluación de daños en la fruta

Para evaluar si se producían daños en la fruta a su paso por el prototipo y si éstos eran de grado mayor a los producidos durante la recolección manual sin asistencia, se realizó un seguimiento poscosecha de frutos recolectados siguiendo el proceso comercial. Este seguimiento consistió en estudiar la aparición de podredumbres en las naranjas, seleccionando aleatoriamente frutos recolectados que habían pasado por el prototipo y frutos que se recolectaron de manera tradicional sin asistencia. Para ello, después de la recolección se seleccionaron 5 muestras de 25 frutas cogidas al azar para cada método de recolección, un total de 125 frutos por método de recolección. Los frutos de cada muestra se colocaron en una caja con alveolos para evitar el contacto entre los mismos. Las cajas se almacenaron durante ocho semanas en una cámara frigorífica en condiciones de mantenimiento comercial a temperatura media de 6,13 °C y humedad relativa media de 95,29%. Los frutos se revisaron semanalmente para observar la aparición de podredumbre y retirar la fruta afectada en su caso. Por último, para cada método de recolección se calculó el porcentaje de frutos con presencia de podredumbres frente al número total de frutos observados.

Se compararon los porcentajes de podredumbres entre el método de recolección tradicional y el método de recolección asistida por el prototipo mediante un ANOVA para conocer si existían diferencias significativas. Se comprobaron los supuestos de homocedasticidad a través de la prueba de Levene y la normalidad mediante el gráfico de probabilidad normal de los residuos. El

nivel de confianza utilizado para el análisis fue del 95%. Se realizó utilizando el software Statgraphics Centurion XVI (Statgraphics Technologies, Inc., The Plains, Virginia, EE. UU.)

7.1.3. *Recolección manual tradicional*

En días anteriores al ensayo, los árboles de las calles restantes de la parcela se recolectaron manualmente mediante el método tradicional. Para ello, los operarios utilizaron tijeras de corte para separar la fruta del árbol y capazos para transportar estas frutas desde el árbol hasta el contenedor situado al final de calle.

Estas frutas se cargaron en camión y se enviaron a almacén para su pesaje.

7.1.3.1. *Cálculo del rendimiento del proceso de recolección manual tradicional*

Para determinar el rendimiento de la recolección manual tradicional se calculó primero la producción recolectada tradicionalmente por hectárea en base al dato de producción proporcionado desde almacén de 84719 kg y a la superficie de 1,34 ha recolectada por este método.

Posteriormente, se calcularon los siguientes parámetros:

- Tiempo que tarda un recolector en llenar un capazo, teniendo en cuenta las siguientes consideraciones:
 - o Peso medio de las cestas o capazos que usaron los recolectores para depositar la fruta recolectada (Pelayo y Duarte, 2019): 20 kg.
 - o Tiempo estimado invertido por el operario para recolectar un kilo de naranja de esta variedad (Mateu et al., 2018): 15,5 segundos.
- Tiempo que tarda el recolector en depositar el capazo lleno en el contenedor y volver de nuevo a su puesto. Para ello, se tuvieron en cuenta:
 - o Distancia media recorrida por el recolector con estos capazos para depositar su contenido en los contenedores: 46m. Se consideró la mitad de la longitud de la fila, ya que los contenedores estaban situados al final de la calle.
 - o Velocidad de desplazamiento del recolector: $1 \text{ m}\cdot\text{s}^{-1}$. Se consideró esta velocidad teórica en base a mediciones realizadas en experiencias previas (datos propios no publicados).
- Tiempo total invertido en el proceso: se calculó como la suma del tiempo de llenado del capazo y el tiempo invertido en ir y volver al contenedor para depositar las frutas del capazo.
- Rendimiento ($\text{h}\cdot\text{ha}^{-1}$): se calculó como el tiempo invertido en el proceso en función de la superficie recolectada. Para ello, se utilizó el valor del número de capazos por hectárea obtenido en función de la producción por hectárea y del peso medio de los capazos y se consideró además un equipo de ocho operarios.
- Capacidad de trabajo ($\text{ha}\cdot\text{h}^{-1}$): se calculó como la inversa del rendimiento.

7.2. Resultados y discusión

7.2.1. Recolección con la plataforma de asistencia

7.2.1.1. Incidencias en el prototipo durante la recolección

En general, el proceso de recolección con la asistencia del prototipo fue conforme a lo esperado. No obstante, se registraron los siguientes acontecimientos:

- Riesgos en materia de prevención y seguridad
 - Riesgo: paradas repentinas a causa de fallos de intercomunicación que pueden provocar caídas.
- Incidencias que afectan a la calidad de la fruta a su paso por el prototipo
 - Área de mejora 1: Sección tolva. En la zona de transición entre las cintas de las tarimas y la tolva se produjo estancamiento de fruta (Figura 32).



Figura 32. Estancamiento de fruta en zona de transición adyacente a la tolva.

- Área de mejora 2: Sección cinta elevadora. En la Figura 33 se aprecian las superposiciones y acumulaciones de fruta producidas en la cinta. Este problema se trasladó al sistema de individualización, que con motivo de la cantidad ingente de fruta no cumplió su función, y al sistema de inspección hacia donde se desplazaron estas acumulaciones de fruta.



Figura 33. Fruta acumulada y superpuesta en la cinta elevadora.

- Área de mejora 3: Sección contenedor interior. Interrupción del paso de fruta en la bajante hacia el contenedor interior por la posición de dos frutas que bloqueaban el movimiento, provocando acumulación de fruta.
- Áreas de mejora en materia de funcionalidad
 - Área de mejora 1: el sistema de guías de rodillos para carga/descarga de contenedores instalado en el prototipo y en el remolque no permitió un deslizamiento adecuado de los contenedores, por lo que se quedaban enganchados entre rodillos (Figura 34).



Figura 34. Izq.) Carga de contenedor del remolque al prototipo. Dcha.) Descarga de contenedor del prototipo al remolque.

- Área de mejora 2: cuando se descargaba un contenedor lleno, si no se manejaba cuidadosamente la descarga del mismo se producía un choque brusco contra el suelo que provocaba que las frutas se desbordaran y saltaran al suelo, cayendo a metros de distancia (Figura 35).



Figura 35. Izq.) Vista lateral del contenedor antes de desbordarse la fruta. Dcha.) Vista trasera del contenedor tras caerse la fruta al suelo.

7.2.1.2. Comprobación de la cantidad de fruta recolectada según el sistema de inspección respecto a la cantidad real recolectada por el prototipo

Tras el ensayo en campo, se recolectaron un total de treinta y ocho contenedores, de los cuales 32 estaban etiquetados con la categoría I y 6 con la categoría II.

El pesaje de los contenedores mediante báscula industrial en almacén dio como resultado 7936 kg de fruta etiquetada como categoría I y 1015 kg de categoría II, teniendo un total de 8951 kg.

En cuanto a la estimación del peso en base al diámetro de las frutas, se calculó un total de 7612,64 kg en la categoría I y 1010,31 kg en la categoría II, dando un total de 8622,95 kg de fruta.

La diferencia de pesos entre la fruta inspeccionada por el prototipo y la pesada mediante báscula es de 328 kg y seguramente se deba al problema de amontonamiento de fruta que se produjo durante su paso por el sistema de visión que no permitió realizar la medición del diámetro de las frutas correctamente.

7.2.1.3. Cálculo del rendimiento del proceso de recolección con el prototipo

En este ensayo se registraron un total de 39 minutos consumidos por las incidencias expuestas en el apartado 7.2.1.1. y 36,55 minutos invertidos en las maniobras de giro del prototipo.

Las velocidades obtenidas de desplazamiento del prototipo se muestran en la Tabla 1. Se aprecia que el prototipo avanzaba prácticamente al doble de la velocidad en la primera calle, lo que es debido a que esa era calle limítrofe de la parcela y sólo había árboles en uno de sus laterales.

Tabla 1. Velocidad de desplazamiento del prototipo para cada calle de cultivo.

Velocidad (km·h ⁻¹)	Calle de recolección				
	1	1*	3	5	2
Real	0,07	0,04	0,04	0,04	0,05
Prevista	0,09	0,05	0,04	0,05	0,05
Teórica	0,09	0,05	0,05	0,06	0,05

* Valor estimado considerando recolección de árboles en ambos lados de la calle.

En la Tabla 2 se muestran los resultados obtenidos para los parámetros de rendimiento y capacidad de trabajo del prototipo durante el ensayo.

Tabla 2. Rendimiento y capacidad de producción de la recolección asistida por el prototipo para cada calle de cultivo.

	Calle de recolección				Valor Medio
	1*	3	5	2	
Rendimiento (h·ha⁻¹)					
Real	44,78	45,71	36,44	34,35	40,32
Prevista	36,08	42,13	33,45	34,35	36,50
Teórica	36,08	33,77	30,17	34,35	33,59
Capacidad de trabajo (ha·h⁻¹)					
Real	0,022	0,022	0,027	0,029	0,025
Prevista	0,028	0,024	0,030	0,029	0,028
Teórica	0,028	0,030	0,033	0,029	0,030

* Valor estimado considerando recolección de árboles en ambos lados de la calle.

La cantidad de combustible consumido durante el ensayo de recolección fue de 24,58 l para la superficie de 0,22 ha. Con estos valores, se estimó que el consumo de combustible del prototipo

por superficie fue de 110,12 l·ha⁻¹. De modo que, el gasto económico de combustible fue de 97,20 €·ha⁻¹.

7.2.1.4. Evaluación del sistema de clasificación del prototipo

En los cinco contenedores de categoría I se obtuvo un 100% de frutas clasificadas correctamente. En los cinco contenedores de categoría II se obtuvo un porcentaje medio de naranjas correctamente clasificadas de 79% (Tabla 3). El diámetro medio de las naranjas mal clasificadas fue de 71,69 mm. Esta diferencia respecto al valor umbral de clasificación de 67 mm se debe a la superposición de frutas a su paso por el sistema de visión, lo que provoca que dos frutas de pequeño tamaño se midan como una sola fruta.

Tabla 3. Porcentaje de frutas clasificadas correctamente en los contenedores de categoría II.

	Denominación del contenedor					Valor Medio
	c1	c2	c3	c4	c5	
Porcentaje de frutos clasificados correctamente (%)	71	83	79	79	83	79
Número de frutos clasificados erróneamente	29	17	21	21	17	21
Diámetro medio de los frutos clasificados erróneamente(mm)	75,55	72,75	70,35	71,41	68,38	71,69

7.2.1.5. Evaluación de daños en la fruta

La cantidad de frutos con presencia de podredumbres fue similar y no se obtuvieron diferencias significativas entre ambos métodos ($F= 0,33$; $gl= 1, 9$; $P=0,579$). Mientras que para la recolección manual sin asistencia se obtuvo un 3% de frutos con presencia de podredumbres, en las frutas que transitaron por el prototipo se registró un 2%.

7.2.2. Recolección manual tradicional

La producción por hectárea calculada para la recolección manual tradicional fue de 63,22 t·ha⁻¹.

Según los valores de los parámetros y los cálculos considerados en la metodología, se obtuvo que el número de capazos por hectárea fue de 3161,16 capazos·ha⁻¹, el tiempo que tarda un recolector en llenar un capazo fue de 310 segundos y el tiempo invertido en ir y venir del contenedor para el vaciado de cada capazo fue de 46 segundos.

Teniendo en cuenta que el rendimiento y la capacidad de trabajo se calculó para ocho operarios, el rendimiento obtenido fue de 44,12 h·ha⁻¹ y la capacidad de trabajo de 0,022 ha·h⁻¹.

Desde una visión panorámica, el uso del prototipo para asistir en la recolección facilita el trabajo del recolector dándole acceso a las partes más altas del árbol sin necesidad de escaleras y reduciendo la fatiga sufrida por el operario al no tener que desplazar el capazo lleno hasta el contenedor, normalmente situado a varios metros de distancia. Además, este prototipo presenta dos ventajas fundamentales: (i) permite obtener parámetros externos de calidad de las frutas durante el proceso de recolección gracias a su sistema de inspección y (ii) separa la fruta en

categorías en función de su diámetro y/o de su color. A diferencia del sistema de inspección para cítricos sobre plataforma desarrollado por Kohno et al., (2011), este prototipo permite inspeccionar a la vez ocho frutas, lo que agiliza el proceso de adquisición de datos y reduce el tiempo de inspección. Además, la clasificación de la fruta en dos categorías en el propio campo permite mejorar la gestión y la logística enviando la fruta en función de su calidad al destino más apropiado, almacén o industria, lo que supone un ahorro tanto de transporte de mercancías como de, por ejemplo, insumos en los tratamientos poscosecha. Asimismo, mientras que la plataforma desarrollada por Lu et al. (2017) necesita amplios marcos de plantación y que los manzanos estén plantados en espaldera, un atributo remarcable de este prototipo es su capacidad para transitar por plantaciones frutícolas con disposiciones clásicas y con unos requisitos mínimos de separación entre filas de árboles y de espaciado en las cabeceras adaptados a los cultivos tradicionales (Mateu et al., 2017).

8. Conclusiones

En el prototipo de plataforma de asistencia a la recolección de cítricos se implementaron mejoras y avances en el área de la prevención y seguridad, en el ámbito de la calidad para garantizar el estado del fruto al transitar por el prototipo y en relación con la funcionalidad tanto del sistema de inspección como del control y la automatización y control del prototipo y sus funciones.

El funcionamiento de la plataforma tras las modificaciones implementadas se evaluó durante un ensayo de recolección en campo, en el que además se determinó el rendimiento de la operación. Respecto al funcionamiento, se observó que los trabajos realizados disminuyeron las incidencias observadas en experimentos previos, agilizando el proceso. Aunque en menor medida, todavía siguen produciéndose acumulaciones de fruta en distintos puntos que habrá que mejorar. Además, se detectaron nuevas áreas de mejora, siendo las más relevantes las halladas en la zona del contenedor exterior. En cuanto al rendimiento obtenido, se apreció que el rendimiento operativo en la recolección manual tradicional ($44,12 \text{ h}\cdot\text{ha}^{-1}$) fue superior al obtenido por promedio utilizando el prototipo ($40,32 \text{ h}\cdot\text{ha}^{-1}$), el cual mejora considerablemente ante la ausencia de incidencias ($36,50 \text{ h}\cdot\text{ha}^{-1}$), lo que indica que el tiempo invertido en el proceso fue menor para la recolección asistida por la plataforma. Asimismo, en la evaluación de la presencia de podredumbres en la fruta a su paso por el prototipo no se detectaron diferencias relevantes frente a la recolección manual tradicional.

Con estos resultados, se evidencia el potencial que ofrece la incorporación de esta tecnología para asistir en la recolección de fruta con destino el mercado en fresco en plantaciones cítricas tradicionales que cumplen los requerimientos mínimos. Además de mejorar la calidad y ergonomía de trabajo de los recolectores, la información extraída de los parámetros de calidad de la fruta y la clasificación por categorías por parte del sistema de inspección proporcionan un valor añadido en la recolección, permitiendo gestionar las frutas clasificadas según sus necesidades y ahorrando con ello costes al agricultor en futuros tratamientos durante el almacenamiento y envasado. Asimismo, los algoritmos de detección de defectos implementados en el sistema de inspección permitirán extraer información útil para el productor cítrico a lo largo de las diferentes campañas de recolección.



Capítulo IV

Herramienta digital para visualización gráfica de datos: *CitrusYield*

CAPÍTULO IV - *CITRUSYIELD*: HERRAMIENTA DIGITAL PARA VISUALIZACIÓN GRÁFICA DEL RENDIMIENTO Y LA CALIDAD DE LOS CÍTRICOS

Resumen

La aplicación de nuevas tecnologías en el ámbito de una estrategia de agricultura de precisión ofrece la posibilidad de vincular información a ubicaciones muy específicas de cultivos. La representación espacial de los datos de explotaciones agrícolas a través de mapas de rendimiento y calidad de fruto permite el manejo del cultivo de manera precisa, lo que significa que las operaciones agrícolas se pueden realizar considerando la variabilidad intraparcelaria, dando como resultado una mayor eficiencia. En este trabajo se presenta la creación y el desarrollo de una nueva herramienta digital en forma de cuadro de mando, llamada *CitrusYield*, para la obtención, manejo y visualización de información de la producción en explotaciones de cítricos. Entre las ventajas que aporta esta nueva herramienta está el poder visualizar la información de forma que se conozca la variabilidad de diferentes características de la parcela relacionadas con la cantidad y la calidad del fruto y que pueden ayudar a un manejo más eficiente y preciso del cultivo.

Además, se muestra la evaluación del funcionamiento de este cuadro de mando a partir de los datos de producción y su calidad, así como de geolocalización, obtenidos mediante un prototipo de plataforma de asistencia a la recolección de cítricos. *CitrusYield* generó automáticamente los mapas, tablas y gráficos que muestran la información global o por calle del cultivo a partir del análisis de los datos recopilados. La principal ventaja de conocer las diferencias de producción dentro del cultivo es proporcionar al productor información precisa para tomar decisiones informadas y tempranas que permitan optimizar recursos y reducir insumos y costos de producción.

1. Introducción

La información sobre calidad y producción en el sector cítrico es uno de los factores más importantes que inciden en el valor comercial de la fruta. Una de las principales herramientas utilizadas en la agricultura de precisión para presentar esta información a los agricultores es la creación de mapas para evaluar la variabilidad espacial presente en el campo (Ping et al., 2005). Estos mapas son una herramienta clave por su utilidad tanto en el desarrollo como en la evaluación de estrategias de gestión de precisión (Sudduth y Drummond, 2007). Sin embargo, en la fase de recolección la generación de mapas que representen la variabilidad espacial no se ha desarrollado ampliamente debido a que ésta se realiza principalmente de forma manual. Por tanto, solo se obtienen los datos de rendimiento por parcela (Qiao et al., 2005). Se han desarrollado algunos sistemas y técnicas para monitorear datos y generar mapas de cultivos de cítricos. Específicamente, Schueller et al. (1999) desarrolló y evaluó un sistema de mapeo de rendimiento de bajo coste para cítricos y Molin et al. (2007) generó mapas de productividad pesando las cajas de fruta recolectada en el campo.

Ambos métodos utilizaron los datos obtenidos de la recolección manual de la fruta, que actualmente es el sistema predominante de recolección en el caso de la producción destinada al mercado de fruta en fresco y que además representa un porcentaje considerable de los costes totales de producción. Con el fin de reducir estos costes y garantizar una producción rentable para los agricultores, se han propuesto una serie de soluciones para permitir la mecanización de la

recolección, descritas en el capítulo I y entre las que figuran las plataformas de asistencia a la recolección para los cítricos destinados al consumo en fresco (Chinchuluun et al., 2009; Kohno et al., 2011; Gutiérrez et al., 2012).

El uso de estas plataformas ofrece una gran ventaja a la hora de calcular la producción de cítricos, ya que permite incorporar tecnología basada en sensores para realizar tareas complementarias, como el recuento de frutos, el pesaje, la clasificación o la extracción de parámetros de calidad. El desarrollo de sistemas de inspección en campo permite determinar la producción y caracterizar su calidad (color, tamaño, presencia de defectos o podredumbres, entre otros) durante la recolección. Esta información, junto con los datos de ubicación obtenidos con un GNSS, facilita la georreferenciación de cada fruto y la asociación con sus propiedades (Cubero et al., 2014). La generación conjunta de mapas de rendimiento y calidad de frutos, junto con información sobre factores condicionantes que pueden afectar al cultivo, como la salud del cultivo, las propiedades del suelo, la presencia de enfermedades y plagas o los datos climáticos, pueden permitir una gestión más eficiente de las fincas.

Los mapas se suelen generar a partir de la información de georreferenciación obtenida en campo utilizando SIG. Estos sistemas son herramientas informáticas específicas que, mediante información espacialmente referenciada, permiten importar, georreferenciar, manipular y visualizar una gran cantidad de datos en diversas formas (gráficos, figuras, mapas, etc.) (Mantovani y Magdalena, 2014). En la actualidad, existen muchas aplicaciones SIG y también aplicaciones de gestión agrícola con módulos SIG integrados (por ejemplo, QGIS, AFS, ArcGIS y Trimble Ag) para gestionar datos espaciales y proporcionar información a los productores agrícolas (Zagórda y Walczykova, 2018). Sin embargo, las funciones básicas de visualización que brindan pueden no ser suficientes para la posterior toma de decisiones, lo que hace necesario crear nuevas herramientas con funciones más avanzadas para convertir los datos obtenidos por los sensores en información útil y práctica para el agricultor de un manera fácil y accesible. Por esta razón, algunos investigadores han comenzado a desarrollar herramientas personalizadas con módulos SIG integrados para agricultura de precisión (Uva y Campanella, 2009; Tan et al., 2015; González-de-Santos et al., 2017; Leorux et al., 2018).

En el caso específico del cálculo y mapeo de la producción de cítricos, existen muy pocas herramientas disponibles que estén dedicadas al procesamiento explícito de esta información. Las herramientas comerciales SIG existentes mencionadas anteriormente no cuentan con algoritmos para el cálculo de la producción, clasificación por categorías relacionadas con la calidad, georreferenciación de la información categorizada en mapas y el análisis estadístico de información por áreas delimitadas dentro del propio cultivo, lo que impide el manejo diferencial inmediato de la parcela. Algunos investigadores han desarrollado herramientas para calcular la producción, pero su penetración en el mercado sigue siendo relativamente baja. Por ejemplo, el programa *Crop Auditor* desarrollado por Ampatzidis et al. (2016) procesa la información obtenida en base al peso de cada una de las cajas de fruta recolectada manualmente y las georreferencia según la ubicación de las cajas.

2. Objetivos

Los objetivos específicos de este trabajo fueron:

1. Creación y el desarrollo de una nueva herramienta digital en forma de cuadro de mando, denominada *CitrusYield*, para la generación automática de mapas de rendimiento y calidad de la fruta accesibles al agricultor, a partir de los datos obtenidos por los diferentes sensores instalados en la plataforma de asistencia a la recolección de cítricos

descrita en el capítulo III de esta Tesis Doctoral, capaz de mostrar la información clave obtenida del cultivo mediante mapas y gráficos.

2. Evaluación del funcionamiento de la herramienta con los datos obtenidos en un ensayo de recolección realizado en una parcela experimental.

3. Creación de la herramienta digital a modo de cuadro de mando *CitrusYield*

3.1. Arquitectura e interfaz de CitrusYield

Un cuadro de mando es una herramienta de gestión de la información que monitoriza, analiza y muestra de manera visual los KPI, métricas y datos fundamentales para hacer un seguimiento del estado del cultivo. El cuadro de mando *CitrusYield* se desarrolló utilizando el software de código abierto R (R Software, 2022) por su alto potencial para el procesamiento, extracción de datos, análisis computacional y visualización gráfica de grandes cantidades de información. Para mejorar las funcionalidades del software R y poder crear el panel de control se optó por utilizar paquetes de R.

Para la creación de la base del cuadro de control se decidió usar el paquete R *Shiny* (Shiny package for R, 2022), que permite crear cuadros de mando con la interactividad propia de las páginas web modernas. *CitrusYield* se configuró para la inserción de las variables de entrada de información, se programó para el procesamiento interno de los datos y se decidió presentar la información de salida mediante tablas, mapas y gráficos (González-González et al., 2019). De esta manera, se pueden extraer conclusiones que permiten un manejo más eficiente del cultivo. Si se producen cambios en cualquier valor de entrada varían de manera inmediata los resultados visualizados en el cuadro de mando sin necesidad de actualizar la consola, lo que se conoce como programación reactiva.

En la interfaz de usuario se definió la configuración de todas las entradas de información y el aspecto del panel de control. Para lograr un diseño intuitivo y de fácil manejo se optó por el paquete R *Shinydashboard* (Shinydashboard package for R, 2022) ya que permite la configuración de los paneles y los botones junto con la arquitectura de la interfaz. El servidor contiene el código para el procesamiento, tratamiento y visualización de la información. Por ello, la creación del cuadro de mando se basó en la configuración de la interfaz de usuario y la programación del servidor.

El entorno operativo para el que se diseñó *CitrusYield* es Windows 7 en adelante.

3.2. Método de adquisición de datos

La adquisición de datos a procesar en el cuadro de mando se lleva a cabo por el prototipo de plataforma de asistencia a la recolección (Figura 1).



Figura 1. Prototipo de plataforma de asistencia a la recolección.

A modo de resumen, este prototipo permite individualizar toda la fruta recolectada a medida que avanza por las cintas transportadoras e incorpora un sistema de visión artificial para inspeccionar la calidad externa del producto durante la recolección. Las características inspeccionadas por el sistema de visión son el tamaño y el color (Cubero et al., 2010). Además, este prototipo tiene dos salidas para separar la fruta en dos categorías comerciales (salida/contenedor 1 y salida/contenedor 2). Aquellas frutas que no logran una categoría comercial por no alcanzar el tamaño mínimo y/o color deseado se envían a la salida 2, mientras que el resto son enviadas a la salida 1. También dispone de un sistema GNSS con RTK para mejorar la precisión de los datos de ubicación obtenidos. De esta forma, se consigue una precisión de 10 mm H y 15 mm V (González-González et al., 2020b).

En el cuadro de mando para georreferenciar cada fruta, se utilizan los datos del GNSS instalado en el prototipo con una frecuencia de geolocalización establecida en el mismo de 1 Hz y con el registro de la hora con una precisión de segundos para sincronizar posteriormente la información geográfica y la adquisición de las imágenes mediante un método de marca de tiempo.

El ordenador del prototipo almacena los archivos correspondientes a los datos de ubicación obtenidos por el GNSS y los archivos que contienen las mediciones obtenidas para cada fruta con el momento en que se capturan las imágenes. Ambos archivos tienen formato de documento de texto. El sistema de visión genera dos archivos, uno por cada cámara. Los datos y mediciones obtenidos del sistema de visión a utilizar por *CitrusYield* figuran en la Tabla 1.

Tabla 1. Datos y medidas obtenidas por la plataforma de asistencia a la recolección y que se utilizan en *CitrusYield*.

Medida	Fuente	Tipo de dato	Definición
Diámetro	Imágenes de la fruta	Numérico	Diámetro máximo de la sección ecuatorial de la fruta
Índice de color	Imágenes de la fruta	Numérico	Número asignado de acuerdo a la coloración de la epidermis de la fruta
Cámara	Prototipo	Factor	Cámara que adquiere la imagen
Canal	Prototipo	Factor	Canal por el que la fruta llega al sistema de visión
Salida	Prototipo	Factor	Salida por la que ha sido enviada la fruta clasificada

3.3. Funcionalidades implementadas en CitrusYield

CitrusYield se desarrolló para permitir la introducción y análisis de diferentes variables cuantitativas, produciendo información sobre el cultivo y el proceso de recolección. *CitrusYield* analiza la información recogida por los sensores (Figura 2), proporcionando (1) una base de datos espacial donde cada fruta está vinculada a su ubicación y características; (2) mapas de la producción y características de la producción; (3) un análisis exploratorio de los datos que se representa en gráficos, diagramas de cajas e histogramas con curvas de densidad; y (4) el cálculo de una serie de parámetros para el análisis espacial del rendimiento del proceso de recolección y el rendimiento del prototipo, como un indicador de calidad de la fruta inspeccionada, el rendimiento del sistema de visión del prototipo, un indicador de productividad y la capacidad de funcionamiento del prototipo.

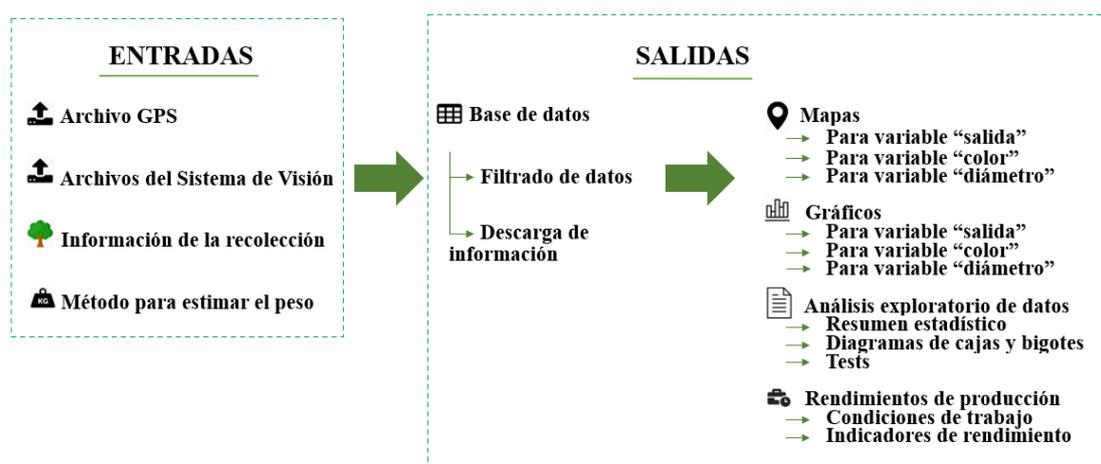


Figura 2. Funcionalidades de *CitrusYield*.

3.3.1. Variables de entrada en el cuadro de mando CitrusYield

La primera sección se configuró para albergar los controles de subida de documentos donde se cargan los archivos correspondientes al GNSS y a los obtenidos del sistema de inspección de la plataforma (Figura 3). Junto a ello, hay una sección para insertar información del cultivo, concretamente la especie de cítrico, la variedad y el marco de plantación, así como, información relativa al proceso de recolección que incluye tres parámetros. El primer parámetro es el valor numérico del diámetro de la sección ecuatorial del fruto que en cada recolección se indica en la plataforma para separar entre las dos categorías de clasificación. Este valor es relevante cuando el método de clasificación del cítrico elegido es en función del tamaño. El segundo parámetro es un valor de tiempo para modificar el punto de georreferenciación de la fruta, de manera que se permite variar la vinculación de la información de su momento de inspección al tiempo de su depósito en la tolva del prototipo o al tiempo estimado de recogida en el árbol, entre otras posibles alternativas. El tercer parámetro creado es relativo a los intervalos de diámetros asociados a cada una de las siete categorías definidas en el panel de mando. Cada categoría puede incluir los cítricos relativos a uno o a un conjunto de códigos de calibre establecidos según el Reglamento Delegado (UE) 2019/428 de la comisión de 12 de julio de 2018 (BOE, 2019).

Figura 3. Imagen del cuadro de mando *CitrusYield*.

Además, en esta sección se diseñó una pestaña en la que se incluyó la estimación del peso de la fruta en función del diámetro ecuatorial creando una nueva variable denominada 'peso estimado' que se inserta en la base de datos. Para su estimación se desarrollaron dos métodos. El primero es el método estándar, en el que se da la posibilidad al usuario de seleccionar por defecto el algoritmo donde se calcula el peso en base a una ecuación de regresión lineal dependiendo del tipo de cítrico (naranjas o mandarinas). Para la obtención de los coeficientes de ambas ecuaciones de regresión se realizó un ensayo con 200 frutos para cada tipo de cítrico en el que para cada fruto se midió el diámetro máximo de la sección ecuatorial y se pesó. Se obtuvo para naranjas la ecuación (1) basada en un ensayo con naranjas 'Navelfoios' ($R^2 = 0,94$) y para mandarinas la ecuación (2) basada en un ensayo con mandarinas 'Clemenules' ($R^2 = 0,94$).

$$\text{Peso estimado (kg)} = [(\text{Diámetro (mm)} - 45,827) / 0,137] \times 10^{-3}, \quad (1)$$

$$\text{Peso estimado (kg)} = [(\text{Diámetro (mm)} - 36,253) / 0,2028] \times 10^{-3}, \quad (2)$$

El otro método es personalizado y se configuró para dar la posibilidad al usuario de insertar los coeficientes de las variables de la ecuación de regresión lineal. Se programó *CitrusYield* para insertar en la base de datos una nueva columna correspondiente a la variable 'peso estimado' en kilogramos, en función del diámetro máximo de la sección ecuatorial en milímetros. En ambos métodos, por defecto, se estableció un valor mínimo para esta variable de 0,01 kg.

3.3.2. Creación de la base de datos

La creación de la base de datos espacial fue un paso fundamental en el desarrollo de este cuadro de mando. Se programó el cuadro de mando para que vinculara la información contenida en los archivos originados por el sistema de visión con el archivo que contiene los datos de ubicación en función del tiempo. Para ello, se configuró *CitrusYield* para que adecúe en cada archivo la representación de las variables temporales en un mismo formato, siendo 'yyyy-mm-dd' para la fecha y 'hh:mm:ss' para la hora. Asimismo, se diseñó para que asigne a cada fruta una longitud, latitud y altitud obtenidas de las tramas de información del GNSS. En caso de que un valor de tiempo no se registrara en estas tramas por fallo de adquisición de información por parte

del GNSS, se programó que el panel de control enlace el tiempo de inspección correspondiente a esa fruta con el tiempo de adquisición de información de ubicación cuya diferencia temporal sea menor, adjudicando a esa fruta la información de ubicación correspondiente a esta trama GNSS. La programación interna permite que la vinculación temporal se pueda modificar con el parámetro de desplazamiento temporal presente en la información acerca del proceso de recolección. Para la posterior georreferenciación en mapas de la fruta, se programó *CitrusYield* para transformar y mostrar las variables de longitud y latitud en el sistema geodésico de coordenadas geográficas WGS 1984 (Decker, 1984). Se diseñó también para que la asignación de la calle de cultivo (espacio entre filas por donde transita el prototipo) para cada fruta se llevase a cabo mediante la detección del giro del prototipo en función de las posiciones registradas en las tramas del GNSS, evaluando la información adquirida por éste cada dos minutos con la finalidad de disminuir el tiempo de procesamiento.

Se decidió que la base de datos espacial creada, relacionase cada fruta con el número de la calle de cultivo asignado donde se recolectó, la fecha y la hora de recolección, la ubicación (longitud, latitud y altitud), las variables relativas al prototipo (canal, cámara y contenedor de salida), las variables medidas por el sistema de visión a partir de las imágenes de la fruta (diámetro e índice de color) y, por último, la variable 'peso estimado' obtenida por el cuadro de mando a partir de la relación peso-diámetro ecuatorial. Las variables cuantitativas se muestran en el Sistema Internacional de Unidades (SI).

Además, se configuraron cinco controles junto al marco donde se visualiza la base de datos con la finalidad de ofrecer la posibilidad de filtrar esta base de datos en función de las medidas obtenidas por el sistema de inspección, esto es, tres correspondientes a las variables relativas al prototipo y dos correspondientes a las variables medidas en las imágenes de la fruta. Para los parámetros relativos al prototipo (Figura 4a) se seleccionaron los controles tipo *select box* para las variables número de cámara y de canal y del tipo *radio buttons* para la variable 'contenedor de salida'. Para los parámetros relativos a las medidas de la fruta (Figura 4b) se escogieron del tipo *slider* para el ICC y del tipo *radio buttons* para la selección de la categoría (Shiny widgets gallery, 2022).

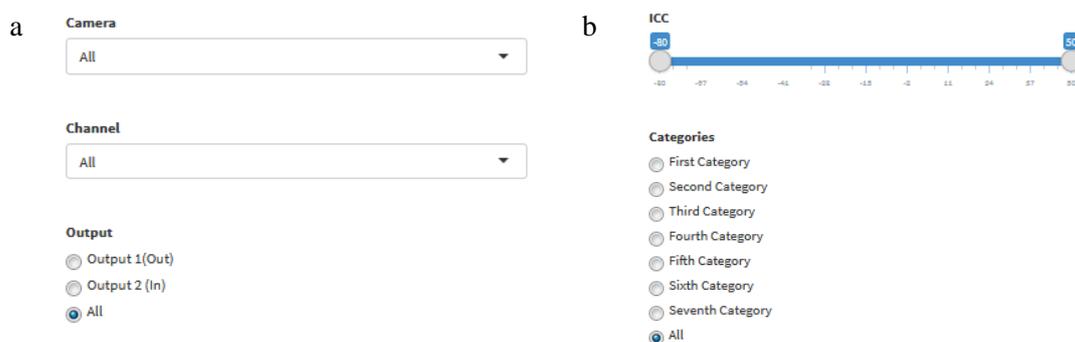


Figura 4. Controles para el filtrado de la base de datos creada por *CitrusYield*. **a)** Controles para las variables relativas al prototipo. **b)** Controles para las variables medidas en las imágenes de la fruta.

3.3.3. Mapas de producción y calidad

Para la creación de los mapas se optó por utilizar el paquete R *Leaflet* (Leaflet package for R, 2022). Esta librería de código abierto facilita la composición de mapas con superposición de formas y marcadores de manera gratuita. Se decidió georreferenciar cada fruta como un punto en un mapa orográfico, de modo que se muestren las calles de cultivo que han sido recolectadas. El

cuadro de mando se programó para que se generen tres mapas. El mapa de la variable salida, *Output Map*, muestra la fruta georreferenciada en función de las dos posibilidades (contenedor 1, contenedor 2) de la variable 'contenedor de salida'. El mapa de la variable índice de color, *Colour Map*, muestra la fruta georreferenciada en función de tres rangos que se han preestablecido para la variable 'índice de color' ((-80, -3), (-2,7), (8,50)). Por último, el mapa de la variable diámetro, *Caliber Map*, muestra la fruta georreferenciada en función de las siete categorías definidas para la variable 'diámetro'. Se trazó mediante programación que la intensidad de color informase de manera cualitativa de la cantidad de frutas con las características correspondientes georreferenciadas en cada mapa, mostrando un color suave para aquellas zonas con baja superposición de puntos. Según aumenta la superposición de puntos en el mapa se intensifica el color, lo que se traduce como mayor cantidad de fruta recolectada con dicha característica en ese punto geográfico.

Se configuró el cuadro de mando para mostrar junto a cada uno de los mapas dos tablas adyacentes donde el agricultor puede conocer la producción por calle y la producción del total recolectado (Figura 5). La tabla superior muestra la producción en kilogramos y en porcentaje, y la tabla inferior, en unidades de fruta y su porcentaje. Además, en ambas tablas esta producción se desglosa según las variables tratadas para cada mapa.

Swath	Production(Kg)/Swath	Production(%) /Swath	Production Output1(Kg)/Swath	Production Output1(%) /Swath	Production Output2(Kg)/Swath	Production Output2(%) /Swath

Swath	Number of fruits(Units)/Swath	Number of fruits(%) /Swath	Number of fruits Output1(Units)/Swath	Number of fruits Output1(%) /Swath	Number of fruits Output2(Units)/Swath	Number of fruits Output2(%) /Swath

Figura 5. Formato de las tablas para la sección Output Map.

3.3.4. Información en los gráficos interactivos

Como base para la creación de los gráficos se eligió el paquete *Plotly* para R (Plotly package for R, 2022), ya que permite generar gráficos interactivos. Se decidió que la herramienta generara diagramas de barras de la producción asociados a las variables 'contenedor de salida', 'índice de color' y 'diámetro' (Figura 6). Para cada variable se crean dos gráficos, en el primer diagrama se muestra la producción en función de la calle de cultivo y del total recolectado y en el segundo diagrama se visualiza la producción segmentada en función de los factores asociados a cada variable para cada calle de cultivo. Además, la herramienta se desarrolló de forma que permite interactuar con los gráficos, de modo que, por ejemplo, al pinchar sobre una columna del gráfico aparece una etiqueta que muestra la información cuantitativa relativa a la producción en kilogramos y unidades y su respectivo porcentaje. De esta manera, el agricultor puede visualizar la información de una manera rápida y sencilla.

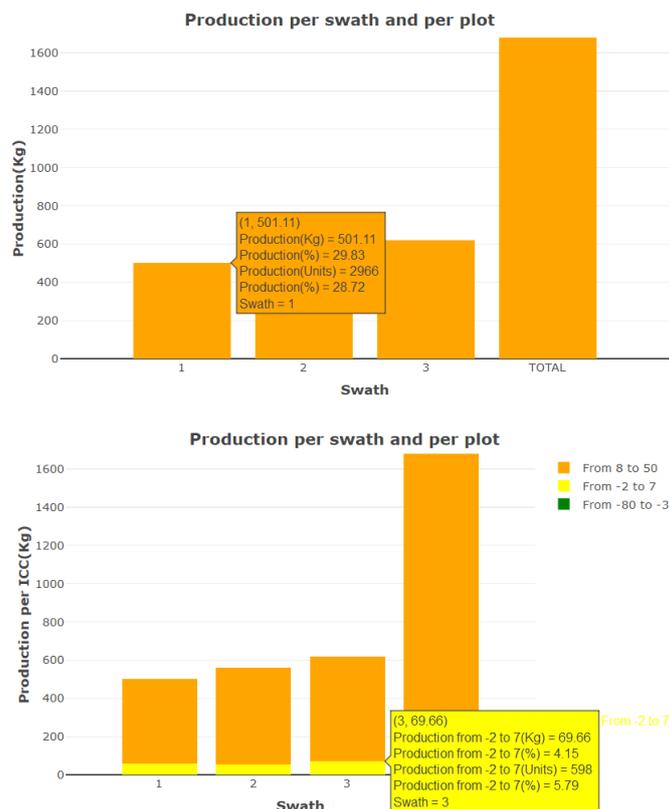


Figura 6. Ejemplo de un diagrama de barras interactivo creado por el cuadro de mando *CitrusYield* en la sección *Colour Map*.

3.3.5. Análisis exploratorio de los datos

En el cuadro de mando *CitrusYield* se configuró una sección para el desarrollo de un análisis exploratorio de los datos. Esta sección se programó para realizar un tratamiento estadístico de los datos, con su representación en diagramas de cajas y bigotes y en histogramas con curvas de densidad, además de realizar un test de normalidad para las variables cuantitativas.

Se diseñó para que la herramienta muestre un resumen estadístico donde se presenta, por un lado, una tabla en la que se reflejan las variables categóricas (calle del cultivo, cámara, canal y contenedor de salida) y cuantitativas (diámetro, índice de color y peso estimado). Para las variables categóricas se muestra su frecuencia en unidades de frutos y en porcentaje. Para las variables cuantitativas, se calculan parámetros como valor mínimo y máximo, desviación típica, rango intercuartílico y coeficiente de variación (Figura 7). Esta tabla permite sintetizar la información contenida en la base de datos espacial. Por otro lado, se programó *CitrusYield* para que calcule el número de unidades, y su porcentaje, que se han clasificado incorrectamente durante la inspección en tiempo real según la información recogida en la base de datos (Figura 8). Para ello, se programó que utilice como umbral teórico de clasificación el valor del diámetro que se introduce manualmente en el sistema de inspección para clasificar la fruta en dos categorías. Mediante este umbral se diseñó *CitrusYield* para que categorice teóricamente el contenedor en el que debería depositarse cada fruta según el diámetro medido en las imágenes. Para cada fruto, se compara el resultado teórico de clasificación con el resultado real aplicado por el sistema de visión. Esto permite saber, por ejemplo, si hubo algún posible fallo en el sistema de adquisición de la información en el prototipo durante la recolección.

Variable	Stats / Values	Freqs (% of Valid)	Valid
Swath [factor]	1. 1 2. 2 3. 3	2966 (28.7%) 3208 (31.1%) 4153 (40.2%)	10327 (100%)
Camera [factor]	1. 1 2. 2	5446 (52.7%) 4881 (47.3%)	10327 (100%)
Channel [factor]	1. 1 2. 2 3. 3 4. 4	2672 (25.9%) 2774 (26.9%) 2658 (25.7%) 2223 (21.5%)	10327 (100%)
Output [factor]	1. 1 2. 2	7929 (76.8%) 2398 (23.2%)	10327 (100%)
Mean_Major_Diameters_mm [integer]	Mean (sd) : 68.1 (6.9) min < med < max: 45 < 68 < 111 IQR (CV) : 9 (0.1)	62 distinct values	10327 (100%)
Area_mm2 [integer]	Mean (sd) : 3783.6 (833.1) min < med < max: 647 < 3777 < 6672 IQR (CV) : 1191 (0.2)	3265 distinct values	10327 (100%)
Estimated_Weight_Kg [numeric]	Mean (sd) : 0.2 (0.1) min < med < max: 0 < 0.2 < 0.5 IQR (CV) : 0.1 (0.3)	60 distinct values	10327 (100%)
Color_Index_ICC [numeric]	Mean (sd) : 12 (4.5) min < med < max: -66 < 12 < 36 IQR (CV) : 6 (0.4)	43 distinct values	10327 (100%)

Figura 7. Ejemplo de tabla contenida en la sección *Data Summary*.

```

[1] Note: Do not forget to insert the value of the major diameter that was inserted in the field in CITRUS for sorting
[1] Number of misclassified fruits by the sorting system in Output 1 (Out):
[1] 124
[1] Percentage of misclassified fruits in Output 1 (Out):
[1] 1.200736
[1] Number of misclassified fruits by the sorting system in Output 2 (In):
[1] 0
[1] Percentage of misclassified fruits in Output 2 (In):
[1] 0
[1] Number of misclassified fruits by the sorting system:
[1] 124
[1] Percentage of misclassified fruits:
[1] 1.200736

```

Figura 8. Ejemplo de texto informativo acerca de las frutas mal clasificadas por el sistema de visión.

Para la creación de los diagramas de cajas y bigotes, al igual que los diagramas de barras, se decidió usar el paquete R *Plotly* para obtener gráficos interactivos. Los primeros tres diagramas corresponden al grupo de datos de las tres variables cuantitativas. Los siguientes seis gráficos presentan, por un lado, la producción en kilogramos y, por otro lado, la producción en unidades, en función de los dos factores de la variable 'contenedor de salida', en función de los tres rangos definidos para la variable 'índice de color' y, por último, en función de las siete categorías definidas para la variable 'diámetro' (Figura 9). Al igual que para los diagramas de barras, el cuadro de mando se programó para interactuar con estos gráficos, de manera que al pinchar sobre una caja del gráfico aparece una etiqueta que muestra la información cuantitativa relativa al gráfico. De este modo, el agricultor puede visualizar las diferencias de producción entre las diferentes calles de cultivo.

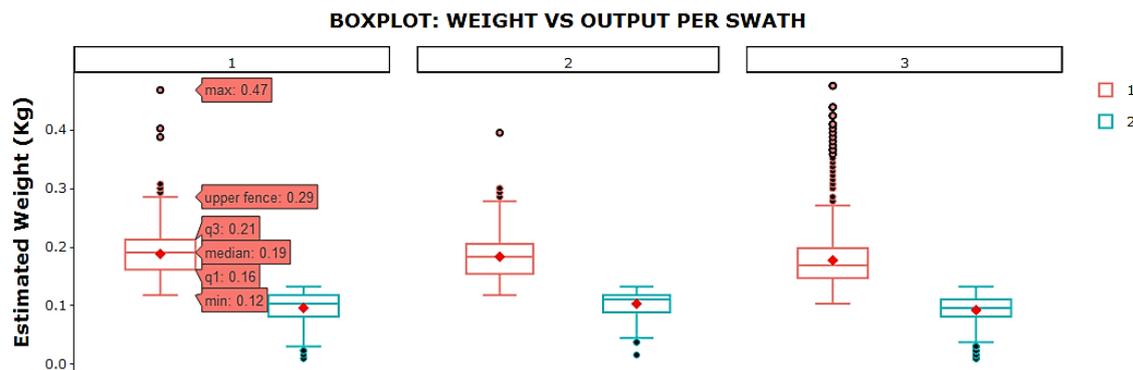


Figura 9. Ejemplo de diagramas de cajas y bigotes creados por el cuadro de mando *CitrusYield*.

El análisis de la normalidad de los datos se basó en la programación en el cuadro de mando de un test de Kolmogorov-Smirnov con la corrección Lilliefors (se asume que la media y la varianza son desconocidas para dar robustez al resultado) ya que el tamaño del conjunto de datos adquiridos durante el uso de este prototipo en campo siempre va a ser superior a 50 unidades. Este test se aplica a las variables relativas a la fruta, diámetro y color, pues son las variables obtenidas directamente de las imágenes tomadas por el sistema de inspección. Esta funcionalidad puede ser útil en un futuro para análisis estadísticos comparativos entre diferentes campañas. Junto con este test se muestra un histograma con curva de densidad (Figura 10) cuya creación se configuró utilizando el paquete R *Plotly*.

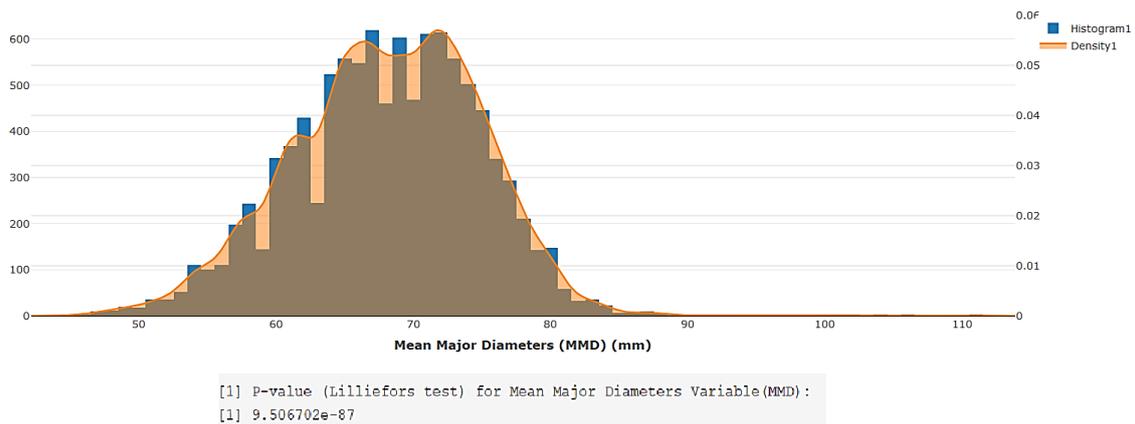


Figura 10. Ejemplo de histograma con curva de densidad para la variable 'diámetro' en *CitrusYield*.

3.3.6. Parámetros de rendimiento y eficiencia

En la herramienta también se decidió desarrollar una sección para medir parámetros de rendimiento y eficiencia de la operación. Por un lado, se eligieron los parámetros de trabajo a mostrar que fueron: el tiempo que el sistema de inspección ha estado funcionando durante la recolección (en horas y segundos), la distancia recorrida por el prototipo (en kilómetros y en metros) y su velocidad para cada calle de cultivo y para el total recolectado durante la recolección (en $\text{m}\cdot\text{s}^{-1}$ y en $\text{km}\cdot\text{h}^{-1}$).

Por otro lado, se establecieron y determinaron parámetros de rendimiento para cada calle de cultivo y para el total recolectado durante la recolección y que fueron:

- Indicador de calidad de la fruta inspeccionada (en %), que se calcula como las unidades de fruta en función de la variable 'contenedor de salida' divididas entre el total de unidades de fruta. Este indicador ayuda al agricultor a conocer la cantidad de fruta almacenada en cada contenedor, al cual se le habrá asignado previamente una calidad según el método de clasificación escogido en el prototipo. Un ejemplo de aplicación sería la clasificación de la fruta durante la recolección en función de su destino considerando la variable 'diámetro'. De este modo, se enviaría al contenedor 1 la fruta con destino mercado en fresco si cumple la normativa en cuanto a tamaño mínimo comercializable y al contenedor 2 la fruta con destino industria que no alcance el tamaño mínimo. Este indicador permite conocer cuánta fruta se envía a cada destino.
- Rendimiento del sistema de visión (en %), que se calcula como las unidades de fruta por segundo que el sistema de visión ha inspeccionado frente a las que habría podido inspeccionar a pleno rendimiento. Este factor indica el margen de procesamiento del sistema de visión frente a la cantidad de frutas recolectadas. Si el margen es muy grande puede deberse a diversos factores como el bajo número de jornaleros contratados para esta tarea, el bajo ritmo de recolección o problemas técnicos en el prototipo que impidan el correcto ascenso de frutas al sistema de visión, entre otros.
- Indicador de productividad que muestra, por un lado, la producción para cada hora de funcionamiento del sistema de inspección (en kilogramos y unidades de fruta), y, por otro lado, la producción para cada hectárea de parcela recolectada. De esta manera, el agricultor puede conocer la eficiencia del proceso de recolección.
- Capacidad de trabajo del prototipo, que se calcula como las hectáreas recolectadas por hora de funcionamiento del sistema de visión. Con este indicador se muestra al agricultor

la capacidad que tiene el prototipo de cumplir con la tarea programada en un tiempo establecido.

3.4. Diagrama de flujo

A continuación, se muestra el diagrama de flujo de la herramienta *CitrusYield* (Figura 11).

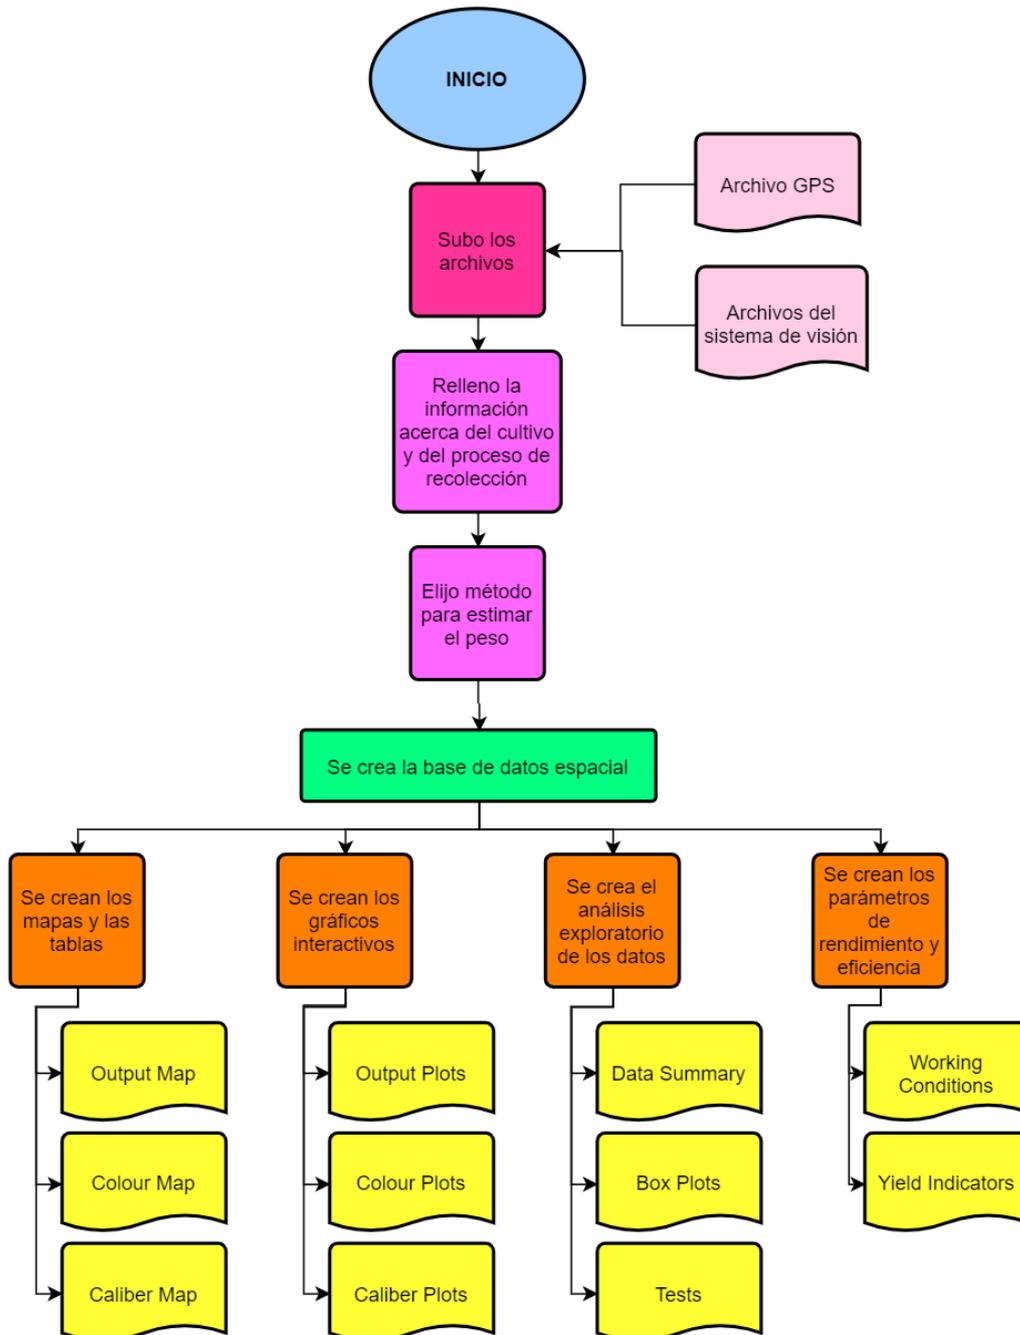


Figura 11. Diagrama de flujo de *CitrusYield*.

4. Evaluación del funcionamiento de *CitrusYield*

4.1. Materiales y métodos

4.1.1. Ensayo en campo

Se realizó un ensayo de recolección de cítricos utilizando el prototipo de plataforma móvil de asistencia a la recolección. Para el ensayo se buscó una parcela de cítricos que presentara variabilidad de producción (cantidad, tamaño y color) por lo que se seleccionó una parcela experimental con diferentes variedades de naranja situada en Moncada (Valencia, España) (WGS84 (Decker, 1984): W: 39.585186, N: -0.397901). Esta parcela tiene una distancia entre líneas de cultivo de 6 m y una distancia entre árboles dentro de una misma línea de cultivo de 4 m. Para el ensayo se recolectó un conjunto de árboles pertenecientes a tres calles contiguas. En cada calle de cultivo se recolectaron los frutos posicionados en las caras de los árboles por donde transita el prototipo. En la Figura 12 se muestra el esquema de recolección en la parcela.

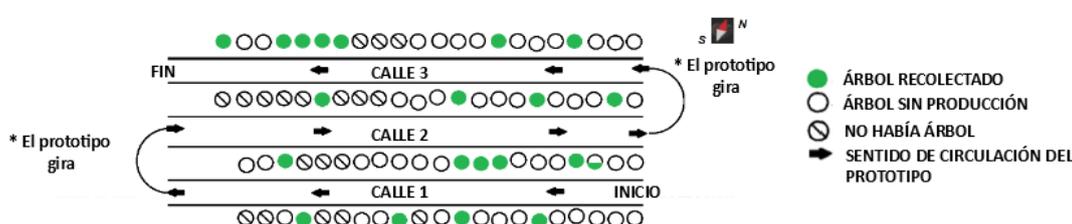


Figura 12. Esquema de la recolección en la parcela.

Previo al comienzo de la recolección, se seleccionó, en el ordenador del sistema de visión, el método para la clasificación de la fruta en dos categorías en función del tamaño de la misma. Se insertó un valor de diámetro máximo de sección ecuatorial de 64 mm. De esta manera, se consideró que aquella fruta cuyo diámetro fuera superior a 64 mm alcanzaba una alta calidad con destino el mercado en fresco, enviándose al contenedor exterior dispuesto sobre la plataforma ('Output 1'), y el resto, catalogadas de calidad inferior y, por tanto, con destino a industria, se enviaron al contenedor central ('Output 2').

Se sincronizaron la hora registrada en el GNSS y la hora reflejada en el ordenador de la centralita del sistema de visión.

Una vez finalizado el ensayo en campo, se obtuvieron e importaron al cuadro de mando *CitrusYield*, por un lado, el archivo con los datos de ubicación registrados por el GNSS y, por otro lado, los dos archivos creados por el sistema de visión del prototipo que contienen la información de cada fruta.

4.1.2. Entradas en el cuadro de mando *CitrusYield*

La información sobre el cultivo y el proceso de recolección se insertó en el cuadro de mando (Figura 13). En el parámetro fruta se seleccionó la especie naranja. No se especificó la variedad ya que se trataba de un campo experimental con diferentes variedades. Se introdujeron los valores del marco de plantación. Respecto al parámetro relativo al valor temporal en segundos para modificar la georreferenciación de la fruta se dejó el valor que ofrece el cuadro de control por defecto, '0', de manera que georreferencia la fruta en función de su momento de inspección. Las categorías en función del tamaño se establecieron según el Reglamento Delegado (UE) 2019/428 de la comisión de 12 de julio de 2018 (BOE, 2019), que se muestra en la Tabla 2.

Tabla 2. Clasificación en categorías de tamaños en función del diámetro.

Categoría	Diámetro	Calibre
Primera	81 – 99	1 – 3
Segunda	73 – 81	4 – 5
Tercera	70 – 73	6
Cuarta	67 – 70	7
Quinta	64 – 67	8
Sexta	0 – 64	-
Séptima	99 – 150	-

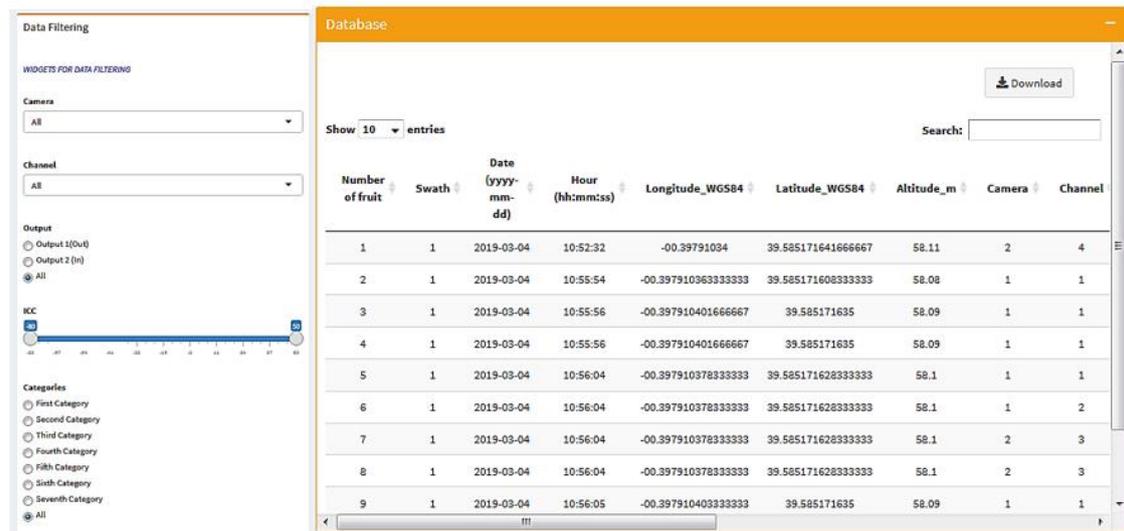
También se seleccionó el método para el cálculo de la variable 'peso estimado' utilizando la regresión insertada en *CitrusYield* para naranjas.

The screenshot shows the 'Estimated weight' configuration page in the CitrusYield software. The page is divided into two main sections: 'About harvesting' and 'Estimated weight'. Under 'About harvesting', there are several input fields: 'Fruit' (Oranges), 'Variety of the fruit' (-), 'Swath width: distance between trees of two adjacent rows (m)' (6), 'Swath length: distance between trees of the same row (m)' (4), 'Value of the diameter(mm) that was inserted in the field in CITRUS for sorting' (64), and 'Value of the shift offset in seconds' (0). Under 'Estimated weight', there are two categories defined by diameter ranges: 'First category' with a smaller diameter of 81 mm and a larger diameter of 99 mm, and 'Second category' with a smaller diameter of 73 mm and a larger diameter of 81 mm.

Figura 13. Captura de pantalla de la información rellena sobre el proceso de recolección.

4.2. Resultados y discusión

CitrusYield creó la base de datos donde se vincula en función del tiempo la información de la ubicación de cada fruta con sus propiedades externas (Figura 14).



The screenshot shows a software interface with a 'Data Filtering' sidebar on the left and a 'Database' table on the right. The table contains 9 rows of data with columns for Number of fruit, Swath, Date, Hour, Longitude, Latitude, Altitude, Camera, and Channel.

Number of fruit	Swath	Date (yyyy-mm-dd)	Hour (hh:mm:ss)	Longitude_WGS84	Latitude_WGS84	Altitude_m	Camera	Channel
1	1	2019-03-04	10:52:32	-00.39791034	39.585171641666667	58.11	2	4
2	1	2019-03-04	10:55:54	-00.397910363333333	39.585171608333333	58.08	1	1
3	1	2019-03-04	10:55:56	-00.397910401666667	39.585171635	58.09	1	1
4	1	2019-03-04	10:55:56	-00.397910401666667	39.585171635	58.09	1	1
5	1	2019-03-04	10:56:04	-00.397910378333333	39.585171628333333	58.1	1	1
6	1	2019-03-04	10:56:04	-00.397910378333333	39.585171628333333	58.1	1	2
7	1	2019-03-04	10:56:04	-00.397910378333333	39.585171628333333	58.1	2	3
8	1	2019-03-04	10:56:04	-00.397910378333333	39.585171628333333	58.1	2	3
9	1	2019-03-04	10:56:05	-00.397910403333333	39.585171635	58.09	1	1

Figura 14. Captura de pantalla de la sección donde se muestra la base de datos.

Con la información de esta base de datos, *CitrusYield* generó automáticamente los mapas de rendimiento y calidad de la fruta. Los mapas muestran un espaciamiento irregular dentro de la parcela que coincide con las características variables de las variedades y producción de la parcela experimental. En la Figura 15 se muestra el mapa *Output Map* en el que se observa un predominio del color naranja, lo que indica que la mayoría de los frutos se depositaron en el contenedor de salida 1, es decir, fueron frutos con un tamaño suficiente para el mercado de fruta fresca. En la Figura 16 se muestra el mapa *Colour Map* donde se observa que la mayor parte de la fruta tiene un ICC superior a 8, por lo que ninguna fruta necesita tratamiento de desverdizado posterior. En la Figura 17 se muestra el mapa *Caliber Map* en el que se observa que la mayoría de las naranjas tienen un tamaño entre la segunda y la quinta categoría según las categorías definidas.



Figura 15. Captura de pantalla de *Output Map*.

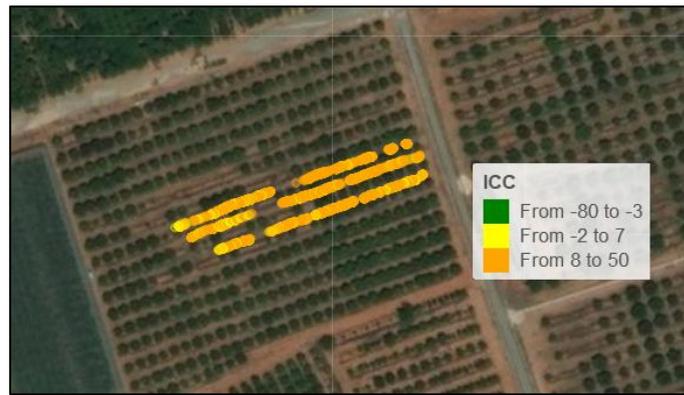


Figura 16. Captura de pantalla de *Colour Map*.

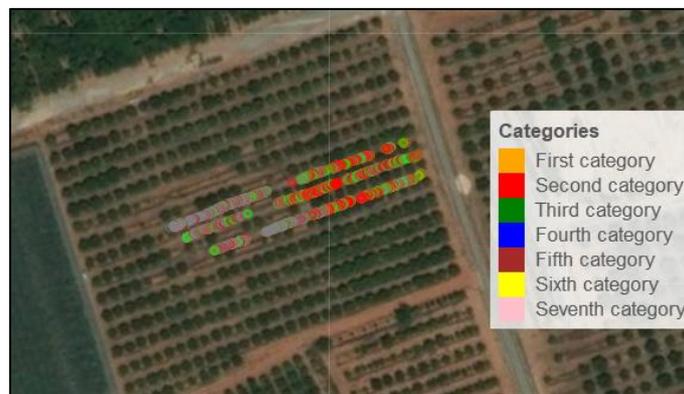


Figura 17. Captura de pantalla de *Caliber Map*.

La información descriptiva junto con los mapas se muestra a modo de ejemplo en la Figura 18 donde se presenta el diagrama de barras apiladas asociado con la variable 'salida', donde el cuadro de mando indica la información asociada con los mapas de una manera más visual. Aquí se puede ver que el porcentaje de frutas clasificadas en el contenedor de salida 2 para la calle 3 (7,64%) fue mayor que para el resto de calles. De la Figura 15 se puede deducir por el color naranja de los puntos y su intensidad que la mayor cantidad de fruta recolectada en el contenedor de salida 1 estuvo en la primera mitad de la tercera calle, mientras que toda la fruta recolectada de menor calidad se ubicó en la segunda mitad de la calle, lo que puede indicar que hubo algún problema con el cultivo en esa área. Comparando esto con el esquema de recolección de la Figura 12, se puede observar que esta zona fue la que presentó mayor cantidad de árboles con frutos recolectados y, por lo tanto, la información que se muestra en este panel de control nos permite deducir que el tamaño relativamente menor de estas naranjas en la sección final de la tercera calle depende de factores que podrían afectar a esa área específica, como el riego, los nutrientes, el estado del suelo, etc.

Por tanto, la información proporcionada permite al agricultor conocer con detalle la producción de cada calle y parcela. Se pueden ubicar aquellas áreas donde la producción es deficiente para que el agricultor pueda localizarlas en el campo y solucionar los problemas que afectan a la producción en esa zona.

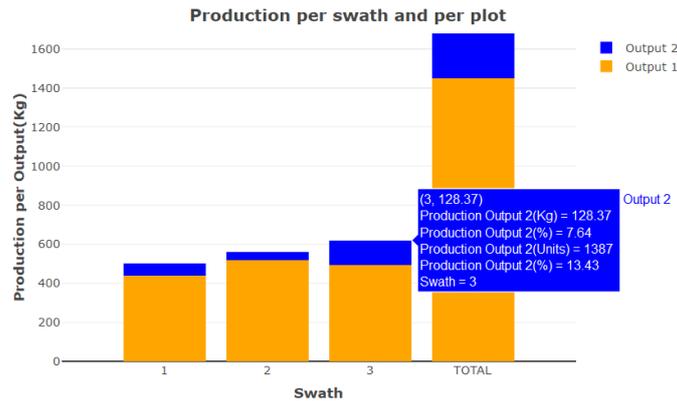


Figura 18. Captura de pantalla de uno de los gráficos de barras según la variable 'salida'.

La información de análisis estadístico se muestra en la Figura 19 donde se observan los gráficos de cajas y bigotes que proporciona la herramienta y se puede ver la variabilidad de los datos obtenidos para cada calle con respecto a la variable 'peso estimado'. La calle 3 presentó un mayor número de frutos recolectados con menor peso lo cual se refleja en el gráfico ya que la mediana (0,15 kg) y la media (0,1492 kg), fueron las más bajas de las tres. El elevado número de datos atípicos desde 0,29 kg en adelante en la calle 3 indicó que había una clara diferencia en la producción en esa calle, lo que corrobora lo descrito anteriormente. A través de esta información, el agricultor puede tener en cuenta las diferencias de producción entre las diferentes calles para el manejo posterior del cultivo.

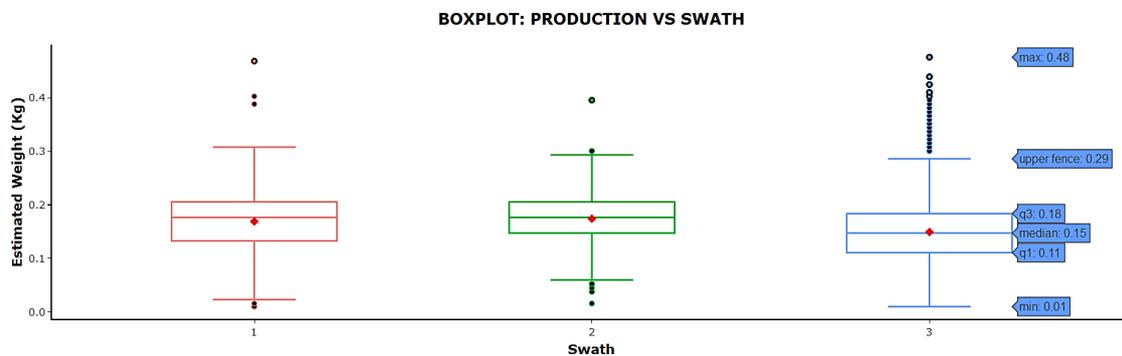


Figura 19. Captura de pantalla de uno de los gráficos de cajas creados por el cuadro de mando.

Los indicadores de calidad de la fruta clasificada se muestran en tablas (Figura 20). En total, el 76,78% de las naranjas recogidas se depositaron en el contenedor de salida 1, lo que indicó que más de las tres cuartas partes de la producción recolectada tienen esa calidad y hubo diferencias entre las calles, ya que la tercera calle tuvo el mayor porcentaje de naranjas depositadas en el contenedor de salida 2 (13,43%).

Swath	Classified fruit quality (%)	Classified fruit quality in Output 1 (%)	Classified fruit quality in Output 2 (%)
1	28.72	22.63	6.09
2	31.06	27.37	3.7
3	40.21	26.78	13.43
TOTAL	100	76.78	23.22

Figura 20. Indicador de calidad de la fruta clasificada.

Otra información importante proporcionada por el cuadro de mando es el rendimiento del proceso de inspección (Figura 21). La experiencia de campo mostró un rendimiento promedio inferior al 17% para cada una de las calles, siendo la media general del 13,8%. Esto significa que la fruta se recolectó lentamente y el sistema de visión estuvo funcionando por debajo de su capacidad. Se esperaba este resultado debido al bajo número de operarios que realizaron la recolección.

Swath	Total Time (s)	Inspected fruits (Uts)	Inspection capacity of vision system (Uts)	Vision system performance (%)
1	3125	2966	25000	11.86
2	3027	3208	24216	13.25
3	3202	4153	25616	16.21
TOTAL	9354	10327	74832	13.8

Figura 21. Rendimiento del sistema de visión.

Los indicadores de productividad obtenidos se muestran en la Figura 22, donde se observa que la calle con mayor número de naranjas recogidas por hora de operación fue la tercera ($696,42 \text{ kg}\cdot\text{h}^{-1}$). Además, se muestra la estimación del rendimiento productivo por hectárea, obteniendo una media de $12098,22 \text{ kg}\cdot\text{ha}^{-1}$ para las tres calles recolectadas.

Swath	Kg/h	Uts/h	Kg/ha	Uts/ha
1	575.99	3409.2	11723.52	69389.86
2	665.32	3819.05	11737.02	67372.31
3	696.42	4666.29	12783.28	85653.59
TOTAL	646.07	3971.92	12098.22	74377.37

Figura 22. Indicadores de productividad.

Desde una perspectiva general, el uso de *CitrusYield* facilita la obtención de información útil sobre la explotación al agricultor. *CitrusYield* presenta una serie de ventajas y novedades respecto a trabajos o aplicaciones similares anteriores. Por ejemplo, la principal diferencia entre los mapas creados por Schueller et al. (1999) o Molin et al. (2007) y los generados automáticamente por *CitrusYield* es la forma de obtener la información en campo y la automatización del procesamiento de los datos. El uso de las máquinas asistentes de recolección con sensores permite la extracción de los parámetros de calidad de la fruta durante el proceso de recolección, y con el uso de este cuadro de mando se obtiene automáticamente información útil sin necesidad de conocimientos informáticos. A diferencia del resto de software SIG comercial y no comercial, *CitrusYield* tiene la capacidad de calcular la producción, clasificar las frutas por categorías en función de su calidad, georreferenciar la información categorizada en mapas y realizar análisis estadísticos automáticamente para cada calle y para la parcela, mostrando los datos mediante gráficos y estadísticas. Esto facilita la comparación intracultivo y en diferentes campañas. La principal ventaja de conocer las diferencias de la producción entre las calles y las áreas dentro del cultivo es proporcionar al productor información para tomar decisiones precisas para un manejo de cultivo localizado.

El programa *Crop Auditor* desarrollado por Ampatzidis et al. (2016), por ejemplo, no permite saber qué cantidad de esa fruta recolectada cumple con los requisitos para el consumo en fresco, ya que la producción no se clasifica durante la recolección. Tampoco realiza georreferenciación en mapas orográficos, lo que dificulta al agricultor visualizar la información capturada

gráficamente en el mapa, ni realiza un análisis estadístico de los datos para encontrar diferencias entre la producción de las diferentes calles o áreas de la parcela, mientras que *CitrusYield* con la generación automática de mapas, tablas y gráficos con la información del cultivo permite al productor conocer el rendimiento espacial de manera visual.

5. Conclusiones

El funcionamiento de la herramienta *CitrusYield* se evaluó a partir de los datos obtenidos durante un ensayo de recolección en una parcela experimental de cítricos con la plataforma móvil de asistencia a la recolección. El cuadro de mando *CitrusYield* analizó los datos y generó los diferentes tipos de mapas georreferenciando la información de la fruta con su punto de recolección. La heterogeneidad de la producción a nivel intraparcelar quedó reflejada en los mapas, concordando la información mostrada con las características variables de las variedades cultivadas en la parcela experimental. En las tablas y gráficos se observaron las diferencias de producción entre diversas zonas dentro del cultivo. Por último, los indicadores de calidad, rendimiento del sistema de inspección por visión artificial y la productividad calculados por *CitrusYield* revelaron el nivel de efectividad y eficiencia del proceso de recolección con la asistencia del prototipo.

Tras los resultados obtenidos, *CitrusYield* evidenció un gran potencial como herramienta para la agroindustria capaz de automatizar procesos de manera eficaz y práctica. La información visual de este cuadro de mando de fácil manejo proporcionó información precisa del rendimiento espacial del cultivo, aumentando la eficiencia en la gestión del campo y la trazabilidad de la fruta. Además, la configuración de *CitrusYield* permite adaptar el software del cuadro de mando para incluir el procesamiento y tratamiento de la información de futuros parámetros de calidad proporcionados por los sensores como, por ejemplo, defectos o podredumbres detectados en la fruta. También se puede configurar para adaptar esta herramienta a todo el espectro de cítricos.



Capítulo V

**Detección automática de
daños causados por la
plaga *Tetranychus urticae*
en hojas de cítricos**

CAPÍTULO V - DETECCIÓN AUTOMÁTICA DE *TETRANYCHUS URTICAE* KOCH EN HOJAS DE CÍTRICOS MEDIANTE IMÁGENES EN COLOR E IMÁGENES HIPERESPECTRALES VIS/NIR

Resumen

Tetranychus urticae Koch es una de las plagas más importantes de los cítricos que produce manchas cloróticas en las hojas y cicatrices en los frutos de los árboles afectados. Su presencia y monitoreo en las parcelas se realiza mediante inspección visual de las hojas siendo una operación laboriosa y costosa. El objetivo de este trabajo es estudiar el potencial de las técnicas de imagen en color e hiperespectral, en condiciones de laboratorio, para detectar el daño causado por esta plaga de forma rápida y automática. Asimismo, se evalúa también la capacidad de estas técnicas para discriminar los daños causados por esta plaga de otros, como los producidos por *Phyllocnistis citrella*, y de problemas foliares debidos a deficiencias nutricionales. En el ensayo se adquirieron imágenes con una cámara a color y una hiperespectral en el rango de 450–1000 nm del haz y el envés de hojas sanas, hojas sintomáticas por *T. urticae*, hojas con daños causados por *P. citrella* y hojas con deficiencias nutricionales. Los datos obtenidos de las imágenes en color se analizaron mediante análisis discriminante clasificando los píxeles como pertenecientes a hojas dañadas o sanas. Con la finalidad de identificar propiedades discriminatorias entre daños por *T. urticae* y otros daños cuyo color es similar, pero que tienen una apariencia y un patrón diferente, se consideraron algunas propiedades geométricas de los daños. Los datos obtenidos de las imágenes hiperespectrales se analizaron mediante PLS-DA. La tasa de detección del daño causado por *T. urticae* con imágenes en color alcanzó el 92,5%, mientras que las hojas que no presentaron daño fueron todas correctamente identificadas. Otros problemas como el daño por *P. citrella* también se discriminaron correctamente de *T. urticae*. Además, las imágenes hiperespectrales permitieron discriminar el daño causado por *T. urticae* de las hojas sanas y distinguir entre hojas jóvenes y adultas, lo que indica si se trata de una infestación reciente o más antigua. Además, se obtuvieron buenos resultados en la discriminación entre daños causados por *T. urticae*, *P. citrella* y deficiencias nutricionales.

1. Introducción

España es el sexto productor mundial de cítricos y el primer exportador de fruta para el mercado en fresco (FAO, 2021). Esto hace que la calidad externa de las frutas sea un factor clave en la decisión de compra, por lo que las plagas que causan daño directo a estas frutas son de crucial importancia (Hare, 1994; Jacas y Urbaneja, 2010). *Tetranychus urticae* Koch (Ácaro: *Tetranychidae*), también llamada araña roja, es una de las plagas económicamente más importantes en una amplia gama de cultivos protegidos y al aire libre en todo el mundo (Van Leeuwen, 2010). En España, *T. urticae* es una plaga clave de los cítricos (Martínez-Ferrer et al., 2006; Aucejo et al., 2003; Ansaloni et al., 2008) y afecta especialmente a los árboles de mandarina clementina (Fenollosa et al., 2011; Aucejo-Romero et al., 2004; Pascual-Ruiz et al., 2013), que son susceptibles a los brotes de este ácaro (Urbaneja et al., 2008).

En verano, en zonas mediterráneas, las colonias de *T. urticae* se ubican principalmente en el envés de las hojas jóvenes de los cítricos, donde tejen los hilos de seda. El ácaro se alimenta del contenido de las células epidérmicas y del parénquima (Fonte et al., 2019). Como resultado, provocan decoloración y desecación en las hojas, que en la mayoría de los casos se manifiesta con manchas cloróticas (amarillentas en las hojas jóvenes de la misma campaña que pasan a

pardas-marrones en las hojas adultas en las campañas siguientes) en el haz de las hojas (Soler-Salcedo et al., 2006; Urbaneja et al., 2022). Los frutos también se ven afectados presentando manchas marrones rojizas, similares al óxido, que se pueden llegar a extender por toda la superficie de la fruta (Aucejo et al., 2003). Estas lesiones dan lugar a pérdidas de la calidad de las frutas, lo que reduce drásticamente los precios en el mercado de productos frescos (Jeppson et al., 1975; Chueca et al., 2010).

Actualmente, la gestión integrada de plagas en la producción agraria es de obligado cumplimiento (BOE, 2012). Bajo esta estrategia, la decisión de los tratamientos fitosanitarios para el control de plagas ya no se realiza en función de un calendario a fechas determinadas sino en función de la incidencia de plaga. Por ello, los productores deben realizar un seguimiento de las mismas. En el caso de la araña roja, las guías GIP recomiendan realizar muestreos entre julio y septiembre con frecuencias semanales o quincenales dependiendo de la incidencia de la plaga (Pascual-Ruiz et al., 2013; Urbaneja et al., 2022). Los muestreos se realizan manualmente y se basan en colocar dos aros de 56 cm de diámetro sobre la copa del árbol y contar el número de aros con más de dos hojas jóvenes sintomáticas (manchas amarillentas). Al mismo tiempo, se muestrean cuatro árboles sintomáticos y se determina el número de hojas ocupadas por araña roja. Se recomienda muestrear 20 árboles por hectárea. Este método hace que los monitoreos sean una tarea cara, que requiere mucho tiempo y trabajo.

La teledetección es una alternativa eficaz en el control de plagas (Rey et al., 2019; Cubero et al., 2020). Por ejemplo, el uso de sensores ópticos de proximidad tiene ventajas sobre los métodos manuales porque permite evaluar el estado vegetativo de forma objetiva y rápida, además de ser una técnica no invasiva y no destructiva. Los sensores ópticos miden la energía electromagnética reflejada, absorbida o transmitida por la vegetación (firma espectral) en diferentes longitudes de onda. Esta energía, y por lo tanto la firma espectral, está directamente relacionada con su estado vegetativo y se ve afectada en momentos de estrés, ataques de plagas o deficiencias nutricionales.

En la bibliografía existen estudios en cultivos no cítricos para la detección de *T. urticae* mediante espectrómetro. Martin y Latheef (2017) utilizaron un sensor óptico multiespectral como herramienta de detección para evaluar el daño foliar causado por esta plaga en el algodón cultivado en invernadero. Distinguieron varios niveles de infestación al comienzo de la temporada. Herrmann et al. (2012) hicieron uso de imágenes multiespectrales de hojas de pimiento en invernadero para calcular los índices de vegetación, lo que permitió la detección temprana de los daños causados por esta plaga. En hojas de fresa en laboratorio, Fraulo et al. (2009) emplearon espectroscopía de reflectancia difusa en los rangos visible e infrarrojo cercano del espectro para identificar regiones espectrales alteradas por la presencia de *T. urticae*. Crockett et al. (2014) utilizaron espectroscopía e imágenes del espectro VNIR en hojas de diferentes cultivos de fresa para caracterizar los patrones de reflectancia del daño, lo que reveló la existencia de diferencias de susceptibilidad según la variedad. Nieuwenhuizen et al. (2020) estudiaron las imágenes obtenidas por una cámara de color y tres cámaras multiespectrales para detectar el daño de la araña roja en hojas de tomate de invernadero; los resultados mostraron bandas espectrales discriminantes entre hojas sanas y dañadas. Además, Uygun et al. (2020) desarrollaron una innovadora técnica de procesamiento de imágenes para determinar el nivel de daño en las plantas de pepino de invernadero infectadas por esta plaga.

Existen otras plagas que también alteran la apariencia de la hoja y causan lesiones diversas. La larva de *Phyllocnistis citrella* Stainton (Lepidóptero: *Gracillariidae*) se alimenta de la hoja en el área entre el parénquima y la cutícula. Traza una galería sinuosa la cual aumenta de tamaño a medida que crece la larva. La cutícula de las hojas afectadas se quiebra, provocando la pérdida de agua en las células y, en consecuencia, las espirales de las hojas se secan y se rompen (Urbaneja et al., 2022). Por otra parte, las deficiencias nutricionales de los cítricos, cuando son graves, también se manifiestan en síntomas en las hojas que se pueden reconocer visualmente (Quiñones

et al., 2012) y que, en algunos casos, pueden ser similares a las manchas cloróticas causadas por *T. urticae*. La deficiencia de nitrógeno ocurre primero en las hojas adultas y causa un amarilleo significativo en las venas. Por el contrario, la deficiencia de hierro se presenta más en hojas jóvenes y produce una pérdida en el color verde que evoluciona hacia tonalidades que van desde el verde claro al amarillo pálido, dependiendo de la intensidad de la afección. Sin embargo, las nervaduras de las hojas permanecen característicamente de color verde oscuro y aparecen marcadas sobre un fondo más claro, asemejándose a una retícula (Futch y Tucker, 2022). La deficiencia de Mn provoca clorosis en el tejido intervenal de las hojas, pero las venas permanecen de color verde oscuro. A veces, esta deficiencia se puede confundir con la deficiencia de Fe y Zn. Las hojas jóvenes suelen mostrar un patrón reticulado sobre un fondo verde más claro que es menos marcado que en las deficiencias de Zn o Fe. El patrón se convierte en una banda verde a lo largo de la nervadura central y las principales nervaduras laterales en las hojas adultas, con áreas de color verde claro entre éstas (Zekri y Obreza, 2022).

Entre los sensores ópticos, las cámaras en color se presentan como un método económico y asequible para la adquisición de imágenes dentro del rango VIS, capturando las mediciones de las bandas correspondientes al RGB. Por otro lado, las cámaras hiperespectrales, con un coste superior a las cámaras en color, son capaces de obtener mediciones a lo largo de todo el espectro electromagnético. Con motivo de esta amplitud de espectro, las imágenes hiperespectrales se encuentran dentro de las tecnologías más empleadas en la investigación para adquirir estas mediciones (Landgrebe, 2002). Una vez obtenida la firma espectral, uno de los problemas que presenta esta tecnología es la redundancia de datos. Las imágenes hiperespectrales generan una cantidad masiva de datos redundantes y correlacionados que deben ser procesados (Rivera et al., 2014). Este hecho puede dar lugar a problemas de multicolinealidad y sobreajuste cuando se utiliza la regresión multivariante convencional para el modelado empírico (Kumar, 1975; Hawkins, 2004). Para manejar esta cantidad tan grande de datos y extraer información útil, se necesitan métodos estadísticos computacionales. Estos métodos conectan las variables originales con la información espectral esencial para clasificar y/o cuantificar características importantes (Amigo et al., 2013; Lorente et al., 2012). La regresión de mínimos cuadrados parciales es uno de los métodos más usados para construir modelos predictivos. Se utiliza comúnmente en imágenes hiperespectrales para extraer y resumir la información espectral, reducir la alta dimensionalidad de los datos obtenidos y abordar el problema de la multicolinealidad (Vinzi et al., 2010). El análisis discriminante PLS es una variante de la regresión PLS en la que la variable independiente es categórica y expresa la pertenencia a clases de las muestras. Se realiza para resaltar la separación entre grupos maximizando la covarianza entre los espectros y la variable independiente, de modo que se obtenga una separación máxima entre clases.

2. Objetivos

El objetivo principal de este trabajo fue la investigación del potencial de las imágenes en color e hiperespectrales como una herramienta práctica para:

1. Detección de la presencia de daños causados por la plaga *T. urticae* en hojas de mandarina.
2. Detección de la antigüedad de dicho daño con el fin de conocer si se trata de una infestación reciente causada por una plaga activa o de un daño antiguo causado por la plaga en campañas previas.
3. Discriminación de este daño de otros similares causados por la plaga *P. citrella* y por deficiencias nutricionales.

3. Materiales y métodos

3.1. Muestras de hojas

Se recolectaron un total de 142 hojas de mandarina 'Clemenules' de dos huertos comerciales ubicados en El Puig de Santa María y Chiva (Valencia, España). Tras la recolección de las hojas, éstas se almacenaron en una cámara frigorífica a 5°C. La selección de las hojas se estableció tal y como viene indicado en la Tabla 1.

Por un lado, para evaluar la capacidad de los sistemas de detectar la presencia de daño causado por esta plaga en las hojas se cogieron 60 hojas con daño visible causado por *T. urticae* y 60 hojas sin síntomas externos de daño alguno. Dado que el daño reciente ocurre típicamente en hojas jóvenes (Urbaneja et al., 2022), para determinar si correspondía a un daño producido por una plaga activa o antigua, la mitad de las hojas seleccionadas, con daño o sin él, eran hojas jóvenes, mientras que la otra mitad eran hojas adultas.

Por otro lado, para probar la capacidad de estos métodos de discriminar entre *T. urticae* y otros problemas se recolectaron 22 hojas, de las cuales, 10 estaban afectadas por *P. citrella* y las 12 hojas restantes estaban afectadas por diversas deficiencias nutricionales, cuyo aspecto era compatible con deficiencia de N (6 hojas) y deficiencias de Fe, Mn o Zn (6 hojas) (Tagliavini y Quiñones, 2012). La Figura 1 presenta imágenes de las muestras de hojas por ambos lados para cada subconjunto.

Por último, se seleccionaron otras 20 hojas más, 10 con presencia de daño por *T. urticae* y 10 con diversas deficiencias, que se usaron como conjunto de entrenamiento del algoritmo desarrollado para analizar las hojas mediante imágenes de color.

Tabla 1. Clasificación de los conjuntos y subconjuntos de las hojas para su análisis.

Conjunto	Subconjunto	Número de hojas	Síntoma	Antigüedad
G1	G1.1	30	Sana	Joven
	G1.2	30	Sana	Adulta
G2	G2.1	30	<i>Tetranychus urticae</i>	Joven
	G2.2	30	<i>Tetranychus urticae</i>	Madura
G3	G3.1	10	<i>Phyllocnistis citrella</i>	Joven y adulta
G4	G4.1	6	Deficiencia N	Joven y adulta
	G4.2	6	Deficiencia Fe, Mn o Zn	Joven y adulta

	G1.1	G1.2	G2.1	G2.2	G3.1	G4.1	G4.2
	Hojas jóvenes y sanas	Hojas adultas y sanas	Hojas jóvenes y sintomáticas con <i>Tetranychus urticae</i>	Hojas adultas y sintomáticas con <i>Tetranychus urticae</i>	Hojas sintomáticas con <i>Phyllocnistis citrella</i>	Hojas sintomáticas con deficiencia de N	Hojas sintomáticas con deficiencia de Fe, Mn o Zn
HAZ							
ENVÉS							

Figura 1. Imágenes de las hojas (haz y envés de la hoja) para cada subconjunto.

3.2. Detección de daños causados por *T. Urticae* mediante imágenes en color

3.2.1. Adquisición y segmentación de imágenes en color

Las imágenes en color se capturaron con una resolución de 0,03 mm·píxel⁻¹ utilizando una cámara digital (EOS 700D, Canon Inc, Tokio, Japón) colocada dentro de un habitáculo de inspección con forma cuadrada que incluía un sistema de iluminación uniforme y calibrado, compuesto por ocho tubos fluorescentes (BIOLUX 18W/965, 6500 K, Osram GmbH, Alemania). El ángulo entre el eje de la lente y las fuentes de iluminación era de aproximadamente 45° (Diago et al., 2014), y se utilizó la polarización cruzada (Elmasry et al., 2012) para evitar brillos en las hojas y reflejos directos hacia la cámara. Las imágenes se capturaron al día siguiente de la recolección de las hojas y las muestras se mantuvieron a temperatura ambiente (22-25°C) durante 30 min antes de adquirir las imágenes. Se fotografió tanto el haz como el envés de las hojas sobre un fondo blanco uniforme.

Las imágenes se procesaron utilizando el software FoodColor-Inspector v4.0 desarrollado en el IVIA (COFILAB, 2022). El procesamiento consistió en un primer paso de segmentación de las imágenes basada en características del color. Sin embargo, el daño causado por *T. urticae* y los cambios de color en la hoja causados por las deficiencias nutricionales no se pueden diferenciar utilizando únicamente el color en la segmentación. Por esa razón, se realizó un segundo paso para clasificar las hojas según algunas características geométricas de los objetos encontrados en el proceso, ya que los dos tipos de problemas tienen un aspecto muy diferente. Por otra parte, utilizando solo información de las imágenes en color, es difícil determinar si el daño causado por *T. urticae* es reciente o antiguo, ya que no existen diferencias evidentes de color, por lo que se decidió unir los conjuntos G2.1 y G2.2 y formar el grupo G2 dada la imposibilidad de diferenciarlos.

En la segmentación basada en el color, se predefinieron cuatro clases de la siguiente manera: fondo, clase verde (que se corresponde con la parte sana de la hoja), clase amarilla (que se corresponde con las manchas cloróticas causadas por *T. urticae* o con las manchas causadas por las deficiencias nutricionales) y clase marrón (que se corresponde con las manchas causadas por *P. citrella*). Antes de la segmentación, fue necesario un entrenamiento supervisado. Para ello, se utilizó el conjunto de 20 hojas extras indicado en el muestreo, que era diferente a los descritos en la Tabla 1. El entrenamiento consistió en la selección manual de regiones de interés representativas de las clases predefinidas en las 20 hojas del conjunto de entrenamiento utilizadas para tal fin. Los valores RGB de los píxeles de cada región se almacenaron junto con la clase a la que pertenecían. Estos valores se utilizaron posteriormente como entrada para construir un análisis discriminante lineal bayesiano (Blasco et al., 2009b). Este tipo de LDA se basa en el teorema de Bayes que se muestra en la Ecuación (1):

$$P(x|w_i) = \frac{p(x|w_i)P(w_i)}{\sum_{j=1}^m p(x|w_j)P(w_j)}, \quad i=1, \dots, m \quad (1)$$

donde x era el vector observado tridimensional (en nuestro caso, los valores RGB promedio de un objeto), w_i ($i = 1, \dots, m$) era una de las m clases diferentes, m era el número de clases, $P(x|w_i)$ era la probabilidad de que la x observada perteneciera a la clase w_i , $P(w_i)$ era la probabilidad a priori de que un objeto perteneciera a la clase w_i (se consideró que esta probabilidad era la misma para cada clase) y $p(x|w_i)$ fue la función de densidad condicional de los valores RGB en la clase w_i .

Para cada píxel de la imagen se estimó la probabilidad de pertenecer a cada clase, asignando el píxel a la clase con mayor probabilidad. Los píxeles contiguos pertenecientes a la misma clase, se unieron para formar los objetos de la imagen.

3.2.2. Definición de los parámetros de discriminación

Como se ha mencionado, el color del daño causado por las deficiencias y por *T. urticae* es similar. Por lo tanto, el proceso de segmentación no pudo separarlos en diferentes clases. Sin embargo, la apariencia y el patrón geométrico del daño eran completamente diferentes. Por estos motivos, se tomó la decisión de analizar algunas propiedades geométricas de los objetos inicialmente clasificados como *T. urticae* (González-González et al., 2021). En el análisis, se hizo una distinción entre estos objetos de hojas dañadas por *T. urticae* y hojas dañadas por deficiencias. El propósito de este análisis fue determinar las propiedades discriminatorias para identificar el daño de *T. urticae*, no la detección o identificación de deficiencias. Teniendo en cuenta que los daños causados por *T. urticae* generalmente se detectan como objetos de forma aproximadamente redonda, las propiedades geométricas consideradas para el análisis fueron (Blasco et al., 2009a):

- El número de áreas dañadas detectadas por hoja.
- El área total dañada (mm²) de la hoja, como la suma de las áreas de todos los objetos encontrados.
- El área (A), redondez (R), compacidad (C), perímetro (P) y alargamiento (E) de cada objeto encontrado en la hoja.

Para conocer si existían diferencias significativas entre las propiedades correspondientes al daño realmente causado por *T. urticae* y al producido por las deficiencias nutricionales se realizó un ANOVA para cada una de estas propiedades geométricas. El nivel de confianza utilizado para los análisis fue del 95%. Se realizaron utilizando el software Statgraphics Centurion XVI (Statgraphics Technologies, Inc., The Plains, Virginia, EE. UU.). Las propiedades

discriminatorias se incluyeron en el algoritmo de discriminación para separar entre *T. urticae* y deficiencias.

3.3. Detección de daños causados por *T. Urticae* mediante imágenes hiperespectrales

3.3.1. Adquisición de imágenes hiperespectrales

El sistema de adquisición de imágenes hiperespectrales estaba compuesto por una cámara (CoolSNAP ES, Photometrics, Tucson, AZ, EE.UU.) y dos filtros sintonizables de cristal líquido (Varispec VIS-07 y NIR-07, Cambridge Research & Instrumentation, Inc., Hopkinton, MA, EE.UU.) que permitieron capturar las imágenes en el rango espectral de 450 a 1000 nm. La cámara se configuró para adquirir imágenes con un tamaño de 1392×1040 píxeles y una resolución espacial de 0,14 mm·píxel⁻¹. Se adquirieron un total de 56 imágenes monocromas para cada lado de la hoja en intervalos de 10 nm. Para optimizar el rango dinámico de la cámara, evitar imágenes saturadas y corregir la sensibilidad espectral de los diferentes elementos del sistema, se realizó una calibración del tiempo de integración para cada banda. Esto consistió en establecer el tiempo de integración individual para cada banda requerido con la finalidad de obtener el 90% de la reflectancia de una referencia de blanco (Spectralon 99%, Labsphere, Inc, NH, EE.UU.).

La escena se iluminó con doce lámparas halógenas (37 W) (Eurostar IR Halogen MR16, Ushio America, Inc., CA, EE.UU.) alimentadas con corriente continua (12 V). Las lámparas se dispusieron equidistantes entre sí dentro de un difusor de aluminio hemisférico para iluminar las muestras de hojas de forma indirecta. Se adquirieron dos imágenes por hoja (haz y envés) en modo de reflectancia utilizando un software desarrollado en el IVIA (Figura 2). La reflectancia capturada se corrigió para obtener la reflectancia relativa usando una referencia oscura y otra blanca a través de la Ecuación (2) (Gat, 2000):

$$\rho_{xy}(x, y, \lambda) = \frac{R^{abs}}{R_{white}^{abs}} = \rho^{Ref}(\lambda) \frac{R(x,y,\lambda) - R_{black}(x,y,\lambda)}{R_{white}(x,y,\lambda) - R_{black}(x,y,\lambda)} \quad (2)$$

donde $\rho^{Ref}(\lambda)$ es la reflectancia estándar del blanco de referencia blanco (99% en este trabajo), $R(x, y, \lambda)$ es la reflectancia de la hoja capturada por el sensor CCD de la cámara en el píxel ubicado en (x,y), $R_{white}(x, y, \lambda)$ es la reflectancia capturada por el CCD del objetivo de referencia blanco, y $R_{black}(x, y, \lambda)$ es la reflectancia capturada por el CCD mientras se evita cualquier fuente de luz para poder cuantificar el ruido electrónico del CCD.



Figura 2. Imágenes, hiperespectral capturada a 650 nm y en color, de los dos lados de una hoja afectada por *T. urticae*.

De este modo se obtuvo una base de datos etiquetada de 204 imágenes hiperespectrales (Tabla 2). Se seleccionaron tres ROI con un tamaño de 10×10 píxeles para cada lado de la hoja para el caso de hojas sanas (G1), las hojas con *P. citrella* (G3) y las hojas con deficiencias (G4). En las hojas afectadas por *T. urticae* (G2), se seleccionaron tres ROI del área dañada y otros tres del área asintomática para cada lado de la hoja. Por consiguiente, se obtuvo un total de 972 ROI de ambos lados. Estas ROI se consideraron como las muestras para el posterior análisis. Se extrajo el espectro de reflectancia promedio de todos los píxeles en cada ROI y se organizó en una tabla con 56 columnas correspondientes al valor de reflectancia de cada banda (variables X) más otra columna con la clase a la que pertenecen (variable Y).

Tabla 2. Clasificación de la base de datos etiquetada para análisis.

Subconjunto	Número de hojas	Número de imágenes hiperespectrales (ambos lados de la hoja)	Número total de ROI
G1.1	10	20	60
G1.2	10	20	60
G2.1	30	60	360
G2.2	30	60	360
G3.1	10	20	60
G4.1	6	12	36
G4.2	6	12	36
TOTAL	102	204	972

3.3.2. Análisis de datos multivariados

Se llevaron a cabo tres experimentos. El primero se realizó con el fin de conocer la capacidad de un modelo para discriminar entre áreas sanas y dañadas por *T. urticae*. Para este ensayo, se utilizaron los conjuntos G1 y G2. El objetivo del segundo experimento fue evaluar la capacidad del modelo para discriminar entre daños recientes y antiguos y, por lo tanto, se incluyeron los subconjuntos G2.1 y G2.2. El tercer experimento exploró la capacidad del modelo para discriminar entre el daño de *T. urticae* y el daño causado por otros problemas en las hojas. En este último caso, se utilizaron todos los conjuntos para construir los modelos.

El análisis multivariante se realizó utilizando PLS-DA. En el PLS-DA, las variables independientes (X) fueron el espectro de cada muestra, mientras que la variable dependiente Y fue una variable categórica que representa a cada clase (Brereton, 2007). Por ende, se asignó un valor numérico a la variable Y que representa la clase. En el primer experimento, para detectar el daño causado por *T. urticae*, se estableció un valor de 0 para las hojas dañadas y 1 para las sanas. En el segundo experimento, que se realizó para diferenciar entre hojas con daños recientes de *T. urticae* y hojas con daños antiguos de *T. urticae*, se asignó un valor de 0 para las hojas jóvenes y un valor de 1 para las hojas adultas. Finalmente, en el tercer experimento, destinado a discriminar entre todos los diferentes tipos de daño, los valores de respuesta se establecieron como 1, 2, 3, 4 y 5 para G1, G2, G4.1, G4.2 y G3, respectivamente.

En este trabajo, el método utilizado para reducir la enorme cantidad de datos redundantes y correlacionados capturados por los sistemas hiperespectrales (Lorente et al., 2012) y para seleccionar las longitudes de onda óptimas, fue el análisis del vector de los coeficientes de regresión. Este método mide la asociación entre cada variable y la respuesta y selecciona las variables en dos pasos: (i) el modelo PLS se ajusta a los datos, y (ii) la selección de variables se basa en un umbral (Mehmood et al., 2012). Las variables con un valor absoluto alto pueden seleccionarse porque hacen la mayor contribución a la clasificación, y las que tienen un valor absoluto pequeño pueden ignorarse (Munera et al., 2018). En este caso, los coeficientes de regresión se obtuvieron a partir de los modelos PLS.

En todos los casos, el 70% de las muestras se utilizaron para entrenar y validar el modelo mediante validación cruzada. El 30% restante de las muestras se utilizó como un conjunto de prueba independiente o predicción. Los resultados mostrados se dan para el conjunto de prueba.

Los espectros de entrada para los modelos PLS-DA se normalizaron utilizando el centrado medio (Rinnan et al., 2009). También se utilizó una validación cruzada de $k=10$ para elegir el número óptimo de variables latentes (LV, en inglés) y así obtener una estimación de la tasa de error de los modelos PLS (Hastie et al., 2001). Por lo general, las primeras variables latentes explican la mayor parte de la varianza en las variables dependientes, de modo que las variables dependientes pueden modelarse mediante un número reducido de variables latentes. En un modelo PLS, el poder explicativo del modelo aumenta a medida que aumenta el número de factores o variables PLS. Sin embargo, la precisión de la predicción del modelo puede disminuir con un aumento en la complejidad del modelo (Kuhn y Johnson, 2013). El software utilizado para construir estos modelos PLS fue The Unscrambler X 10.4 (CAMO Software, Oslo, Noruega).

3.3.3. Evaluación de la eficacia del modelo

Cuando se utiliza un método de regresión para construir un modelo de clasificación, uno de los parámetros más importantes a definir es el valor de corte, es decir, el intervalo de aceptación en el que una nueva muestra se considera correctamente clasificada en la clase. Al igual que en Cortes et al. (2017) y en Chen et al. (2008), el valor de corte de PLS-DA para la discriminación de muestras en función de la presencia de daño causado por *T. urticae* se fijó en 0,5. Si el valor previsto de una muestra era inferior a 0,5, la muestra se clasificaba como dañada; de lo contrario, se consideraba sana. Asimismo, en el segundo experimento para discriminar la antigüedad del daño, se consideraron hojas jóvenes aquellas con un valor pronosticado de 0,5, mientras que aquellas con valores más altos se consideraron hojas adultas y, por ende, daños antiguos. El tercer experimento contenía un mayor número de clases y, por lo tanto, se establecieron intervalos para cada una de ellas. El intervalo [0,5–1,5] correspondió a hojas sanas, [1,5–2,5] se estableció para *T. urticae*, [2,5–3,5] se estableció para la deficiencia de N, [3,5–4,5] se estableció para otras deficiencias y [4,5– 5,5] se fijó por daños causados por *P. citrella*.

Para todos los casos, los resultados de los modelos PLS-DA se expresaron como un porcentaje de clasificación acertado. La precisión y la capacidad predictiva de los modelos PLS-DA se evaluaron mediante el coeficiente de determinación (R^2). Se utilizó el error cuadrático medio (RMSE) entre los valores predichos y los medidos del parámetro de referencia en los conjuntos de calibración, validación cruzada y predicción como medida de bondad del modelo.

4. Resultados y discusión

4.1. Detección de daños causados por *T. Urticae* mediante imágenes en color

4.1.1. Parámetros de discriminación

En general, los daños causados por *T. urticae* y los causados por otros problemas, como deficiencias, son muy diferentes (Figura 3) pero por color ambos grupos no se pudieron separar. Los resultados del ANOVA para saber si las propiedades geométricas consideradas eran significativamente diferentes entre estos dos grupos y, por lo tanto, se podían utilizar para separar daños de *T. urticae* de otras áreas dañadas debido a otras razones se muestran en la Tabla 3, en la que se observa que la mayoría de las propiedades fueron significativamente diferentes en los dos grupos (alto valor de F, $p < 0,05$). Dado el resultado y con el fin de simplificar el modelo se decidió elegir únicamente 3 de los parámetros para la clasificación de las hojas: la cantidad de daño por hoja, el área total y el área individual del daño. De modo que, para cada objeto detectado si los valores de cada una de estas propiedades se encontraban dentro de la media \pm la desviación estándar de los valores correspondientes a daños por *T. urticae*, se consideró que la hoja estaba afectada por *T. urticae*.

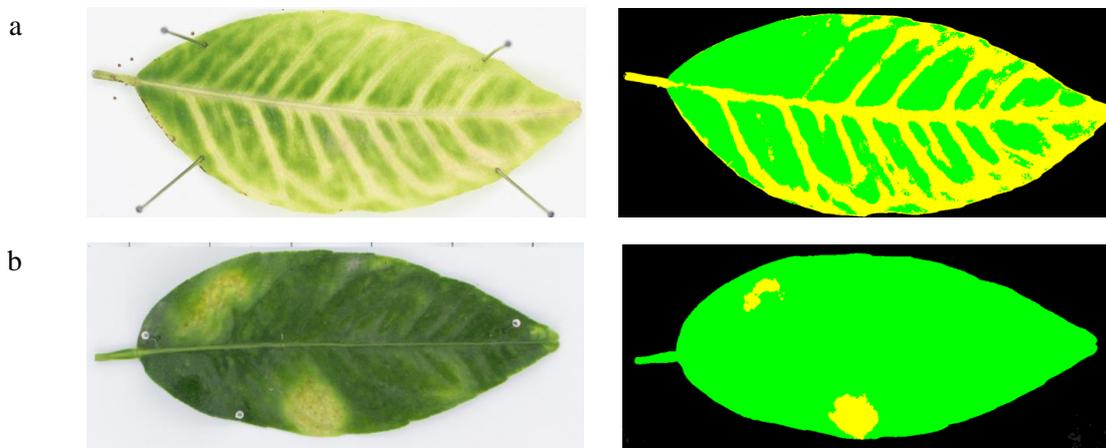


Figura 3. Ejemplos de segmentación de imágenes de hojas. **a)** Hoja con síntomas compatibles con deficiencias de N. **b)** Hoja afectada por *T. urticae*.

Tabla 3. Análisis de varianza (ANOVA) de las propiedades geométricas de los objetos encontrados en las imágenes utilizadas para este análisis. Los objetos corresponden a daños reales causados por *T. urticae* y deficiencias nutricionales (no *T. urticae*).

	<i>T. Urticae</i>		No <i>T. Urticae</i>		Parámetros estadísticos del ANOVA*	
	Media	Desviación típica	Media	Desviación típica	F	p
Alargamiento	1,539	0,272	4,230	4,596	8,161	0,0053
Redondez	0,506	0,163	0,252	0,155	44,362	0,0000
Área Individual	67293,94	39350,89	224056,90	233071,55	9,476	0,0036
Compacidad	34,98	17,41	83,82	75,29	15,092	0,0002
Perímetro	3260,06	2932,77	1848,61	2928,42	5,699	0,0187
Daños por hoja	1,69	0,855	9,000	6,890	11,208	0,0032
Área dañada total	82321,75	35703,98	1176298,75	517992,91	83,652	0,0000

* Grados de libertad: 1,95.

4.1.2. Detección de los daños

La Tabla 4 muestra la clasificación de los daños detectados para cada conjunto y subconjunto según el lado de la hoja. El método basado en la información de color junto con la aplicación de los parámetros de discriminación determinó correctamente el 100% de las hojas sanas en todos los casos, independientemente de que fueran jóvenes o adultas. La detección de daño por *T. urticae* también fue alta en todos los casos, alcanzando una tasa de éxito global del 92,5% (91,67% en el envés y 93,33% en el haz de la hoja). La mayoría de los errores se debieron a daños que no se detectaron, y solo en dos casos dados en el envés de las hojas adultas se confundieron con el daño causado por *P. citrella*, cuya causa probablemente fuera por el pardeamiento que se da en el envejecimiento del daño de *T. urticae* en la hoja. La tasa media de éxito de discriminación de *T. urticae* en el grupo de hojas con daños causados por *P. citrella* fue del 95% (100% para el envés – 0 casos detectados, 90% para el haz – 10 casos detectados). Además, *P. citrella* fue discriminada con éxito en el 100% de los casos cuando se examinó el envés, pues el color del daño en esta superficie tiende a tener color amarronado mientras que para el haz la tasa de éxito no alcanzó ni el 50% en las hojas evaluadas pues no presentaban daño visible en esta superficie (Figura 1). Finalmente, la discriminación entre el daño por deficiencia fue diferente según la deficiencia nutricional. No obstante, a pesar de las similitudes en el color, se obtuvo un 100% de éxito en la discriminación de *T. urticae*, pues se detectaron 0 casos con daños provocados por esta plaga (G2) en el grupo de hojas con deficiencia de N (G4.1) y en el grupo de hojas con deficiencias nutricionales (G4.2) tanto en el haz como en el envés de la hoja. La deficiencia de N no pudo discriminarse correctamente ya que el síntoma principal fue el aclaramiento del color verde, pero no siguió ningún patrón de forma en particular. El sistema no pudo establecer un umbral general válido para determinar cuándo una hoja tenía deficiencia de N o solo era de color verde claro. En lo referente a otras deficiencias, detectó correctamente que el 50% de los casos presentaban daños debidos a deficiencias de Fe, Mn o Zn.

Tabla 4. Resultados de la detección de daño causado por *T. urticae* en cada lado de la hoja usando la información de color y forma en las imágenes en color.

Conjuntos y subconjuntos		Envés (%)					Haz (%)				
Tipo de daño		G1	G2	G3	G4.1	G4.2	G1	G2	G3	G4.1	G4.2
Sana	G1	100	0	0	0	0	100	0	0	0	0
<i>T. urticae</i>	G2	5	91,67	3,33	0	0	6,67	93,33	0	0	0
<i>P. citrella</i>	G3	0	0	100	0	0	90	10	0	0	0
N	G4.1	100	0	0	0	0	83,33	0	0	16,67	0
Fe, Mn o Zn	G4.2	41,67	0	8,33	0	50	50	0	0	0	50

4.2. Detección de daños causados por *T. Urticae* mediante imágenes hiperspectrales

4.2.1. Detección de daño causado por *T. Urticae*

La Figura 4 muestra los espectros de reflectancia promedio obtenidos del haz y el envés de las regiones sanas y dañadas de los conjuntos G1 y G2 según la antigüedad del daño. Tanto los espectros correspondientes a hojas sanas como a hojas con daño siguen los patrones típicos de reflectancia de plantas sanas y estresadas (Reid, 1987). La mayoría de las diferencias se encontraron en la región visible del espectro debido a cambios en la coloración de las hojas, ya que el daño de *T. urticae* provoca la mancha clorótica caracterizada por una decoloración amarilla. Esta decoloración se debe a una pérdida de pigmentos por efecto de la plaga. Los pigmentos de las hojas (principalmente clorofila, caroteno y xantofila) son un factor esencial en la absorción de energía por las hojas en la región de 450-700 nm (Alonso et al., 1999). Para las áreas sanas, el nivel de absorción en la región de 530-600 nm fue menor y, por lo tanto, la reflectancia fue mayor que en las regiones adyacentes azul y roja, donde se observó un pico alrededor de 550 nm (Arnon, 1971), asociado con el color verde de las hojas.

Por el contrario, las regiones dañadas no mostraron ningún pico alrededor de 550 nm debido a la decoloración de la hoja causada por la plaga. En este caso, la curva se extendía entre las regiones verde y roja del espectro visible, alcanzando su punto medio alrededor de los 600 nm y mostrando el pico en diferentes áreas de este rango del espectro. A partir de 700 nm, se observó una transición en la zona de absorción de clorofila con el aumento progresivo en el valor del espectro a las bandas de 740-750 nm. Este fuerte aumento en la curva entre el rojo y la región NIR se conoce como borde rojo. La pendiente y la posición del borde rojo se han correlacionado con las concentraciones de clorofila y, por lo tanto, la posición y la pendiente del borde rojo también cambian en las hojas dañadas porque las sanas continúan teniendo fotosíntesis activa (Rock et al., 1986).

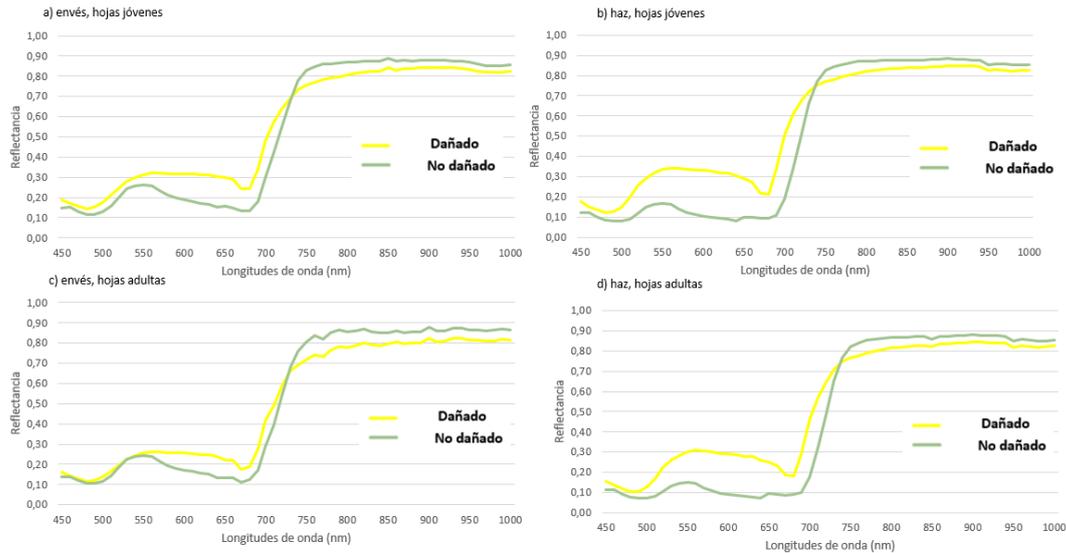


Figura 4. Espectros medios de las regiones sanas y dañadas extraídas de los conjuntos G1 (sin daños) y G2 (dañados por *T. urticae*) en función de la antigüedad y cara de la hoja. **a)** envés, hojas jóvenes; **b)** haz, hojas jóvenes; **c)** envés, hojas adultas; y **d)** haz, hojas adultas.

Se construyeron dos modelos de clasificación PLS-DA supervisados (i) usando las 56 longitudes de onda en el rango espectral 450–1000 nm y (ii) usando solo las longitudes de onda seleccionadas con el análisis del vector de los coeficientes de regresión. La Figura 5 muestra el vector de coeficientes de regresión para cada lado y antigüedad de la hoja. Las longitudes de onda con los coeficientes de regresión absolutos más altos se seleccionaron como longitudes de onda principales. En el caso del haz, se observan diferencias visuales aparentes entre el verde de las regiones sanas (530 nm) y las manchas cloróticas amarillas de las áreas dañadas (600 nm). Sin embargo, las longitudes de onda más importantes fueron tres, identificadas alrededor de las regiones roja y borde rojo (670, 700 y 740 nm).

Las variaciones en las variables espectrales (X) y las variables categóricas (Y) fueron descritas por solo siete LV. Este número relativamente bajo de LV sugiere una baja correlación en los espectros de diferentes clases, pero similitudes en los espectros dentro de las clases. Además, este número de LV indica una excelente diferenciación entre las clases que se construyeron. Por otra parte, tanto para el espectro completo como para las longitudes de onda seleccionadas, los valores de RMSE no mostraron una gran diferencia para la calibración y la validación, respectivamente, indicando así que el error de calibración es una estimación razonable del error estándar de predicción observado en el conjunto de prueba. Además, el conjunto de prueba arrojó un R^2 superior a 0,87 en ambos casos, lo que muestra el excelente desempeño del modelo para la clasificación de daños (Tabla 5). De hecho, la tasa de clasificación lograda fue del 100% para todos los casos. Los modelos pudieron detectar el 100% de los casos de daño causado por *T. urticae* en hojas adultas y jóvenes y en el haz y el envés de las hojas.

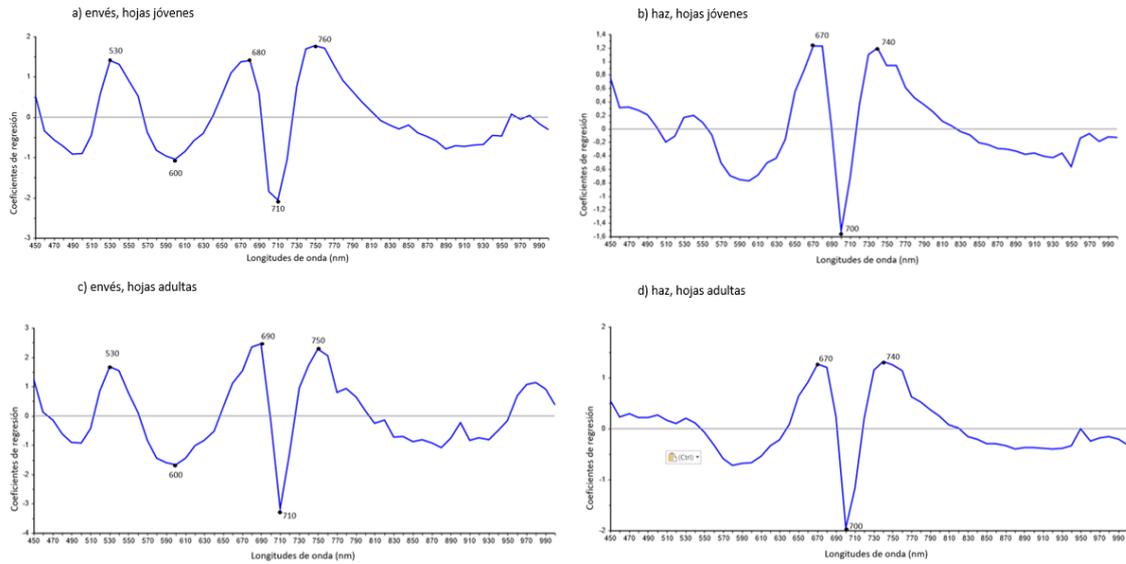


Figura 5. Vector de coeficientes de regresión del modelo PLS usando espectros medios y con las longitudes de onda óptimas seleccionadas en función de la antigüedad y cara de la hoja **a)** envés, hojas jóvenes; **b)** haz, hojas jóvenes; **c)** envés, hojas adultas; y **d)** haz, hojas adultas.

Tabla 5. Resultados de la predicción del daño causado por la plaga *Tetranychus urticae* para hojas jóvenes y adultas utilizando todas las longitudes de onda y las longitudes de onda seleccionadas.

			Variables Latentes	Calibración		Validación cruzada		Predicción	
				R ² _c	RMSE _c	R ² _{cv}	RMSE _{cv}	R ² _c	RMSE _c
Envés	Todas las longitudes de onda	Joven	7	0,946	0,116	0,937	0,127	0,926	0,136
		Adulta	7	0,926	0,136	0,917	0,145	0,894	0,163
	Longitudes de onda seleccionadas	Joven	7	0,939	0,124	0,928	0,136	0,919	0,142
		Adulta	7	0,926	0,135	0,915	0,149	0,874	0,178
Haz	Todas las longitudes de onda	Joven	7	0,974	0,08	0,971	0,08	0,936	0,126
		Adulta	7	0,967	0,09	0,961	0,099	0,968	0,089
	Longitudes de onda seleccionadas	Joven	7	0,974	0,080	0,970	0,087	0,939	0,123
		Adulta	7	0,967	0,091	0,961	0,099	0,968	0,089

4.2.2. Detección de la antigüedad del daño causado por *T. Urticae*

La Figura 6 muestra la reflectancia espectral media obtenida del daño causado por esta plaga para cada lado de la hoja en función de su antigüedad. Se observaron algunas diferencias entre hojas jóvenes y adultas. La reflectancia del daño de las hojas adultas fue menor que la reflectancia

de las hojas jóvenes, especialmente en la parte visible del espectro. Esto podría deberse a diferencias en la pigmentación. Un bajo contenido de pigmentación da como resultado una mayor reflectancia y viceversa. Por tanto, en una hoja joven afectada por *T. urticae*, la descomposición de las clorofilas hace que la presencia de carotenos y xantofilas sea más evidente, produciendo un fuerte aumento de la reflectancia (Roy, 1989). Otra posible razón podría ser los cambios en las propiedades espectrales de las hojas de las plantas durante el crecimiento.

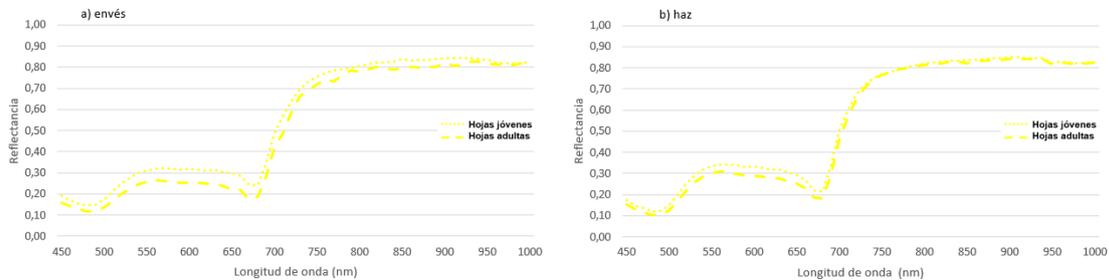


Figura 6. Espectros medios de las regiones dañadas por *T. urticae* en las hojas jóvenes y adultas en a) el envés y b) el haz de la hoja.

En cuanto a la selección de longitudes de onda, se obtuvieron cinco longitudes de onda a partir del vector de coeficientes de regresión para el envés y siete para el haz de la hoja (Figura 7). Las bandas espectrales seleccionadas como principales se encuentran principalmente detrás del borde rojo, siendo la banda espectral de 850 nm común para ambos lados de la hoja.

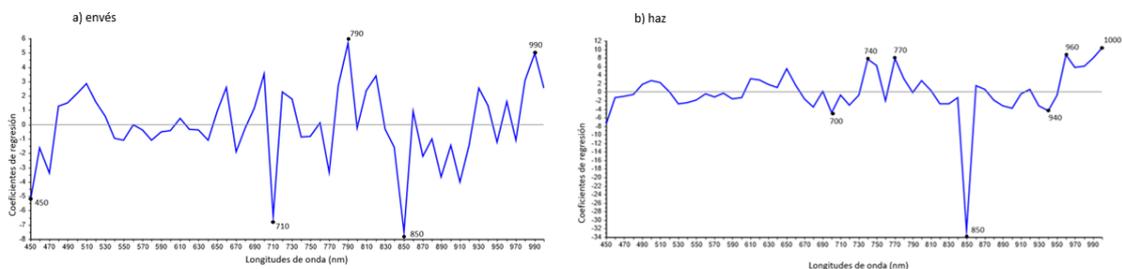


Figura 7. Vector de coeficientes de regresión del modelo PLS utilizando espectros medios y con las longitudes de onda óptimas seleccionadas en (a) el envés y (b) el haz de la hoja.

En la tabla 6 se muestran los resultados obtenidos para la clasificación PLS-DA según la antigüedad del daño. Para ambos modelos, se clasificó correctamente un alto porcentaje según la antigüedad del daño (> 92% para todos los casos). Es importante resaltar que la tasa de éxito del 100% se logró para el envés, ya que es la parte de la hoja donde se alimenta el ácaro y, por consiguiente, el daño es más evidente.

Para el envés de la hoja, los valores de RMSE obtenidos en el modelo PLS de longitudes de onda óptimas fueron más altos en comparación con el modelo con todas las longitudes de onda. Ambos mostraron concordancia entre calibración y validación, obteniendo además un R^2 superior a 0,87 en todos los casos. Por otro lado, el haz de la hoja mostró un R^2 muy bajo para la predicción, con un valor de 0,65 para el modelo basado en todas las longitudes de onda (Tabla 7).

Tabla 6. Clasificación de la antigüedad del daño de *T. urticae* (%) en hojas jóvenes y adultas para el conjunto de validación establecido en el PLS-DA utilizando todas las longitudes de onda seleccionadas en cada lado de la hoja.

		Variables Latentes	Clase (%)		
			Joven	Adulta	Adulta
Envés	Todas las longitudes de onda	7	Joven Adulta	100 0	0 100
	Longitudes de onda seleccionadas	5	Joven Adulta	100 0	0 100
Haz	Todas las longitudes de onda	7	Joven Adulta	88,89 3,70	11,11 96,30
	Longitudes de onda seleccionadas	5	Joven Adulta	86,73 1,02	13,27 98,98

Tabla 7. Resultados de la predicción de la antigüedad del daño causado por la plaga *Tetranychus urticae* en hojas jóvenes y adultas utilizando todas las longitudes de onda y las longitudes de onda seleccionadas para cada lado de la hoja.

		Variables Latentes	Calibración		Validación cruzada		Predicción	
			R ² _c	RMSE _c	R ² _{cv}	RMSE _{cv}	R ² _c	RMSE _c
Envés	Todas las longitudes de onda	7	0,929	0,133	0,895	0,164	0,960	0,099
	Longitudes de onda seleccionadas	5	0,882	0,172	0,868	0,182	0,909	0,150
Haz	Todas las longitudes de onda	7	0,792	0,228	0,750	0,252	0,645	0,298
	Longitudes de onda seleccionadas	5	0,836	0,202	0,795	0,228	0,671	0,287

4.2.3. Discriminación entre daños causados por *T. Urticae* y otros daños

Se evaluaron los espectros de reflectancia promedio de hojas sanas, hojas con daño causado por *T. urticae* y *P. citrella* y hojas con diferentes deficiencias para cada lado de la hoja (Figura 8).

En el rango espectral de verde a rojo, se pudieron observar las diferencias entre los distintos tipos de daño. El conjunto G2 (*T. urticae*) y los subconjuntos G4.1 (deficiencia de N) y G4.2 (daño por otras deficiencias) presentaron un pico alrededor de 550-570 nm en ambos lados de la hoja, pero con un nivel de intensidad diferente. Por otro lado, el conjunto G3 (*P. citrella*) presentó un comportamiento diferente según la superficie de la hoja, ya que la galería creada por la larva durante su alimentación es bastante visible solo en el envés de las hojas de muestra (Figura 1).

El valle en la región de 670-690 nm estuvo marcado en todos los casos, lo que indica la absorción de clorofila en mayor o menor medida. En la región de 700 a 750 nm, el valor del espectro aumentó, pero no con el mismo nivel de intensidad en todos los casos. G3 obtuvo valores bajos de reflectancia en el NIR respecto a los otros tipos de daños, lo que indica que esta vegetación estaba bastante afectada o que tenía una falta de humedad considerable. En esta región espectral, los valles y picos se pueden ver con bastante claridad en diferentes bandas espectrales para cada tipo de daño. En ambos lados de la hoja, el espectro muestra un pequeño valle en 770 nm típico de todos los daños a excepción del causado por *T. urticae*. Lo mismo sucedió con un pico encontrado en 900 nm.

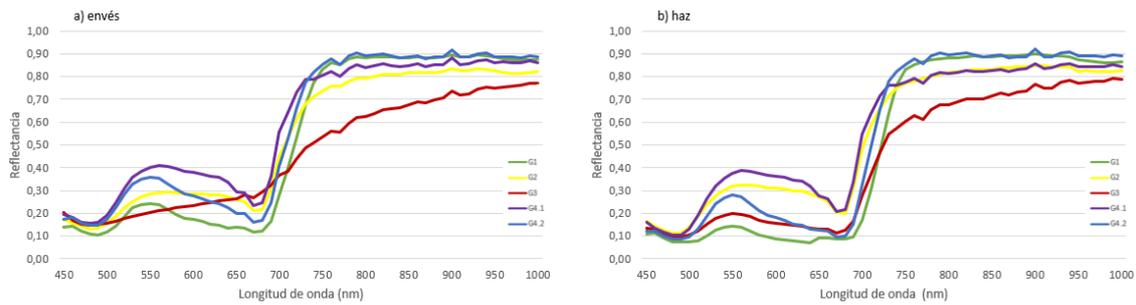


Figura 8. Espectros medios de hojas sanas (G1), hojas con daño causado por *T. urticae* (G2) y *P. citrella* (G3), y hojas con deficiencia de N (G4.1) y con otras deficiencias (G4.2) en **a)** envés y **b)** haz de la hoja.

Las longitudes de onda que más contribuyeron a la clasificación y que se obtuvieron mediante los coeficientes de regresión del modelo PLS (Figura 9) fueron nueve en el envés y once en el haz de la hoja.

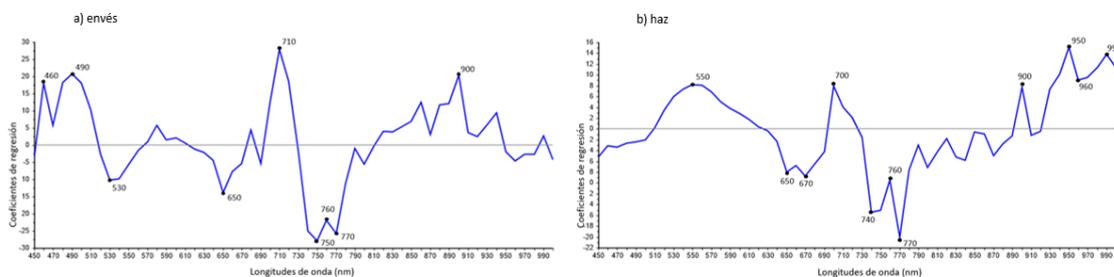


Figura 9. Vector de coeficientes de regresión del modelo PLS utilizando espectros medios y con las longitudes de onda óptimas seleccionadas en **a)** el envés y **b)** el haz de la hoja.

En la Tabla 8 se muestran los resultados obtenidos para la clasificación de daños en función de los grupos de muestras. Todos los modelos, utilizando todas las longitudes de onda y las longitudes de onda óptimas, mostraron un bajo porcentaje de daño correctamente clasificado (<50%), con el valor más bajo para el daño causado por otras deficiencias (0% en ambos modelos para cada lado de la hoja).

Tabla 8. Clasificación de daños según la presencia de diferentes tipos de daño para el conjunto de validación en el PLS-DA utilizando todas las longitudes de onda seleccionadas en cada lado de la hoja.

		Variables		Clase (%)				
		Latentes	Conjunto	G1	G2	G3	G4.1	G4.2
Envés	Todas las longitudes de onda	7	G1	100	0	0	0	0
			G2	0	75,93	1,85	16,67	5,56
			G3	0	0	100	0	0
			G4.1	0	33,33	0	66,67	0
			G4.2	20	80	0	0	0
	Longitudes de onda seleccionadas	5	G1	100	0	0	0	0
			G2	0	69,67	1,85	22,92	5,56
			G3	0	0	100	0	0
			G4.1	0	33,33	0	66,67	0
			G4.2	0	100	0	0	0
Haz	Todas las longitudes de onda	7	G1	95,83	4,17	0	0	0
			G2	0	81,48	1,85	12,96	3,70
			G3	0	0	100	0	0
			G4.1	0	16,67	16,67	66,67	0
			G4.2	20	80	0	0	0
	Longitudes de onda seleccionadas	4	G1	95,83	4,17	0	0	0
			G2	0	94,20	1,85	3,95	0
			G3	0	0	100	0	0
			G4.1	0	33,33	0	66,67	0
			G4.2	0	100	0	0	0

Los valores de RMSE para calibración y validación en los modelos con el espectro completo y con las longitudes de onda seleccionadas fueron similares. La predicción R^2 para los dos lados de la hoja mostró valores de 0,85 y 0,84 usando todas las longitudes de onda y 0,80 y 0,86 usando las longitudes de onda seleccionadas (Tabla 9).

Tabla 9. Resultados de la predicción de la discriminación de daño causado por la plaga *Tetranychus urticae* frente a otros daños utilizando todas las longitudes de onda y las longitudes de onda seleccionadas.

		Variables Latentes	Calibración		Validación cruzada		Predicción	
			R ² _c	RMSE _c	R ² _{cv}	RMSE _{cv}	R ² _c	RMSE _c
Envés	Todas las longitudes de onda	7	0,885	1,810	0,875	1,899	0,848	2,081
	Longitudes de onda seleccionadas	5	0,877	1,875	0,874	1,905	0,802	2,255
Haz	Todas las longitudes de onda	7	0,874	1,902	0,865	1,969	0,838	2,149
	Longitudes de onda seleccionadas	4	0,891	1,762	0,880	1,858	0,857	2,017

Cabe destacar el potencial del sistema para detectar los daños causados por *P. citrella* que son casi invisibles desde el haz de las hojas, como se puede observar en la Figura 1 y la Figura 10a. Aunque este no fue el objetivo de esta investigación, que se centró en los daños causados por *T. urticae*, este hallazgo es relevante. *P. citrella* se detectó utilizando una longitud de onda de 770 nm, que el análisis PLS identificó como una de las más importantes para hallar el daño. La figura 10a muestra la comparación entre el haz de una hoja fotografiada con una cámara a color y la banda de 770 nm en la imagen hiperespectral. En general, como se muestra en la Figura 10b, el área dañada presenta una reflectancia menor en la región NIR, lo que está de acuerdo con la mayoría de trabajos científicos sobre la reflectancia de plantas estresadas.

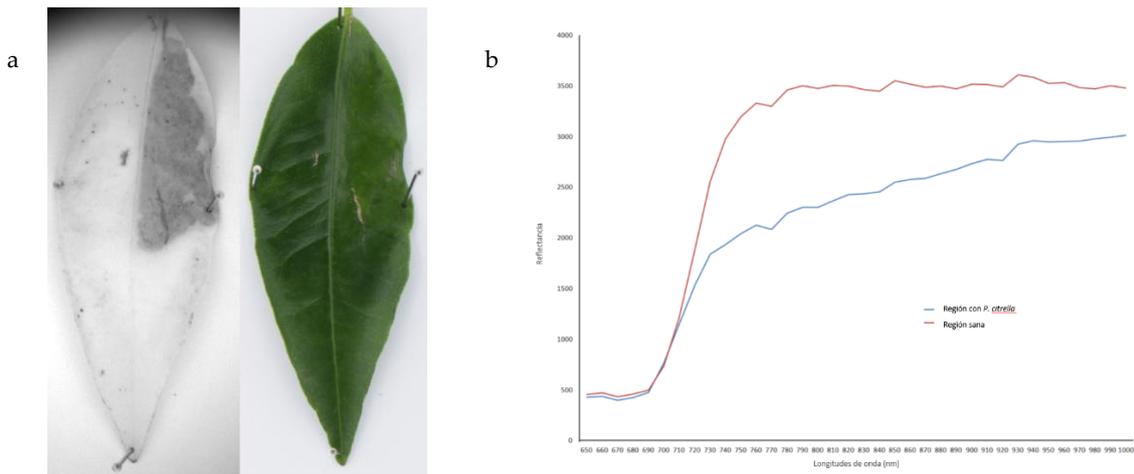


Figura 10. a) Comparación de la imagen del haz de una hoja capturada a 700 nm con la cámara hiperespectral y la imagen de la misma hoja capturada con la cámara a color. **b)** Espectros de las regiones sanas y dañadas de esta hoja.

5. Conclusiones

En el análisis de las imágenes en color, con la segmentación de color y la discriminación en función de los parámetros geométricos se obtuvo una tasa de éxito del 100% para identificar hojas sin daños, mientras que las hojas con presencia de *T. urticae* se identificaron correctamente en el 92,5% de los casos. La mayoría de los errores se debieron a la confusión con algunas deficiencias. Sin embargo, este método no fue capaz de discriminar entre daños antiguos y recientes causados por *T. urticae*.

En el conjunto de hojas con daños provocados por *P. citrella*, esta plaga se discriminó con éxito en el 100% de los casos cuando se examinó el envés. En el haz, el 10% de los casos se confundieron con daños causados por *T. urticae*, debido a la similitud en la tonalidad de color, y se catalogó el 90% de daños como hoja sana, puesto que en la mayoría de hojas examinadas el daño era visible únicamente en la parte inferior de las hojas.

En lo referente a las deficiencias, no se confundieron estos daños con los causados por *T. urticae* en ningún caso. La deficiencia de N no pudo discriminarse correctamente y las deficiencias de Fe, Mn o Zn se detectaron acertadamente en el 50% de los casos.

En el análisis de las imágenes hiperespectrales, el modelo PLS-DA pudo separar el área sana de las áreas dañadas en el 100% de los casos. Por un lado, las infestaciones recientes se distinguieron de las adultas en el 92% de los casos, con una tasa de éxito del 100% para el envés de las hojas, ya que el daño es más evidente en esta superficie. La plaga *P. citrella* se discriminó con éxito en el 100% de los casos, tanto en el haz como en el envés. Las deficiencias por N se discriminaron correctamente en más del 65% de los casos en ambos lados de la hoja, debiéndose los errores a la similitud de color con los daños causados por *T. urticae*, clase en la que se catalogaron el resto de casos. Los modelos para explorar la capacidad para discriminar entre *T. urticae* y el daño causado por deficiencias de Fe, Mn o Zn mostraron un porcentaje de daño correctamente clasificado inferior al 50%.

Si bien no fue el objetivo de esta investigación, un hallazgo relevante ha sido el potencial de los sistemas hiperespectrales para detectar el daño causado por *P. citrella*.

Los resultados indicaron el potencial de las imágenes en color e hiperespectrales para detectar las manchas cloróticas causadas por *T. urticae* en las hojas de los cítricos como técnicas rápidas y automáticas que representan una mejora respecto a los métodos manuales.



Capítulo VI

Conclusiones

CAPÍTULO VI - CONCLUSIONES

Atendiendo a las investigaciones y desarrollos realizados, las estrategias propuestas y los resultados obtenidos en el marco de esta Tesis Doctoral, las principales conclusiones en función de los objetivos definidos son:

OBJETIVO 1: Análisis e identificación de las necesidades en un prototipo de plataforma autopropulsada de asistencia, con el fin de facilitar y optimizar el proceso de recolección de cítricos para consumo en fresco minimizando los riesgos laborales, implementación de mejoras en el prototipo y evaluación de la funcionalidad tras la realización de estas mejoras mediante ensayos de recolección e inspección en una parcela comercial de cítricos.

- Análisis e identificación de las necesidades en el prototipo:
 - Se identificaron los riesgos laborales para los operarios mediante la inspección de los elementos de seguridad activa y pasiva, y se adoptaron las soluciones correctivas para garantizar la seguridad y prevención en el prototipo y minimizar estos riesgos. Entre estas soluciones destacan las mejoras en los accesos a las escaleras, la adecuación y mejora de las tarimas del prototipo, la disposición de sistemas de seguridad y la instalación de asideros y argollas de seguridad.
 - Se identificaron las áreas del prototipo susceptibles de producir daños a los frutos a su paso por el mismo, y se implementaron mejoras estructurales y funcionales para asegurar la calidad de la fruta inspeccionada, destacando la sustitución de los volcadores de fruta, la instalación de un sistema de control para la cinta transportadora de la tolva y el diseño y disposición de elementos para evitar acumulaciones y aplastamientos de la fruta.
 - Se mejoró el sistema de inspección automática de la fruta y la automatización y control del prototipo mediante el rediseño del sistema de iluminación, una nueva placa de control del sistema de inspección, el rediseño del mando de conducción y el diseño y configuración de una nueva pantalla HMI táctil en el cuadro de control.
- Evaluación de la funcionalidad tras las mejoras llevadas a cabo:
 - Se detectaron nuevas áreas de mejora y zonas donde seguía acumulándose la fruta en la sección de la tolva, la cinta elevadora y el contenedor interior.
 - Se demostró que el tiempo invertido en el proceso de recolección con la asistencia del prototipo fue un 17% menor que en la recolección manual tradicional, pues se obtuvo un rendimiento operativo teórico con el prototipo de 36,50 h·ha⁻¹ mientras que con la recolección manual sin asistencia el rendimiento fue de 44,12 h·ha⁻¹.
 - Se evidenció también que las frutas que transitan por el prototipo no sufrieron daños que puedan causar podredumbres, pues no se obtuvieron diferencias significativas entre ambos métodos de recolección, obteniéndose un 2% y un 3% de frutos con presencia de podredumbres durante su almacenaje postcosecha en las frutas que transitaban por el prototipo y en la recolección manual sin asistencia, respectivamente.

Como conclusión general, se demostró el potencial que ofrece esta tecnología de asistencia en la recolección de fruta con destino al mercado en fresco, mejorando la calidad y ergonomía de trabajo de los recolectores, extrayendo información de los parámetros de calidad de la fruta y clasificando esta fruta in situ por categorías lo que permite al agricultor mejorar la gestión en función de las necesidades. De igual manera, las mejoras y avances llevados a cabo supusieron

un gran paso en la seguridad de los operarios, en la garantía de la calidad de la fruta a su paso por el prototipo y en el funcionamiento eficaz y óptimo del prototipo.

OBJETIVO 2: Creación de una herramienta digital a modo de cuadro de mando para la generación automática de mapas accesibles al agricultor mostrando la información clave obtenida del cultivo mediante los sensores instalados en el prototipo de plataforma.

- Creación de la nueva herramienta digital *CitrusYield*:
 - Se desarrolló una nueva herramienta con el software R en forma de cuadro de mando para el análisis y gestión de datos y la visualización de mapas de producción y calidad de la fruta a partir de los datos obtenidos por los diferentes sensores instalados en la plataforma móvil durante el proceso de recolección
 - Se integró en ella información de interés para técnicos y agricultores en cuanto a distribución espacial y calidad de la producción citrícola.
 - Se diseñó en un entorno intuitivo y fácilmente manejable, mostrando la información útil del cultivo, sin necesidad de conocimientos informáticos por parte del usuario.
 - Se configuró para poder calcular la producción, clasificar las frutas por categorías en función de su calidad, georreferenciar la información categorizada en mapas y realizar análisis estadísticos automáticamente para cada calle y para la parcela, mostrando los datos mediante gráficos y estadísticas.

- Evaluación de la funcionalidad de *CitrusYield*:
 - Se demostró la capacidad que tienen los mapas creados por el cuadro de mando para mostrar la heterogeneidad de la producción a nivel intraparculario, coincidiendo con las características variables de las variedades y producción de la parcela experimental.
 - Se probó que la información proporcionada por las tablas y gráficos permite conocer con detalle la variabilidad de la producción entre calles y áreas dentro del cultivo, identificando aquellas zonas donde la producción es deficiente.
 - Se logró obtener el grado de efectividad y eficiencia del proceso de recolección a través de los resultados obtenidos en los indicadores de calidad de la fruta clasificada, el rendimiento del proceso de inspección y los indicadores de productividad.

En definitiva, *CitrusYield* demostró ser una herramienta relevante en la agricultura 4.0 para representar la distribución espacial de los cítricos a nivel de calle, conocer la trazabilidad de la fruta, automatizar la creación de mapas y calcular la producción y calidad de los frutos, realizando el análisis exploratorio de los datos para detectar diferencias y anomalías, y también para el cálculo de rendimientos en la parcela, proporcionando al productor información precisa para tomar decisiones respecto al manejo del cultivo a nivel local, como fertilización, riego, control de plagas y enfermedades, etc.

OBJETIVO 3: Investigación del potencial de la imagen en color y la imagen hiperespectral para la detección automática de daños causados por la plaga *Tetranychus urticae* en hojas de cítricos (Capítulo V).

- Evaluación de la capacidad de ambas tecnologías para detectar el daño causado por la plaga *Tetranychus urticae*:
 - En las imágenes en color, en base a la segmentación de color y la discriminación en función de parámetros geométricos, se logró una tasa de detección de daños causados por *T. urticae* de 92,5%, debiéndose la mayoría de los errores a la confusión con algunas decoloraciones debidas a deficiencias nutricionales cuyo patrón de color se asemejaba al causado por *T. urticae*. Además, se obtuvo un 100% de éxito en la identificación de hojas sanas.
 - En las imágenes hiperespectrales, se identificaron correctamente el 100% de los casos tanto para hojas sanas como para hojas con áreas dañadas por esta plaga.
- Discriminación de la antigüedad del daño:
 - En las imágenes en color, no fue posible discriminar entre daños antiguos y recientes causados por *T. urticae* debido a que las diferencias de color entre ambos casos no resultaron apreciables.
 - En las imágenes hiperespectrales, se alcanzó una tasa de éxito del 92% en la distinción de infestaciones recientes, obteniendo un 100% en los casos evaluados para el envés de las hojas. En parte, este éxito se logró por la capacidad de la imagen hiperespectral para hallar diferencias entre hojas jóvenes y adultas, ya que ambas presentaron espectros diferenciados.
- Discriminación de los daños causados por la plaga *T. urticae* de otros daños producidos por la plaga *Phyllocnistis citrella* así como de otros problemas foliares como los provocados por deficiencias nutricionales.
 - En las imágenes en color,
 - En el conjunto de hojas con daños provocados por *P. citrella*, se detectaron y clasificaron correctamente el 100% de los casos cuando se examinó el envés.
 - En el haz, el 10% de los casos se confundieron con daños causados por *T. urticae*, debido a la similitud en la tonalidad de color, y el restante 90% de casos se catalogó como hoja sana, debiéndose estos errores a que en la mayoría de hojas examinadas el daño era visible únicamente en la parte inferior de las hojas.
 - En el conjunto de hojas con deficiencia de N y en el conjunto de hojas con deficiencias de Fe, Mn o Zn, no se confundieron estos daños con los causados por *T. urticae* en ningún caso.
 - Las deficiencias de N no pudieron ser discriminadas correctamente y en la discriminación de las deficiencias por Fe, Mn o Zn se obtuvo una tasa de éxito del 50%.
 - En las imágenes hiperespectrales,
 - La plaga *P. citrella* se discriminó correctamente en el 100% de los casos, tanto en el haz como en el envés.
 - Se detectó la capacidad de esta tecnología para identificar el daño causado por *P. citrella* utilizando la longitud de onda de 770 nm.
 - Las deficiencias por N se discriminaron correctamente en más del 65% de los casos en ambos lados de la hoja, debiéndose los errores a la similitud de color

con los daños causados por *T. urticae*, clase en la que se catalogaron el resto de casos.

- No se pudieron establecer diferencias discriminatorias entre los daños causados por *T. urticae* y el daño causado por deficiencias de Fe, Mn o Zn, donde el porcentaje de daño correctamente clasificado fue inferior al 50%.

Los resultados mostraron el potencial de estas técnicas como una alternativa rápida, automática y no destructiva frente al actual método de detección basado en la inspección visual para detectar las manchas cloróticas causadas por *T. urticae* en las hojas de los cítricos.

En base a las conclusiones de los tres objetivos específicos, esta Tesis Doctoral ha demostrado cómo el desarrollo de soluciones mecanizadas y automatizadas mediante la aplicación de sensores y nuevas tecnologías para monitorizar, optimizar tareas y digitalizar procesos influye en el aumento de la eficiencia y productividad en las tareas llevadas a cabo en los campos de cítricos y, por ende, en la competitividad del sector citrícola.



Capítulo VII

Consideraciones Finales y Recomendaciones para futuros trabajos de I+D

CAPÍTULO VII – CONSIDERACIONES FINALES Y RECOMENDACIONES PARA FUTUROS TRABAJOS I+D

Los resultados y conclusiones obtenidos en esta Tesis Doctoral muestran el potencial de las soluciones mecanizadas y automatizadas para monitorizar, optimizar tareas y aumentar la productividad y eficiencia en los campos cítricos. La generación de conocimiento extraída de estos estudios y la incorporación de la tecnología desarrollada es un avance de gran relevancia para este sector tan tradicional como es la agricultura, allanando el camino para alcanzar los objetivos para un desarrollo sostenible.

A partir de los conocimientos generados en esta Tesis Doctoral, se proponen futuros trabajos de investigación dentro de cada objetivo definido:

1. Análisis e identificación de las necesidades en un prototipo de plataforma autopropulsada de asistencia, con el fin de facilitar y optimizar el proceso de recolección de cítricos para consumo en fresco minimizando los riesgos laborales, implementación de mejoras en el prototipo y evaluación de la funcionalidad tras la realización de estas mejoras mediante ensayos de recolección e inspección en una parcela comercial de cítricos (Capítulo III).
 - Implementación de nuevos algoritmos de detección de defectos en el sistema de inspección del prototipo y evaluación del funcionamiento.
 - Adaptación de una configuración física ajustable del prototipo para todas las variedades y cultivares de cítricos y frutas en general. Evaluación del funcionamiento, velocidad de trabajo, rendimiento y robustez de la configuración adaptable.
 - Diseño, implementación y validación de nuevos algoritmos de detección y clasificación ajustables para cualquier tipo de fruta mediante aprendizaje automático con redes neuronales profundas.
 - Evaluación de la factibilidad económica y estratégica de este prototipo autopropulsado como método de asistencia en la recolección de fruta.
 - Evaluación medioambiental tras la implementación de un motor eléctrico con sus baterías para el funcionamiento del prototipo. Estudio de la reducción de emisiones y la disminución de contaminación acústica frente al estado actual con el motor diésel.
 - Digitalización de la información obtenida por el sistema de inspección del prototipo de manera que se pueda acceder a los datos en la nube desde cualquier dispositivo. Desarrollo de una aplicación para dispositivos móviles para visualizar esta información.
 - Comparativa entre la evaluación de producción con el prototipo y la estimación de la producción mediante técnicas de Deep Learning.
2. Creación de una herramienta digital a modo de cuadro de mando para la generación automática de mapas accesibles al agricultor mostrando la información clave obtenida del cultivo mediante los sensores instalados en el prototipo de plataforma (Capítulo IV).
 - Adaptación de la herramienta para procesar datos procedentes de la recolección de diferentes temporadas con el fin de realizar análisis comparativos de series temporales.

- Diseño, configuración y validación de nueva información mostrada en el cuadro de mando relacionada con la calidad y la producción, una vez se haya adaptado el prototipo a todo el espectro de cítricos.
 - Adaptación para la creación automática de mapas relacionados con la fertilización, el riego y el control de plagas y enfermedades con datos provenientes de sensores alternativos a los instalados en el prototipo, aunando toda esta información con la generada actualmente por la herramienta.
3. Investigación del potencial de la imagen en color y la imagen hiperespectral para la detección automática de daños causados por la plaga *Tetranychus urticae* en hojas de cítricos (Capítulo V).
- Investigación del potencial de la imagen en color e hiperespectral para la detección automática de daños causados por la plaga *T. urticae* en cítricos en condiciones de campo con el fin de desarrollar de manera efectiva un sistema automático de detección en condiciones reales de campo.
 - Generación de mapas de presencia de *T. urticae* a partir del uso del sistema automático de detección en campo y la georeferenciación de dichos datos.
 - Ampliación del estudio de detección de daños causados por la plaga *Phyllocnistis citrella* en hojas de cítricos mediante sistemas hiperespectrales.
 - Desarrollo de una aplicación en dispositivos móviles para la detección automática de plagas en cítricos mediante aprendizaje supervisado o no supervisado. Para ello, se ha de aumentar la base de datos de los daños comunes presentes en los cítricos, ya sea en el fruto o en las hojas.
 - Creación de una biblioteca espectral de daños en hojas para diferentes variedades y cultivares de cítricos, de modo que puedan obtenerse fácilmente modelos universales.



Capítulo VIII

Producción científica y Difusión

CAPÍTULO VIII – PRODUCCIÓN CIENTÍFICA Y DIFUSIÓN

1. Publicaciones en revistas recogidas en el JCR

González-González, M.G., Blasco, J., Cubero, S., y Chueca, P. (2021). Automated Detection of *Tetranychus urticae* Koch in Citrus Leaves Based on Colour and VIS/NIR Hyperspectral Imaging. *Agronomy*, 11(5), 1002.

DOI: 10.3390/agronomy11051002. Factor de impacto: 2.603 (Q1).

González-González, M.G., Gómez-Sanchis, J., Blasco, J., Soria-Olivas, E., y Chueca, P. (2020). *CitrusYield*: A Dashboard for Mapping Yield and Fruit Quality of Citrus in Precision Agriculture. *Agronomy*, 10(1), 128.

DOI:10.3390/agronomy10010128. Factor de impacto: 2.603 (Q1).

2. Publicaciones en revistas técnicas y de divulgación

González-González, M.G., Gómez-Sanchis, J., Blasco, J., Soria-Olivas, E., y Chueca, P. (2021). Herramienta digital para creación de mapas de rendimiento y calidad de cítricos. *Levante Agrícola*.

Chueca P., Garcerá C., Castro García S., Martín-Gorriz B., Mateu G., **González-González, M.G.** y Torregrosa A. (2019). La importancia de la mecanización en la citricultura. *Horticultura*.

3. Capítulos de libro

González-González, M.G., Chueca, P., Cubero, S., y Blasco, J. (2020). La irrupción de las tecnologías electrónicas y de la información. Una hoja de ruta para la citricultura española, 191-200. ISBN: 978-84-95531-49-0.

Chueca, P., Mateu, G., **González-González, M.G.**, Garcerá, C., Castro, S., Martín-Gorriz, B., y Torregrosa, A. (2020). La mecanización de los tratamientos fitosanitarios, la poda y la recolección Presente y futuro. Una hoja de ruta para la citricultura española, 177-190. ISBN: 978-84-95531-49-0.

Blasco, J., **González-González, M.G.**, Chueca, P., Cubero, S., y Aleixos, N. (2019). Advances in automated in-field grading of harvested crops. *Robotics and automation for improving agriculture*, 215-232. ISBN: 978-1786762726. DOI: 10.19103/AS.2019.0056.16.

4. Contribuciones en congresos nacionales e internacionales

Comunicaciones orales

González-González, M.G., Gómez, J., Alegre, V., López, S., Blasco, J., Cubero, S., Soria, E. y Chueca, P. (2019). Herramienta para la monitorización y generación de mapas de rendimiento en cítricos con los datos de una plataforma de asistencia a la recolección con sistema de clasificación. X Congreso Ibérico de Agroingeniería. 3-6 de noviembre de 2019, Huesca, España.

Gyomar González González, Patricia Chueca, Coral Ortiz y Beatriz Pérez-Lluch. (2018). Evaluation of a citrus mobile platform using a wireless impact recording device. *International Conference on Agricultural Engineering (EurAgEng 2018)*. 8-12 de julio de 2018, Wageningen, Holanda.

Pósteres

González-González, M.G., Chueca, P., Cubero, S. y Blasco, J. (2021). Capacity and limitations of colour image processing to detect *Tetranychus urticae* in citrus leaves. International Conference on Agricultural Engineering (EurAgEng 2021). 4-8 de julio de 2021, online.

González-González, M.G., Chueca, P., Cubero, S. y Blasco, J. (2021). Potential of VIS-NIR hyperspectral imaging to detect automatically *Tetranychus urticae* in citrus leaves. International Conference on Agricultural Engineering (EurAgEng 2021). 4-8 de julio de 2021, online.

González-González, M.G., Gómez-Sanchís, J., Blasco, J., Soria-Olivas, E. y Chueca, P. (2021). Cuadro de mando para la generación automática de mapas de producción de cítricos durante la recolección mecanizada. Congreso en red de olivicultura, citricultura y fruticultura de la Sociedad Española de Ciencias Hortícolas (SECH). 23-25 de marzo de 2021, online.

González-González, M.G., Gómez, J., Alegre, V., López, S., Blasco, J., Cubero, S., Soria, E. y Chueca, P. (2019). Mapping yield and quality of citrus using self-propelled platform with in-field sorting. European Conference on Precision Agriculture (ECPA). 8-11 de julio de 2019, Montpellier, Francia.

A. Fazari, S. Cubero, L. Palou, V. Taberner, S. Munera, J. Gómez-Sanchís, **G. González-González**, S. Benalia, G. Zimbalatti, B. Bernardi y J. Blasco. (2019). Detection of anthracnose in olives using VIS-NIR hypersectral imaging. Model-IT 6th International Symposium on Applications of Modelling as an Innovative Technology in the Horticultural Supply Chain. 9-12 de junio de 2019, Molfetta, Italia.

Gyomar González González. (2018). Análisis de los impactos de la fruta en una plataforma de asistencia a la recolección. V Encuentro de estudiantes de doctorado. Universidad Politécnica de Valencia. 5 de julio de 2018, Valencia, España.

5. Participación en jornadas de divulgación

TÍTULO: Datos agrícolas: Del sensor a la Tablet.

Jornada: Jornada “Inteligencia Artificial en Agricultura”.

Tipo de jornada: Online

Entidad organizadora: Intelligent Data Analysis Laboratory (IDAL), Universidad de Valencia (UV) e Instituto Valenciano de Investigaciones Agrarias (IVIA).

Ponente: **Gyomar González González**.

Duración: 30 minutos.

Fecha: 10 de diciembre de 2020.

TÍTULO: Herramienta para la monitorización y generación de mapas de rendimiento en cítricos.

Jornada: Jornada técnica “Resultados del proyecto CITRUSREC: Aplicaciones de nuevas tecnologías para una estrategia integral de la recolección mecanizada de cítricos”.

Tipo de jornada: Presencial

Localidad: Moncada, Valencia, España.

Entidad organizadora: Organizado por Instituto Valenciano de Investigaciones Agrarias (IVIA), Universidad Politécnica de Valencia (UPV), Universidad de Córdoba (UCO), Universidad de Valencia (UV) e Instituto de Investigación y Formación Agraria y Pesquera de Andalucía (IFAPA).

Ponente: **Gyomar González González**.

Duración: 20 minutos.

Fecha: 12 de marzo de 2019.

6. Registros de propiedad intelectual

González-González, M.G., Gómez-Sanchis, J., Blasco, J., Soria, E. y Chueca, P. (2019). Programa de ordenador *CitrusYield*. Registro General Universidad de Valencia, España. Fecha de registro: 20 de diciembre de 2019. Número de entrada: 203019.

:



Capítulo IX

Bibliografía

CAPÍTULO IX – BIBLIOGRAFÍA

Abdulridha, J., Batuman, O., & Ampatzidis, Y. UAV-based remote sensing technique to detect citrus canker disease utilizing hyperspectral imaging and machine learning. *Remote Sensing*. **2019**, *11*(11), 1373.

Álamo, S., Ramos, M.I., Feito, F.R., & Cañas, A. Precision techniques for improving the management of the olive groves of southern Spain. *Spanish Journal of agricultural research*. **2012**, (3), 583-595.

Alcalá, A.R., & Álamo, S. Using GPS for yield mapping in olive orchards. In *First International Conference on Geospatial Information in Agriculture and Forestry*. **1998**, 2, 633-637.

Alonso, C., Moreno, V., & Rodríguez, E. Determinación Experimental de la Firma Espectral de la Vegetación. Una Sencilla Práctica de introducción a la teledetección. In *TELEDETECCIÓN. Avances y Aplicaciones, VIII Congreso Nacional de Teledetección*: Albacete, España. **1999**, 429–443.

Amigo, J.M., Martí, I., & Gowen, A. Hyperspectral Imaging and Chemometrics. In *Multivariate Pattern Recognition in Chemometrics, Illustrated by Case Studies*, Elsevier BV: Amsterdam, The Netherlands, **2013**, 28, 343–370.

Ampatzidis, Y., Tan, L., Haley, R., & Whiting, M.D. Cloud-based harvest management information system for hand-harvested specialty crops. *Computers and Electronics in Agriculture*. **2016**, *122*, 161-167.

Annamalai, P., Lee, W.S., & Burks, T.F. Color vision system for estimating citrus yield in real-time. In *2004 ASAE Annual Meeting (p. 1)*. American Society of Agricultural and Biological Engineers. **2004**.

Ansaloni, T., Pascual-Ruiz, S., Hurtado, M.A., Jacas, J.A., & Jaques, J.A. Can summer and fall vegetative growth regulate the incidence of *Tetranychus urticae* Koch on clementine fruit? *Crop. Prot.* **2008**, *27*, 459–464.

Aragón-Rodríguez, F. Caracterización de la respuesta del árbol a la recolección mecanizada con sacudidores de copa en sistemas de plantación en seto de cítricos y olivar. **2021**.

Arenas-Arenas, F.J., Romero-Rodríguez, E., Quinto, J., & Hervalejo, A. Nuevos desafíos de la citricultura española. *Horticultura*. **2018**, *68*, 68-73.

Arnó Satorra, J., & Martínez Casasnovas, J.A. Operation in the field: site-specific management using variable rate technologies. *New Ag International*. **2018a**, *71*, 28-35.

Arnó Satorra, J., & Martínez Casasnovas, J.A. Cómo obtener y qué hacer con los mapas de colores. *New Ag International*. **2018b**, 16-20.

Arnó Satorra, J., Martínez Casasnovas, J.A., Ribes Dasi, M., & Rosell Polo, J.R. Precision viticulture. Research topics, challenges and opportunities in site-specific vineyard management. *Spanish Journal of Agricultural Research*. **2009**, *7* (4), 779-790.

Arnon, D.I. The Light Reactions of Photosynthesis. *Proc. Natl. Acad. Sci. USA*. **1971**, *68*, 2883–2892.

Aucejo, S., Foó, M., Ramis, M., Troncho, P., Gómez-Cadenas, A., & Jacas, J.A. Evaluación de la eficacia de algunos acaricidas contra la araña roja, *Tetranychus urticae* Koch (Acari: Tetranychidae), en clementino. *Bol. San. Veg. Plagas*. **2003**, *29*, 453–459.

Aucejo-Romero, S., Gómez-Cadenas, A., & Jacas-Miret, J.A. Effects of NaCl-stressed citrus plants on life-history parameters of *Tetranychus urticae* (Acari: Tetranychidae). *Exp. Appl. Acarol.* **2004**, *33*, 55–67.

- Bentini, M., Caprara, C., & Martelli, R. Harvesting damage to potato tubers by analysis of impacts recorded with an instrumented sphere. *Biosystems Engineering*, **2006**, *94*(1), 75-85.
- Berger, J., Preussler, C., & Agostini, J P. Identificación de síntomas de Huanglongbing en hojas de cítricos mediante técnicas de deep learning. *Electronic Journal of SADIO (EJS)*. **2019**, *18*(2), 2-20.
- Blasco, J., Aleixos, N., Cubero, S., Gómez-Sanchís, J., & Moltó, E. Automatic sorting of satsuma (Citrus unshiu) segments using computer vision and morphological features. *Comput. Electron. Agric.* **2009a**, *66*, 1–8.
- Blasco, J., Cubero, S., Gómez-Sanchis, J., Mira, P., & Moltó, E. Development of a machine for the automatic sorting of pomegranate (Punica granatum) arils based on computer vision. *J. Food Eng.* **2009b**, *90*, 27–34.
- Blasco, J., Diago-Santamaría, M.P., Rovira-Más, F., Aleixos, N., Sáiz-Rubio, V., Cubero, S., & Tardáguila, J. Aplicaciones de la visión artificial en viticultura (I). *Vida rural*. **2014**, *376*, 42-46.
- Blasco, J., González-González, M. G., Chueca, P., Cubero, S., & Aleixos, N. Advances in automated in-field grading of harvested crops. *Robotics and automation for improving agriculture*, **2019**, 215-232.
- Blok, P.M., Barth, R., & Van Den Berg, W. Machine vision for a selective broccoli harvesting robot. *IFAC-PapersOnLine*. **2016**, *49*(16), 66-71.
- BOE. (1997). Disponible online: <https://www.boe.es/buscar/doc.php?id=BOE-A-1997-17824> (acceso el 10 de febrero de **2022**).
- BOE. (2012). Disponible online: <https://www.boe.es/buscar/act.php?id=BOE-A-2012-11605&p=20120915&tn=2> (acceso el 10 de febrero de **2022**).
- BOE. (2019). Disponible online: <https://www.boe.es/buscar/doc.php?id=DOUE-L-2019-80410> (acceso el 10 de febrero de **2022**).
- Bonilla, I., Martínez de Toda, F., & Martínez-Casasnovas, J.A. Vine vigor, yield and grape quality assessment by airborne remote sensing over three years: Analysis of unexpected relationships in cv. Tempranillo. *Spanish Journal of Agricultural Research*. **2015**, *13*(2), e0903.
- Bornschlegel, T. The history of the Global Positioning System GPS. **2009**.
- Brereton, R.G. *Applied Chemometrics for Scientists*, Wiley: Hoboken, NJ, USA. **2007**.
- Bulanon, D. M., Burks, T. F., & Alchanatis, V. Fruit visibility analysis for robotic citrus harvesting. *Transactions of the ASABE*. **2009**, *52*(1), 277-283.
- Castro García, S., Sola Guirado, R.R., Blanco Roldán, G.L., & Gil Ribes, J.A. Sistemas sacudidores de copa laterales para la recolección mecanizada de cítricos con destino industria. *Horticultura*. **2018**, *335*, 34-39.
- Chen, S.W., Shivakumar, S.S., Dcunha, S., Das, J., Okon, E., Qu, C., & Kumar, V. Counting apples and oranges with deep learning: A data-driven approach. *IEEE Robotics and Automation Letters*. **2017**, *2*(2), 781-788.
- Chen, Y., Xie, M.Y., Yan, Y., Zhu, S.B., Nie, S.P., Li, C., Wang, Y.X., & Gong, X.F. Discrimination of Ganoderma lucidum according to geographical origin with near infrared diffuse reflectance spectroscopy and pattern recognition techniques. *Anal. Chim. Acta* **2008**, *618*, 121–130.
- Choi, D., Lee, W.S., Ehsani, R., Schueller, J.K., & Roka, F. Machine vision system for early yield estimation of citrus in a site-specific manner. In *2015 ASABE Annual International Meeting (p. 1)*. American Society of Agricultural and Biological Engineers. **2015**.

- Chueca, P., Garcerá, C., Castro Garcia, S., Martin-Gorriz, B., Mateu, G., Gonzalez-Gonzalez, M.G., & Torregrosa, A. La importancia de la mecanización en la citricultura. *Horticultura*. **2019**, *341*, 28-35.
- Chueca, P., Garcerá, C., Moltó, E., Jacas, J.A., Urbaneja, A., & Pina, T. Spray Deposition and Efficacy of Four Petroleum-Derived Oils Used Against *Tetranychus urticae* (Acari: Tetranychidae). *J. Econ. Entomol.* **2010**, *103*, 386–393.
- Chueca, P., Mateu, G., González-González, M.G., Garcerá, C., Castro, S., Martín-Gorriz, B., & Torregrosa, A. La mecanización de los tratamientos fitosanitarios, la poda y la recolección Presente y futuro. *Una hoja de ruta para la citricultura española*. **2020**, 177-190.
- COFILAB. (2022). Disponible online: <http://www.cofilab.com/registered-software/> (acceso el 10 de febrero de **2022**).
- Cortés, V., Rodríguez, A., Blasco, J., Rey, B., Besada, C., Cubero, S., Salvador, A., Talens, P., & Aleixos, N. Prediction of the level of astringency in persimmon using visible and near-infrared spectroscopy. *J. Food Eng.* **2017**, *204*, 27–37.
- Crockett, C., Liburd, O., & Abd-Elrahman, A. Development of image-based detection methods for two-spotted spider mite, *Tetranychus urticae* Koch, on strawberries. In *Proceedings of the Entomological Society of America Annual Meeting 2014*, Portland, OR, USA, 16–19 November 2014.
- Cubero, S. Diseño e implementación de nuevas tecnologías basadas en visión artificial para la inspección no destructiva de la calidad de fruta en campo y mínimamente procesada. Tesis doctoral, Universitat Politècnica de València. **2012**.
- Cubero, S., Aleixos, N., Albert, F., Torregrosa, A., Ortiz, C., García-Navarrete, O., & Blasco, J. Optimised computer vision system for automatic pre-grading of citrus fruit in the field using a mobile platform. *Precision agriculture*. **2014**, *15(1)*, 80-94.
- Cubero, S., Marco-Noales, E., Aleixos, N., Barbé, S., & Blasco, J. RobHortic: A Field Robot to Detect Pests and Diseases in Horticultural Crops by Proximal Sensing. *Agriculture*. **2020**, *10*, 276.
- Cubero, S., Moltó, E., Gutiérrez, A., Aleixos, N., García-Navarrete, O. L., Juste, F., & Blasco, J. Real-time inspection of fruit on a mobile harvesting platform in field conditions using computer vision. *Progress in Agricultural Engineering Science*. **2010**, *6*, 1-16.
- Davey, P. C. & Lahiff, P. Mechanical aids for citrus harvesting. *Proceedings of the International Society of Citriculture*, **1978**, *2*, 105–6.
- Decker, B.L. World geodetic system 1984. *Defense Mapping Agency Aerospace Center St Louis Afs Mo*. **1984**.
- Diago, M. P., Rovira-Más, F., Saiz-Rubio, V., Faenzi, E., Evain, S., Ben Ghazlen, N., ... & Tardáguila, J. The "eyes" of the VineRobot: Non-destructive and autonomous vineyard monitoring on-the-go. **2016**.
- Diago, M.P., Tardáguila, J., Aleixos, N., Millán, B., Prats-Montalban, J.M., Cubero, S., & Blasco, J. Assessment of cluster yield components by image analysis. *J. Sci. Food Agric.* **2014**, *95*, 1274–1282.
- Ebel, R.C., Burns, J.K., Morgan, K.T., & Roka, F. Abscission agent application and canopy shaker frequency effects on mechanical harvest efficiency of sweet orange. *Hortscience*. **2010**, *45(7)*, 1079-1083.
- Elmasry, G., Cubero, S., Moltó, E., & Blasco, J. In-line sorting of irregular potatoes by using automated computer-based machine vision system. *J. Food Eng.* **2012**, *112*, 60–68.

- FAO. (2009). Global agriculture towards 2050. Disponible online: https://www.fao.org/fileadmin/templates/wsfs/docs/Issues_papers/HLEF2050_Global_Agriculture.pdf (acceso el 10 de febrero de 2022).
- FAO. (2011). El estado de los recursos de tierras y aguas del mundo para la alimentación y la agricultura. Disponible online: <https://www.fao.org/3/i1688s/i1688s.pdf> (acceso el 10 de febrero de 2022).
- FAO. (2017). Disponible online: <http://www.fao.org/faostat/es/#data/QC> (acceso el 10 de febrero de 2022).
- FAO. (2018). The Future of Food and Agriculture: Alternative Pathways to 2050 (Summary Version). Disponible online: <https://www.fao.org/policy-support/tools-and-publications/resources-details/en/c/1259562/> (acceso el 10 de febrero de 2022).
- FAO. (2019). New standards to curb the global spread of plant pests and diseases. Disponible online: <https://www.fao.org/news/story/es/item/1188251/icode/> (acceso el 10 de febrero de 2022).
- FAO. (2021). Disponible online: <http://faostat.fao.org> (acceso el 10 de febrero de 2022).
- Fenollosa, E.A., Gual, M.V.I., Ruiz, M.H., Hurtado, M., & Jacas, J. Effect of ground-cover management on spider mites and their phytoseiid natural enemies in clementine mandarin orchards (I): Bottom-up regulation mechanisms. *Biol. Control*. **2011**, *59*, 158–170.
- Fernández, T., Pérez, J.L., Cardenal, J., Gómez, J.M., Colomo, C., & Delgado, J. Analysis of landslide evolution affecting olive groves using UAV and photogrammetric techniques. *Remote Sensing*. **2016**, *8*(10), 837.
- Fernández, T., Pérez-García, J.L., Gómez-López, J.M., Cardenal, J., Calero, J., Sánchez-Gómez, M., & Tovar-Pescador, J. Multitemporal analysis of gully erosion in olive groves by means of digital elevation models obtained with aerial photogrammetric and LiDAR data. *ISPRS International Journal of Geo-Information*. **2020**, *9*(4), 260.
- Ferreira, M. D., Sanchez, A. C. Braunbeck, O. A., & Santos, E. A. Harvesting fruits using a mobile platform: A case study applied to citrus. *Engenharia Agrícola, Jaboticabal*, **2018**, *38*, 293–9.
- Fonte, A., Garcerá, C., Tena, A., & Chueca, P. CitrusVol Validation for the Adjustment of Spray Volume in Treatments against *Tetranychus urticae* in Clementines. *Agronomy*. **2019**, *10*, 32.
- Fountas, S., Aggelopoulou, K., & Gemtos, T.A. Precision Agriculture. In *Supply Chain Management for Sustainable Food Networks*. **2016**, 41–65.
- Fraulo, A.B., Cohen, M., & Liburd, O.E. Visible/near infrared reflectance (VNIR) spectroscopy for detecting twospotted spider mite (Acari: Tetranychidae) damage in strawberries. *Environ. Entomol.* **2009**, *38*, 137–142.
- Fruticultura. (2021). Fruticultura de precisión: luces y sombras. *Fruticultura*. **2021**, *79*, 58-73.
- Futch, S.H., & Tucker, D.P.H. A Guide to Citrus Nutritional Deficiency and Toxicity Identification. University of Florida IFAS Extension Publication HS-797. 2000. Disponible online: <https://edis.ifas.ufl.edu/pdf/CH/CH14200.pdf> (acceso el 10 de febrero de 2022).
- García, E., & Flego, F. Agricultura de precisión. *Revista Ciencia y Tecnología*. **2008**.
- García-Ruiz, F., Sankaran, S., Maja, J.M., Lee, W.S., Rasmussen, J., & Ehsani, R. Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. *Computers and Electronics in Agriculture*. **2013**, *91*, 106-115.
- Gat, N. Imaging spectroscopy using tunable filters: A review. *Wavelet Appl.* **2000**, *4056*, 50–65.

- Gil, E. Design of a decision support method to determine volume rate for vineyard spraying. *Applied engineering in agriculture*. **2009**, 25(2), 145-151.
- Gomes, V., Reis, M. S., Rovira-Más, F., Mendes-Ferreira, A., & Melo-Pinto, P. Prediction of Sugar Content in Port Wine Vintage Grapes Using Machine Learning and Hyperspectral Imaging. *Processes*. **2021**, 9(7), 1241.
- Gonzalez-de-Santos, P., Ribeiro, A., Fernandez-Quintanilla, C., Lopez-Granados, F., Brandstötter, M., Tomic, S., & Perez-Ruiz, M. Fleets of robots for environmentally-safe pest control in agriculture. *Precision Agriculture*. **2017**, 18(4), 574-614.
- Gonzalez-Gonzalez, M.G., Blasco, J., Cubero, S., & Chueca, P. Automated Detection of Tetranychus urticae Koch in Citrus Leaves Based on Colour and VIS/NIR Hyperspectral Imaging. *Agronomy*. **2021**, 11(5), 1002.
- González-González, M.G., Chueca, P., Cubero, S., & Blasco, J. La irrupción de las tecnologías electrónicas y de la información. Una hoja de ruta para la citricultura española. **2020a**, 191-200.
- González-González, M. G., Chueca, P., & Ortiz, C. Evaluation of a Citrus Mobile Platform Using a Wireless Impact Recording Device. In *European Conference on Agricultural Engineering (AgEng2018)*, **2018**, (pp. 1003-1009). Wageningen University & Research.
- González-González, M.G., Gómez, J., Alegre, V., López, S., Blasco, J., Cubero, S., Soria, E., & Chueca, P. Mapping yield and quality of citrus using self-propelled platform with in-field sorting. In *the 12th European Conference on Precision Agriculture*. **2019**, 84-85.
- González-González, M.G., Gómez-Sanchis, J., Blasco, J., Soria-Olivas, E., & Chueca, P. CitrusYield: A dashboard for mapping yield and fruit quality of citrus in precision agriculture. *Agronomy*. **2020b**, 10(1), 128.
- Gracia, C. y Bernad, J.J. Carretillas autopropulsadas, un elemento que se introduce en la recolección de cítricos. *Fruticultura profesional*, **1988**, 14, 61-68.
- GRAP. (2020). Ciclo de las cuatro etapas de la Agricultura de Precisión. Disponible online: <http://www.grap.udl.cat/es/presentacion/ap.html> (acceso el 10 de febrero de **2022**).
- Gutiérrez, A., Blasco, J., Chueca, P., Garcerá, C., Alegre, S., López, S., & Moltó, E. Harvesting and in-field sorting of citrus with a self-propelled machine. In *I International Symposium on Mechanical Harvesting and Handling Systems of Fruits and Nuts*. **2012**, 965, 149-152.
- Hare, J.D. Sampling Arthropod Pests in Citrus. In *Handbook of Sampling Methods for Arthropods in Agriculture*, Pedigo, L.P., Buntin, G.D., Eds. CRC Press: Boca Raton, FL, USA. **1994**, 417-431.
- Hastie, T., Friedman, J., & Tibshirani, R. Model Assessment and Selection. In *Linear and Generalized Linear Mixed Models and Their Applications*, Springer Science and Business Media LLC: Berlin, Germany. **2001**, 193-224.
- Hawkins, D.M. The Problem of Overfitting. *J. Chem. Inf. Comput. Sci.* **2004**, 44, 1-12.
- Hernández, P., Caracterización instrumental de “frutos electrónicos” y su utilización en la evaluación de daños en las líneas de confección de cítricos. Trabajo fin de carrera, Escuela Técnica Superior de Ingenieros Agrónomos, Universitat Politècnica de València. **2000**.
- Herrmann, I., Berenstein, M., Sade, A., Karnieli, A., Bonfil, D.J., & Weintraub, P.G. Spectral monitoring of two-spotted spider mite damage to pepper leaves. *Remote. Sens. Lett.* **2012**, 3, 277-283.
- INSST. (2021). Disponible online: <https://www.insst.es/documents/94886/96076/utilizaci%C3%B3n+de+equipos+de+trabajo/8cb41928-5b07-4a9c-a29c-fe140f43320b> (acceso el 10 de febrero de **2022**).

- ISPA. (2019). Disponible online: <https://www.ispag.org/about/definition> (acceso el 10 de febrero de 2022).
- Jacas, J.A., & Urbaneja, A. Biological Control in Citrus in Spain: From Classical to Conservation Biological Control. In *Integrated Management of Arthropod Pests and Insect Borne Diseases*, Springer Science and Business Media LLC: Berlin, Germany. **2010**, 61–72.
- Jeppson, L.R., Keifer, H.H., & Baker, E.W. Mites Injurious to Economic Plants, University of California Press: Berkeley, CA, USA. **1975**.
- Jiménez-Cuesta, M. J., Cuquerella, J., & Martínez-Jávega, J. M. Determination of a color index for citrus fruit degreening. Proceedings of the *International Society of Citriculture*, Tokyo (Japan), **1981**, 2, 750–3.
- Juste, F., Martín, B., Fabado, F., & Moltó, E. Estudio sobre la reducción de los costes de producción de cítricos mediante la mecanización de las prácticas de cultivo. *Comunidad valenciana agraria*. **2000**, 12, 23-29
- Juste, F., & F. Sevilla. Citrus: An European project to study the robotic harvesting of oranges. In *Proc. 2nd Workshop Robotics in Agriculture and the Food Industry*. **1991**, 187-195.
- Jutras, P. J. & Coppock, G. E. Mechanization of citrus fruit picking. *Florida State Horticultural Society*, **1958**, 71, 201–4.
- Kise, M., Zhang, Q., & Rovira-Más, F. A stereovision-based crop row detection method for tractor-automated guidance. *Biosystems engineering*. **2005**, 90(4), 357-367.
- Kleinjan J., Clay D., Carlson G., & S. Clay. Developing productivity zone from multiple years of yield monitor data. *GIS Applications in agriculture*. **2007**, 4, 65-79.
- Kohno, Y., Kondo, N., Iida, M., Kurita, M., Shiigi, T., Ogawa, Y., Kaichi, T., & Okamoto, S. Development of a mobile grading machine for citrus fruit. *Engineering in Agriculture, Environment and Food*. **2011**, 4(1), 7–11.
- Kuhn, M., & Johnson, K. Applied Predictive Modeling 26, Springer: New York, NY, USA. **2013**.
- Kumar, T.K. Multicollinearity in Regression Analysis. *Rev. Econ. Stat.* **1975**, 57, 365.
- Kurtulmus, F., Lee, W.S., & Vardar, A. Green citrus detection using ‘eigenfruit’, color and circular Gabor texture features under natural outdoor conditions. *Computers and Electronics in Agriculture*. **2011**, 78(2), 140-149.
- Landgrebe, D. Hyperspectral image data analysis. *IEEE Signal Process.* **2002**, 19, 17–28.
- Leaflet package for R. (2022). Disponible online: <https://rstudio.github.io/leaflet/> (acceso el 10 de febrero de 2022).
- Leroux, C., Jones, H., Pichon, L., Guillaume, S., Lamour, J., Taylor, J., & Tisseyre, B. GeoFIS: An open source, decision-support tool for precision agriculture data. *Agriculture*. **2018**, 8(6), 73.
- Li, M., Imou, K., Wakabayashi, K., & Yokoyama, S. Review of research on agricultural vehicle autonomous guidance. *International Journal of Agricultural and Biological Engineering*. **2009**, 2(3), 1-16.
- Li, X., Lee, W.S., Li, M., Ehsani, R., Mishra, A.R., Yang, C., & Mangan, R.L. Feasibility study on Huanglongbing (citrus greening) detection based on WorldView-2 satellite imagery. *Biosystems Engineering*. **2015**, 132, 28-38.
- Lima-Cueto, F.J., Blanco-Sepúlveda, R., Gómez-Moreno, M.L., & Galacho-Jiménez, F.B. Using vegetation indices and a UAV imaging platform to quantify the density of vegetation ground cover in olive groves (*Olea Europaea* L.) in Southern Spain. *Remote Sensing*. **2019**, 11(21), 2564.

- Llorens, J., Gil, E., & Llop, J. Ultrasonic and LIDAR sensors for electronic canopy characterization in vineyards: Advances to improve pesticide application methods. *Sensors*. **2011**, *11*(2), 2177-2194.
- López-Granados, F., Jurado-Expósito, M., Alamo, S., & Garcia-Torres, L. Leaf nutrient spatial variability and site-specific fertilization maps within olive (*Olea europaea* L.) orchards. *European Journal of Agronomy*. **2004**, *21*(2), 209-222.
- Lorente, D., Aleixos, N., Gomez-sanchis, J., Cubero, S., García-Navarrete, O.L., & Blasco, J. Recent Advances and Applications of Hyperspectral Imaging for Fruit and Vegetable Quality Assessment. *Food Bioprocess Technol.* **2012**, *5*, 1121–1142.
- Lowenberg-DeBoer, J., & Swinton, S.M. Economics of site-specific management in agronomic crops. *The state of site specific management for agriculture*. **1997**, 369-396.
- Lu, R., Pothula, A. K., Vandyke, M., Mizushima, A., & Zhang, Z. System for sorting fruit. U.S. Patent 15/256,931. **2016**.
- Lu, R., Zhang, Z., & Pothula, A. K. Innovative technology for apple harvest and in-field sorting. *Fruit Quarterly*, **2017**, *25*(2), 11–14.
- Mantovani, E.C., & Magdalena, C. Manual de agricultura de precisión. *Embrapa Milho e Sorgo-Livro científico (ALICE)*. **2014**.
- MAPA. Ministerio de Agricultura, Pesca y Alimentación. (2022a). Disponible online: https://www.mapa.gob.es/en/agricultura/temas/producciones-agricolas/frutas-y-hortalizas/Informacion_subsectorial.aspx (acceso el 10 de febrero de **2022**).
- MAPA. Ministerio de Agricultura, Pesca y Alimentación. (2022b). Disponible online: <https://www.mapa.gob.es/es/agricultura/temas/medios-de-produccion/maquinaria-agricola/> (acceso el 10 de febrero de **2022**).
- Martin, D.E., & Latheef, M.A. Remote Sensing Evaluation of Two-spotted Spider Mite Damage on Greenhouse Cotton. *J. Vis. Exp.* **2017**, *122*, e54314.
- Martin, J.M., & Pérez, P.P. Libro blanco de la agricultura y el desarrollo rural. **2004**.
- Martínez-Ferrer, M.T., Jacas, J.A., Ripollés-Moles, J.L., & Aucejo-Romero, S. Approaches for Sampling the Twospotted Spider Mite (Acari: Tetranychidae) on Clementines in Spain. *J. Econ. Entomol.* **2006**, *99*, 1490–1499.
- Mateu, G., Caballero, P., Torregrosa, A., Segura, B., Juste, F., & Chueca, P. Análisis de la influencia de las operaciones de cultivo sobre los costes de producción en la citricultura de la Comunidad Valenciana. *Levante Agrícola*, **2018**, *440*, 60-64.
- Mateu, G., Torregrosa, A., Juste, F., Castro, S., Arenas, F.J., Hervalejo, A., & Chueca, P. Recolección mecanizada de cítricos: equipos y características de las plantaciones para su uso. *Levante Agrícola*. **2017**, *435*, 63-68.
- Mehmood, T., Liland, K.H., Snipen, L., & Sæbø, S. A review of variable selection methods in Partial Least Squares Regression. *Chemom. Intell. Lab. Syst.* **2012**, *118*, 62–69.
- Mehta, S. S., & Burks, T. F. Vision-based control of robotic manipulator for citrus harvesting. *Computers and Electronics in Agriculture*. **2014**, *102*, 146-158.
- Miller, W. M., & Wagner, C. Florida citrus packing line studies with an instrumented sphere. *Applied Engineering in Agriculture*, **1991**, *7*(5), 577-581.
- Modesti, M., & Mateus, S. Sistemas de guiado para colaboración en navegación de vehículos autónomos (AGV). In 6th Meeting of National and International Researchers. **2008**.

- Molin, J.P., & Mascarín, L.S. Colheita de citros e obtenção de dados para mapeamento da produtividade. *Engenharia Agrícola*. **2007**, 27(1), 259-266.
- Montero, F., Brasa, A., Montero-García, F., & Orozco, L. Redes de sensores inalámbricas para Viticultura de Precisión en Castilla-La Mancha. *Actas de Horticultura [SECH]*. **2007**, 48, 158-160.
- Moreno, R., Torregrosa, A., Molto, E., & Chueca, P. Effect of harvesting with a trunk shaker and an abscission chemical on fruit detachment and defoliation of citrus grown under Mediterranean conditions. *Spanish Journal of Agricultural Research*. **2015**, 13(1), 1-12.
- Moriya, É., Imai, N.N., Tommaselli, A.M.G., Berveglieri, A., Honkavaara, E., Soares, M.A., & Marino, M. Detecting citrus Huanglongbing in Brazilian orchards using hyperspectral aerial images. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*. **2019**.
- Mousazadeh, H. A technical review on navigation systems of agricultural autonomous off-road vehicles. *Journal of Terramechanics*. **2013**, 50(3), 211-232.
- Munera, S., Amigo, J.M., Aleixos, N., Talens, P., Cubero, S., & Blasco, J. Potential of VIS-NIR hyperspectral imaging and chemometric methods to identify similar cultivars of nectarine. *Food Control*. **2018**, 86, 1–10.
- Muscato, G., Prestifilippo, M., Abbate, N., & Rizzuto, I. A prototype of an orange picking robot: past history, the new robot and experimental results. *Industrial Robot: An International Journal*. **2005**.
- National Research Council. Precision agriculture in the 21st century: geospatial and information technologies in crop management. Washington DC, USA: National Academy Press. **1997**.
- Nieuwenhuizen, A., Kool, J., Suh, H., & Hemming, J. Automated spider mite damage detection on tomato leaves in greenhouses. *Acta Horti*. **2020**, 1268, 165–172.
- Ortiz, C., Blasco, J., Balasch, S., & Torregrosa, A. Shock absorbing surfaces for collecting fruit during the mechanical harvesting of citrus. *Biosystems engineering*, **2011**, 110(1), 2-9.
- Pascual-Ruiz, S., Aguilar-Fenollosa, E., Ibáñez-Gual, V., Hurtado-Ruiz, M.A., Martínez-Ferrer, M.T., Jacas, J.A., & Jaques, J.A. Economic threshold for *Tetranychus urticae* (Acari: Tetranychidae) in clementine mandarins *Citrus clementina*. *Exp. Appl. Acarol.* **2013**, 62, 337–362.
- Pelayo, D. A. M., & Duarte, D. M. G. Diseño e implementación de un sistema de riego en un cultivo de cítricos. *Revista Matices Tecnológicos*, **2019**, 9.
- Peng, H., Huang, B., Shao, Y., Li, Z., Zhang, C., Chen, Y., & Xiong, J. General improved SSD model for picking object recognition of multiple fruits in natural environment. *Transactions of the Chinese Society of Agricultural Engineering*. **2018**, 34(16), 155-162.
- Pérez Lluch, B. Evaluación de los daños producidos a la fruta en la recolección mediante una plataforma de recogida de cítricos. Trabajo Fin de Máster, Universitat Politècnica de València. **2018**.
- Pérez-Ruiz, M., Agüera, J., Gil, J.A., & Slaughter, D.C. Optimization of agrochemical application in olive groves based on positioning sensor. *Precision Agriculture*. **2011**, 12(4), 564-575.
- Pérez-Ruiz, M., Apolo-Apolo, O.E., & Egea, G. DronFruit: inteligencia artificial para la estimación de producción en cítricos. *Fruticultura*. **2021**, 79, 74-79.

- Pierce, F.J., Robert, P.C., & Mangold, G. Site specific management: The pros, the cons, and the realities. In *Proceedings of the International Crop Management Conference, Iowa State University*. **1994**, 17-21.
- Pierce, F.J., & Sadler, E.J. The State of Site-Specific Management for Agriculture. The State of Site-Specific Management for Agriculture. *American Society of Agronomy, Crop Science Society of America, Soil Science Society of America*. **1997**.
- Ping, J.L., & Dobermann, A. Processing of yield map data. *Precision Agriculture*. **2005**, 6(2), 193-212.
- Plant, R. E. Site-specific management: the application of information technology to crop production. *Computers and electronics in agriculture*. **2001**, 30(1-3), 9-29.
- Plotly package for R. (2022). Disponible online: <https://cran.r-project.org/web/packages/plotly/index.html> (acceso el 10 de febrero de **2022**).
- Pourreza, A., Lee, W.S., Ehsani, R., Schueller, J.K., & Raveh, E. An optimum method for real-time in-field detection of Huanglongbing disease using a vision sensor. *Computers and Electronics in Agriculture*. **2015**, 110, 221-232.
- Qiang, L., Jianrong, C., Bin, L., Lie, D., & Yajing, Z. Identification of fruit and branch in natural scenes for citrus harvesting robot using machine vision and support vector machine. *International Journal of Agricultural and Biological Engineering*. **2014**, 7(2), 115-121.
- Qiao, J., Sasao, A., Shibusawa, S., Kondo, N., & Morimoto, E. Mapping yield and quality using the mobile fruit grading robot. *Biosystems engineering*. **2005**, 90(2), 135-142.
- Quiñones, A., Martínez-Alcántara, B., Primo-Millo, E., & Legaz, F. Fertigation: Concept and Application in Citrus. In *Advances in Citrus Nutrition*, Springer Science and Business Media LLC: Berlin, Germany. **2012**, 281–301.
- R Software. (2022). Disponible online: <https://www.r-project.org/> (acceso el 10 de febrero de **2022**).
- Ramos, M.I., Gil, A.J., Feito, F.R., & García-Ferrer, A. Using GPS and GIS tools to monitor olive tree movements. *Computers and electronics in agriculture*. **2007**, 57(2), 135-148.
- Recce, M., Taylor, J., Plebe, A., & Tropicano, G. Vision and neural control for an orange harvesting robot. In *Proceedings of International Workshop on Neural Networks for Identification, Control, Robotics and Signal/Image Processing*. **1996**, 467-475.
- Reid, N.J. ES&T Views: Remote Sensing and Forest Damage. *Environmental science & technology*. **1987**, 21(5), 428-429.
- Rey, B., Aleixos, N., Cubero, S., & Blasco, J. Xf-Rovim. A Field Robot to Detect Olive Trees Infected by Xylella Fastidiosa Using Proximal Sensing. *Remote. Sens.* **2019**, 11, 221.
- Rinnan, Å., Berg, F.V.D., & Engelsen, S.B. Review of the most common pre-processing techniques for near-infrared spectra. *TrAC Trends Anal. Chem.* **2009**, 28, 1201–1222.
- Rivera, N.V., Gómez-Sanchis, J., Chanona-Pérez, J., Carrasco, J.J., Millán-Giraldo, M., Lorente, D., Cubero, S., & Blasco, J. Early detection of mechanical damage in mango using NIR hyperspectral images and machine learning. *Biosyst. Eng.* **2014**, 122, 91–98.
- Robert, P.C. Site-specific Management for the Twenty-first Century. *HortTechnology*. **2000**, 10(3), 444-447.
- Rock, B.N., Vogelmann, J.E., Williams, D.L., & Hoshizaki, T. Remote Detection of Forest Damage. *Biosci.* **1986**, 36, 439–445.

- Roka, F.M., Ehsani, R.J., Futch, S.H., & Hyman, B.R. Citrus mechanical harvesting systems-Continuous canopy shakers. Florida: *Food and Economic Resources Department*. **2014**.
- Román, C., Llorens, J., Uribeetxebarria, A., Sanz, R., Planas, S., & Arnó, J. Spatially variable pesticide application in vineyards: Part II, field comparison of uniform and map-based variable dose treatments. *Biosystems Engineering*. **2020**, *195*, 42-53.
- Rovira-Más, F. Recent innovations in off-road intelligent vehicles: in-field automatic navigation. *Recent Patents on Mechanical Engineering*. **2009**, *2*(3), 169-178.
- Rovira-Más, F., Millot, C., & Sáiz-Rubio, V. Navigation strategies for a vineyard robot. In *2015 ASABE annual international meeting* (p. 1). *American Society of Agricultural and Biological Engineers*. **2015**.
- Roy, P.S. Spectral reflectance characteristics of vegetation and their use in estimating productive potential. *Plant Sci*. **1989**, *99*, 59–81.
- Saiz-Rubio, V., Rovira-Más, F., Cuenca-Cuenca, A., & Alves, F. Robotics-based vineyard water potential monitoring at high resolution. *Computers and Electronics in Agriculture*. **2021**, *187*, 106311.
- Sanz, R., Llorens, J., Escolà, A., Arnó, J., Planas, S., Roman, C., & Rosell-Polo, J.R. LIDAR and non-LIDAR-based canopy parameters to estimate the leaf area in fruit trees and vineyard. *Agricultural and forest meteorology*. **2018**, *260*, 229-239.
- Schueller, J.K., Whitney, J.D., Wheaton, T.A., Miller, W.M., & Turner, A.E. Low-cost automatic yield mapping in hand-harvested citrus. *Computers and Electronics in Agriculture*. **1999**, *23*(2), 145-153.
- Seamount, D. T. & Opitz, K. W. The Sunkist 2C platform harvester. *Citrograph*, **1973**, *59*, 55–8.
- Sengupta, S., & Lee, W.S. Identification and determination of the number of immature green citrus fruit in a canopy under different ambient light conditions. *Biosystems Engineering*. **2014**, *117*, 51-61.
- Shalal, N., Low, T., McCarthy, C., & Hancock, N. A review of autonomous navigation systems in agricultural environments. **2013**.
- Shiny package for R. (2022). Disponible online: <https://shiny.rstudio.com> (acceso el 10 de febrero de **2022**).
- Shiny widgets gallery. (2022). Disponible online: <https://shiny.rstudio.com/gallery/widget-gallery.html> (acceso el 10 de febrero de **2022**).
- Shinydashboard package for R. (2022). Disponible online: <https://rstudio.github.io/shinydashboard/> (acceso el 10 de febrero de **2022**).
- Soler-Salcedo, E., Rodrigo, E., & Ferragut, F. Colonización, comportamiento alimenticio y producción de daños en las arañas rojas *Tetranychus urticae* y *T. turkestanii* (Acari: Tetranychidae). *Boletín Sanid. Veg. Plagas*. **2006**, *32*, 523–534.
- Stafford, J.V. Essential technology for precision agriculture. In *Proceedings of the Third International Conference on Precision Agriculture*. **1996**, 593-604. Madison, WI, USA: American Society of Agronomy, Crop Science Society of America, Soil Science Society of America.
- Statista. (2017a). Disponible online: <https://es.statista.com/estadisticas/508983/produccion-mundial-de-naranjas/> (acceso el 10 de febrero de **2022**).

- Statista. (2017b). Disponible online: <https://es.statista.com/estadisticas/501272/produccion-mundial-de-mandarinas-clementinas-satsumas/> (acceso el 10 de febrero de **2022**).
- Statista. (2020a). Disponible online: <https://es.statista.com/estadisticas/1219179/agricultura-volumen-de-exportacion-de-espana-por-producto/> (acceso el 10 de febrero de **2022**).
- Statista. (2020b). Disponible online: <https://es.statista.com/estadisticas/1037130/evolucion-mensual-del-precio-de-un-litro-de-gasoleo-para-uso-agricola-en-espana/> (acceso el 10 de febrero de **2022**).
- Statista. (2022). Evolución de la población mundial desde 1950 hasta 2050. Disponible online: <https://es.statista.com/estadisticas/635122/evolucion-de-la-poblacion-mundial/> (acceso el 10 de febrero de **2022**).
- Sudduth, K.A., & Drummond, S.T. Yield editor. *Agronomy Journal*. **2007**, 99(6), 1471-1482.
- Sumner, H.R. Selective harvesting of Valencia oranges with a vertical canopy shaker. *System*. **1970**.
- Tagliavini, M., & Quiñones, A. Nutrizione e Concimazione. In *Glo Agrumi*, Tribulato, E., Inglese, P., Eds., Bayer CropScience: Milano, Italy. **2012**, 183–193.
- Tan, L., Haley, R., & Wortman, R. Cloud-based harvest management system for specialty crops. In *2015 IEEE Fourth Symposium on Network Cloud Computing and Applications (NCCA)*. **2015**, 91-98.
- Tao, Y., Zhou, J., Wang, K., & Shen, W. Rapid detection of fruits in orchard scene based on deep neural network. In *Proc. ASABE Annu. Int. Meeting*. **2018**.
- Tennes B., Zapp H., Armstrong P., & Marshall D. Combined impact sensing and data acquisition units for studies of bruising during handling of fruits and vegetables. *Journal of Agricultural Engineering Research*. **1991**, 49, 189-196.
- Torregrosa, A., Ortí, E., Martín, B., Gil, J., & Ortiz, C. Mechanical harvesting of oranges and mandarins in Spain. *Biosystems engineering*. **2009**, 104(1), 18-24.
- Torres, L.G., Peña-Barragán, J.M., López-Granados, F., Jurado-Expósito, M., & Fernández-Escobar, R. Automatic assessment of agro-environmental indicators from remotely sensed images of tree orchards and its evaluation using olive plantations. *Computers and Electronics in Agriculture*. **2008**, 61(2), 179-191.
- Urbaneja, A., Catalán, J., Tena, A., & Jacas, J.A. Plagas y Enfermedades. Tetránquidos. Araña Roja. In *Gestión Integrada de Plagas de Cítricos*, Urbaneja, A., Catalán, J., Tena, A., Jacas, J.A., Eds., IVIA: Moncada, España, 2020. Disponible online: <http://gipcitricos.ivia.es/area/plagas-principales/tetraniquidos/arana-roja> (acceso el 10 de febrero de **2022**).
- Urbaneja, A., Pascual-Ruiz, S., Pina, T., Abad-Moyano, R., Vanaclocha, P., Montón, H., Dembilio, Óscar, Castañera, P., Jacas, J.A., & Jaques, J.A. Efficacy of five selected acaricides against *Tetranychus urticae* (Acari: Tetranychidae) and their side effects on relevant natural enemies occurring in citrus orchards. *Pest Manag. Sci.* **2008**, 64, 834–842.
- US House of representatives. US code Title 7-Agriculture. Chapter 103-Agricultural research, extension, and education reform. Subchapter II-New agricultural research, extension, and education initiatives. Section 7623. (a) Definitions. Washington, USA: US. **2002**.
- Uva, M., & Campanella, O. AP-SIG: un SIG con funciones específicas para Agricultura de Precisión. In *XI Workshop de Investigadores en Ciencias de la Computación*. **2009**.
- Uygun, T., Ozguven, M.M., & Yanar, D. A new approach to monitor and assess the damage caused by two-spotted spider mite. *Exp. Appl. Acarol.* **2020**, 82, 335–346.
- Van Canneyt, T., Tijssens, E., Ramon, H., Verschoore, R., & Sonck, B. Characterisation of a potato-shaped instrumented device. *Biosystems Engineering*, **2003**, 86(3), 275-285.

- Van Leeuwen, T., Vontas, J., Tsagkarakou, A., Dermauw, W., & Tirry, L. Acaricide resistance mechanisms in the two-spotted spider mite *Tetranychus urticae* and other important Acari: A review. *Insect Biochem. Mol. Biol.* **2010**, *40*, 563–57.
- Vidal, A., Talens, P., Prats-Montalbán, J. M., Cubero, S., Albert, F., & Blasco, J. In-line estimation of the standard colour index of citrus fruits using a computer vision system developed for a mobile platform. *Food and Bioprocess Technology*, **2013**, *6(12)*, 3412–19.
- Vinzi, V.E., Chin, W.W., Henseler, J., & Wang, H. *Handbook of Partial Least Squares*, Springer: Berlin, Germany. **2010**.
- Whelan, B.M., & McBratney, A.B. The “null hypothesis” of precision agriculture management. *Precision Agriculture*. **2000**, *2(3)*, 265-279.
- Whitney, J.D. Trunk shaker and abscission chemical effects on yields, fruit removal, and growth of orange trees. In *Proceedings of the Florida State Horticultural Society*. **2003**, 116, 230-235.
- Whitney, J. D., Hyman, B. R., & Roka, F. M. The past, present and future of citrus mechanical harvesting. *Acta Horticulturae*, **2012**, *965*, 183–8.
- Whitney, J.D., & Wheaton, T.A. Shakers affect Florida orange fruit yields and harvesting efficiency. *Applied Engineering in Agriculture*. **1987**, *3(1)*, 20-24.
- Wilson, J.N. Guidance of agricultural vehicles—a historical perspective. *Computers and electronics in agriculture*. **2000**, *25(1-2)*, 3-9.
- Zagórda, M., & Walczykova, M. The application of various software programs for mapping yields in precision agriculture. In *BIO Web of Conferences. EDP Sciences*. **2018**, *10*, 01018.
- Zarco-Tejada, P.J., Berjón, A., López-Lozano, R., Miller, J.R., Martín, P., Cachorro, V., & De Frutos, A. Assessing vineyard condition with hyperspectral indices: Leaf and canopy reflectance simulation in a row-structured discontinuous canopy. *Remote Sensing of Environment*. **2005**, *99(3)*, 271-287.
- Zekri, M., & Obreza, T. Manganese (Mn) and Zinc (Zn) for Citrus Trees. Publication #SL403 of the Department of Soil and Water Sciences, UF/IFAS Extension. 2019. Disponible online: <https://edis.ifas.ufl.edu/pdf/SS/SS61600.pdf> (acceso el 10 de febrero de **2022**).
- Zhang, Z. Design, test, and improvement of a low-cost apple harvest-assist unit. PhD diss. University Park, PA: Pennsylvania State University, Department of Agricultural and Biological Engineering. **2015**.
- Zhang, Z., Pothula, A. K., & Lu, R. Development and preliminary evaluation of a new bin filler for apple harvesting and in-field sorting machine. *Transactions of the ASABE*, **2017a**, *60(6)*, 1839–49.
- Zhang, Z., Pothula, A. K., & Lu, R. Economic evaluation of apple harvest and in-field sorting technology. *Transactions of the ASABE*, **2017b**, *60(5)*, 1537–50.
- Zhang, Z., Pothula, A. K., & Lu, R. A review of bin filling technologies for apple harvest and postharvest handling. *Applied Engineering in Agriculture*, **2018**, *34(4)*, 687–703.



Anexo I

Artículos científicos

ANEXO I – ARTÍCULOS CIENTÍFICOS

1. **González-González, M. G.,** Gómez-Sanchis, J., Blasco, J., Soria-Olivas, E., & Chueca, P. (2020). CitrusYield: A Dashboard for Mapping Yield and Fruit Quality of Citrus in Precision Agriculture. *Agronomy*, 10(1), 128.



Article

CitrusYield: A Dashboard for Mapping Yield and Fruit Quality of Citrus in Precision Agriculture

María Gyomar González-González ¹, Juan Gómez-Sanchis ², Jose Blasco ¹, Emilio Soria-Olivas ² and Patricia Chueca ^{1*}

¹ Centro de Agroingeniería, Instituto Valenciano de Investigaciones Agrarias (IVIA), CV-315, km 10,7, 46113 Moncada, Valencia, Spain; gyomar.glez@gmail.com (M.G.G.-G.); blasco_josiva@gva.es (J.B.)

² Intelligent Data Analysis Laboratory (IDAL), Escola Tècnica Superior d'Enginyeria, Universitat de València, Avinguda de la Universitat, 46100 Burjassot, Valencia Spain; Juan.Gomez-Sanchis@uv.es (J.G.-S.); emilio.soria@uv.es (E.S.-O.)

* Correspondence: chueca_pat@gva.es

Received: 25 November 2019; Accepted: 13 January 2020; Published: 15 January 2020

Abstract: The application of new technologies in precision agriculture offers the possibility to link information to very specific crop locations. The spatial representation of these agricultural data through yield and fruit quality maps allows for crop management in a precise way that means that agricultural operations may be carried out considering intraorchard variability, thus resulting in greater efficiency. The aim of this work was to advance the development of new tools for the generation of yield and quality maps for precision agriculture. A new tool was implemented for citrus through a dashboard called CitrusYield that integrates the requirements demanded by technicians and farmers in terms of spatial distribution and the quality of their citrus production. The data for testing were collected by a prototype of a citrus harvest-assist platform. In order to obtain maps showing heterogeneity of production, an experimental plot with different varieties and variable production was chosen. The maps, tables and graphs showing different crop data were generated automatically by CitrusYield from the analysis of the data collected. The main advantage of knowing the differences in production between the swaths and areas inside the crop is to provide the grower with precise information to make accurate decisions for localised crop management, such as fertilisation, irrigation, pest and disease control, etc.

Keywords: ICT; GIS; IoT; R software; data analysis; spatial variability

1. Introduction

Citrus is one of the most important crops in the world. According to data from the United Nations Food and Agriculture Organization (FAO), in 2017 there were a total of 148 citrus-producing countries [1] and the world production reached almost 50 million tonnes for oranges [2] and almost 30 million for mandarins, tangerines and satsumas [3]. Spain leads the world ranking of citrus exports for consumption as fresh fruit and is the sixth-largest producer worldwide [4].

Information about quality and production in the citrus sector is one of the most important factors affecting the commercial value of fruit, but the generation of maps representing spatial variability has been not widely developed due to the fact that the harvest is mainly carried out manually. Therefore, only the data for yield per orchard is obtained [5]. Just a few systems and techniques have been developed to monitor data and generate maps of citrus crops. Specifically, Schueller et al. [6] developed and evaluated a low-cost yield mapping system for citrus and Molin et al. [7] generated productivity maps by weighing the bags of harvested fruit in the field.

Both methods used the data obtained from the manual harvesting of the fruit, which is currently the predominant system for harvesting in the case of fruit destined for the fresh fruit market. This harvesting method accounts for between 30% and 50% of the total costs of production, depending on the species and method of cultivation [8]. In order to reduce costs and ensure profitable production for farmers, a number of solutions have been proposed to allow for the mechanisation of harvesting, such as harvest-assist platforms for citrus to be commercialised for consumption as fresh fruit [9–11] and trunk and canopy shakers for citrus to be used for industry [12].

Mechanised harvesting offers a great advantage when it comes to calculating citrus production, as it allows technology to be incorporated into harvest-assist machines together with sensors for carrying out complementary tasks, such as fruit counting, weighing, classification or the extraction of quality parameters. The development of field inspection systems makes it possible to characterise the quality (colour, size, rot) and the production during harvesting. This information, together with the location data obtained with a global navigation satellite system (GNSS), makes it easier to georeference each fruit and associate it with its properties [13]. The joint generation of yield and fruit quality maps, together with information on conditioning factors that may affect the crop, such as crop health, soil properties, the presence of diseases and pests or climatic data, allow farms to be managed more efficiently.

The use of information and communication technologies (ICT) in precision agriculture makes it possible to optimise the management of farms. One of the main tools used in precision agriculture to present information to farmers is the creation of maps to evaluate the spatial variability present in the field [14]. Such maps are a key tool due to their usefulness both in the development and in the evaluation of precision management strategies [15]. The spatial representation of crop data through maps is one of the most effective techniques for offering farmers information in a useful and understandable way.

The maps are generated from the georeferencing information obtained in the field using geographic information systems (GIS). These systems are specific computer tools that, by means of spatially-referenced information, make it possible to import, georeference, manipulate and display a large amount of data in various forms (graphs, figures, maps, etc.) [16]. At present, there are many GIS and also agricultural management applications with built-in GIS modules (i.e. QGIS, AFS, ArcGIS, Trimble Ag) for the management of spatial data. These applications are used to provide precision agriculture information to agricultural producers [17]. However, the basic visualisation functions they provide may not be sufficient for later decision-making, which makes it necessary to create new tools with more advanced functions for converting the data obtained by the sensors into information that is useful and practical to the farmer in an easy and accessible way. For this reason, some researchers have started to develop custom tools with integrated GIS modules for precision agriculture [18–21].

In the specific case of calculating and mapping citrus production, there are very few tools available that are dedicated to the explicit processing of this information. The existing commercial GIS tools mentioned above do not have algorithms for calculating production, classifying by quality-related categories, georeferencing the categorised information on maps and the statistical analysis of information for delimited areas within the crop itself, which prevents immediate differential management of the orchard. Some researchers have developed tools for calculating production, but their market penetration is still relatively low. For example, the Crop Auditor program developed by Ampatzidis et al. [22] processes the information obtained based on the weight of each of the boxes of fruit harvested manually and the georeferences according to the location of the boxes.

The aim of this work was the generation of a new smart tool to create yield and fruit quality maps through a new dashboard called CitrusYield. This tool converts agricultural data into information that is useful for farm management. To demonstrate the performance of this tool, tests were carried out using a citrus harvest-assist platform. The sensors installed on the platform captured information about both the crop and the machine performance during the mechanised harvesting of orange and tangerine. The information was analysed by this tool through specific algorithms and statistical analyses and converted into graphs and practical maps.

2. Materials and Methods

2.1. Data Acquisition

The data were acquired from a prototype harvest-assist platform created at the Valencian Institute of Agricultural Research (IVIA), Moncada (Valencia), Spain (Figure 1).



Figure 1. Prototype of a self-propelled harvest-assist platform.

This prototype allows for the individualisation of all collected fruit as they move through the conveyor belts and incorporates an artificial vision system for inspecting the external quality of all of the produce while it is harvested. The features inspected by the vision system are size, shape and colour [23]. In addition, this prototype has two outlets to separate the fruit into two commercial categories (output bin 1 and output bin 2). Those fruits that did not achieve a commercial category because they did not reach the minimum size were sent to the output bin 2, while the rest were delivered to the output bin 1.

The computer vision is composed of bi-conic rollers to transport the fruit so that they rotate under the cameras in order to capture the complete surface of the fruits, two colour cameras, and an encoder to identify and track the exact position of every individual fruit.

The computer vision system captured four views of each fruit while the fruit rotated under the cameras. To separate the fruit from the background in the images, a green and blue (G/B) band ratio based on the red-green-blue (RGB) value of each pixel was used. Only those pixels with a value greater than the threshold are considered to belong to the fruit. This ratio was chosen due to the relatively low blue and high green values of the fruit at all stages of maturity.

The citrus colour index (CCI) [24] was used to estimate the standard colour of the fruit, calculated according to Equation (1), where L , a and b are the coordinates of the Hunter Lab colour space. The average RGB value of each partial view of the fruit was calculated during the previous segmentation process. Then, it was converted into HunterLab coordinates to obtain the partial CCI. The CCI of the fruit is calculated as the average of the four images of the fruit [25].

$$CCI = (1000 \times a) / (L \times b) \quad (1)$$

where L , a , and b are colour coordinates in the HunterLab colour space.

To optimize and speed up the process, the fruit size was estimated from the sum of all the pixels, considered as belonging to the fruit when the image was segmented. Then, the diameter was calculated using Equation (2) for the area:

$$d = 2 \times \sqrt{(A/\pi)} \tag{2}$$

where d is the estimated fruit diameter (size) and A is the area calculated as the number of pixels in the fruit. Finally, the fruit size was calculated as the average of the partial sizes of each image acquired from the same fruit [13].

The system was calibrated to measure colour and diameter using 225 oranges cv. 'Navelina' covering all range of colours and sizes. The colour of each fruit was measured in two different locations using a colorimeter (Minolta C400, Konica Minolta Opto Inc., Tokyo, Japan) and the equatorial diameter of each fruit was measured using a digital calliper. The coefficient of determination (R^2) between the references and the measurements given by the vision system were calculated, achieving values of 0.918 and 0.993 for the CCI and the size, respectively.

In order to be able to georeference each fruit for this work, a GNSS was installed on the prototype (Hiper SR, Topcon Positioning Systems, Tokyo, Japan). The geolocation frequency was set to 1 Hz. The exact time was also recorded with a precision of milliseconds to synchronise the geographical information and the acquisition of the images using a timestamp method. The GNSS receiver used real-time kinematic (RTK) positioning to enhance the precision of the location data obtained. This was achieved using a real-time communication between this receiver (rover station) and a base station through the mobile telephone network. This way, a precision of 10 mm (H) and 15 mm (V) was achieved. The measurements captured can be seen in Table 1.

Table 1. Measurements obtained by the harvest-assist platform.

Measurement	Source	Datatype	Meaning
Diameter	Fruit images	Numeric	Maximum diameter of the equatorial section of the fruit
Colour Index (CCI)	Fruit images	Numeric	Number assigned according to the colouring of the fruit epidermis
Camera	Prototype	Factor	Camera that acquires the image
Channel	Prototype	Factor	Channel through which the fruit arrives at the vision system
Output	Prototype	Factor	Output bin in which the classified fruit is stored

2.2. Field Tests

Field tests were carried out using the prototype of a mobile harvest-assist platform. For the trials, a citrus plot with a spatially varied production in harvest, size and colour was required. Thus, an experimental plot producing different varieties of orange was selected in Moncada (Valencia), Spain (World Geodetic System 1984 (WGS84) [26]: W: 39.585186, N: -0.397901). This plot had a distance of 6 m between crop lines and 4 m between trees within the same crop line. During the tests, a set of trees belonging to three adjacent swaths was harvested. In each swath, the fruits located on the sides facing the prototype movement were harvested. Figure 2 shows the harvesting scheme in the plot.

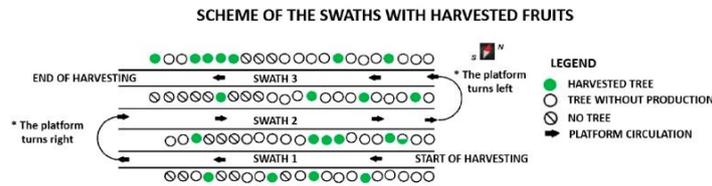


Figure 2. Harvesting scheme in plot.

After the field tests, the file with the location data recorded by the Global Positioning System (GPS) and the files created by the vision system of the prototype were obtained and analysed.

For the data analysis and display, a dashboard called CitrusYield was developed using the open source R software [27]. CitrusYield was developed to allow the introduction and processing of different quantitative input variables, producing information about the crop and the harvesting process. The information was processed and analysed by CitrusYield (Figure 3), which provides (1) a spatial database where each fruit is linked to its location and characteristics; (2) maps of the production and features of the production; (3) an exploratory data analysis (EDA) representing the information analysed in plots, box diagrams and histograms with density curves; and (4) the calculation of a series of parameters for the spatial analysis of the yield of the harvest process and the prototype performance, as a quality indicator of the inspected fruit, the performance of the prototype vision system, a productivity indicator and the working capacity of the prototype.

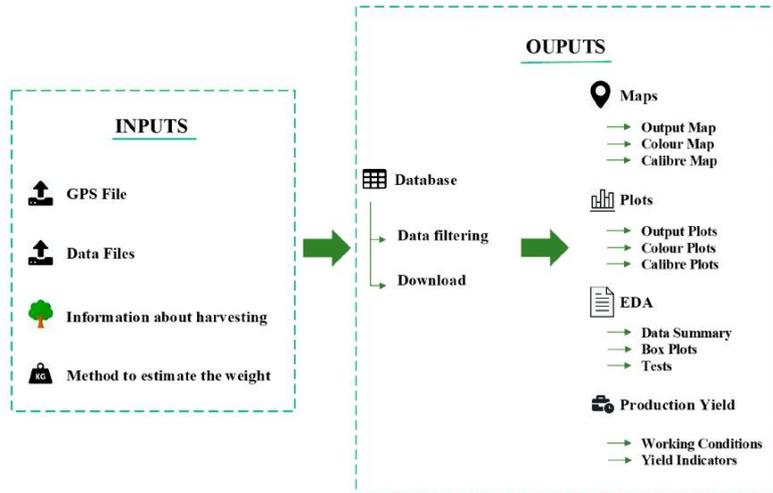


Figure 3. Features analysed by CitrusYield. EDA (exploratory data analysis), GPS (Global Positioning System).

2.3. Inputs in the CitrusYield Dashboard

Information about the crop and the harvesting process was inserted in the dashboard (Figure 4).

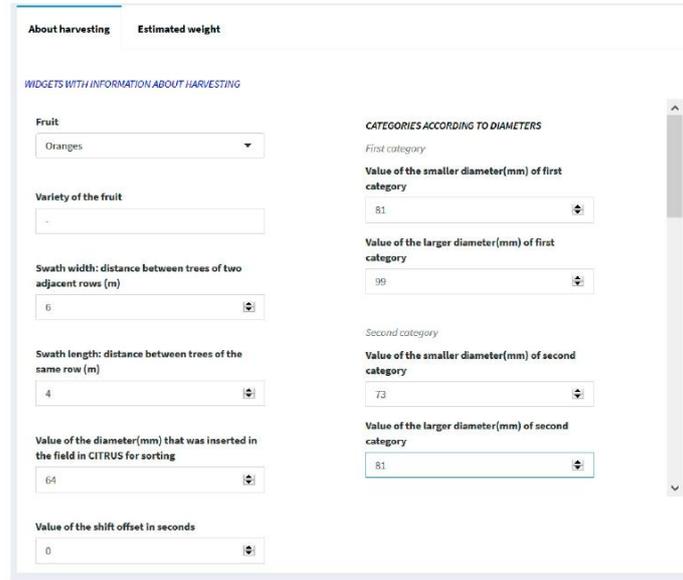


Figure 4. Screenshot of the information about harvesting that was filled in.

The size categories were established according to the Commission Delegated Regulation (EU) 2019/428, which are shown in Table 2.

Table 2. Diameter intervals for each category.

Categories	Diameter	Calibre
First	81–99	1–3
Second	73–81	4–5
Third	70–73	6
Fourth	67–70	7
Fifth	64–67	8
Sixth	0–64	-
Seventh	99–150	-

In addition, the estimation of the weight of the fruit as a function of the diameter was included. The weight was calculated based on a linear regression equation depending on the type of citrus being harvested (oranges or mandarins). In order to obtain the coefficients of the variables, a test was carried out using 200 fruits for each cultivar. In this test, the diameter of the equatorial section of each fruit was measured and the fruits were weighed. For oranges, Equation (3) was obtained with oranges cv. 'Navelfoios' ($R^2 = 0.94$) and Equation (4) was obtained for mandarins based on a trial conducted with mandarins cv. 'Clemenules' ($R^2 = 0.94$). However, CitrusYield leaves it open to the user to introduce different coefficients to adapt the dashboard to other cultivars.

$$\text{Estimated weight (kg)} = ((\text{Diameter (mm)} - 45.827) / 0.137) \times 10^{-3} \quad (3)$$

$$\text{Estimated weight (kg)} = ((\text{Diameter (mm)} - 36.253) / 0.2028) \times 10^{-3} \quad (4)$$

2.4. Agricultural Maps

A spatial database was created by CitrusYield, linking the time stamps created by the GPS and the vision system. In the tests carried out, the spatial database that was created related each fruit to the number assigned to the swath where it was collected, the date and time of linking, the location (longitude, latitude and altitude), the variables related to the prototype (channel, camera and output bin), the variables measured in the images of the fruit (diameter and colour index) and, finally, the ‘estimated weight’ variable created in the dashboard. The longitude and latitude variables are displayed in the WGS84. Quantitative variables were measured using the International System of Units (SI). This way, it was possible to locate the amount of fruit collected in each point of the field or assign the quality of any fruit to its exact harvest location. The creation of this database offered a record of the fruits, which ensured traceability from the early stages of production.

Using this information, maps were created within CitrusYield using the leaflet package for R [28]. This open source library makes it easy to create customised maps. One of the advantages of using this package is that it is not necessary to pre-load the maps. For each location data obtained by the GNSS, the latitude and longitude were extracted. With this geographical information, the functions programmed in the dashboard superimposed a marker for each fruit on the crop map. Among the map options offered for the projection of the markers, the orographic map was selected, therefore, the point for each fruit is projected directly on the map by means of its location information.

The dashboard was programmed to generate three types of maps: one according to three ranges for the ‘colour index’ variable, where the limits for each range were pre-set at the CCI values (-80, -3), (-2, 7), (8, 50); another showing the size distribution according to the seven categories defined; and, finally, one map showing the fruits sent to output bins 1 and 2, representing where those fruit not achieving commercial quality were harvested.

Each fruit was georeferenced as a point on the orographic map. If there were many points in the same category that overlapped in one area, the colour related to this category intensified there. Therefore, the greater the intensity of the colour for a category in an area, the greater the amount of fruits collected from that category in that area.

2.5. Exploratory Data Analysis (EDA)

A main advantage of this new tool is the possibility of performing analyses from the data shown in the maps. These analyses were shown to the grower through easy-to-understand graphs and plots. For this purpose, the plotly package for R [29] was chosen as it can be used to generate interactive graphs. Data collected during the tests were shown through diagrams for the quantitative variables. Figure 5 shows graphs representing the estimated weight per output bin of the fruit harvested in the three swaths.

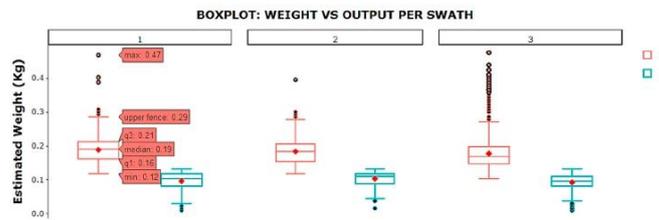


Figure 5. Example of box plots created by the CitrusYield dashboard. In the legend, red mark (1) is related to output bin 1 and blue mark (2) to output bin 2.

A Kolmogorov–Smirnov test with Lilliefors correction was also programmed in order to conduct analyses of data normality (it was assumed that the mean and variance were unknown in order to make the result more robust) since the size of the dataset acquired during the use of this citrus harvest-assist prototype in the field was always greater than 50 units. This feature is very useful for comparative statistical analyses between different harvesting campaigns. An example histogram with a density curve is shown in Figure 6, which was created using the `plotly` package for R.

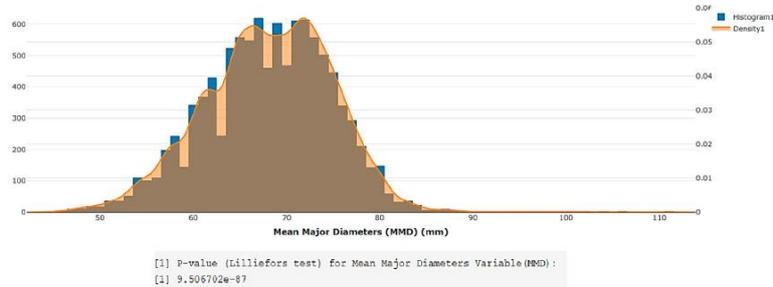


Figure 6. Example of a histogram with density curve for the ‘diameter’ variable in CitrusYield.

3. Results

The yield and fruit quality maps were generated automatically by CitrusYield. The maps showed an irregular spacing within the plot that matched the variable characteristics of the varieties and production of the experimental plot. In Figure 7, the fruit on the map was georeferenced according to the two factors of the ‘output bin’ variable. This map was called Output Map. Here, a predominant orange colour is observed, which indicates that most of the fruits were deposited in output bin 1, that is to say, they were fruits of sufficient size for the fresh market. In Figure 8, the fruit was georeferenced according to three ranges according to the ‘colour index’ variable. This map was called Colour Map. In this map, as expected, it was observed that most of the fruit had a CCI higher than 8, so that none of the fruit needed any subsequent degreening treatment. In Figure 9, georeferencing was performed on the map according to the seven categories defined for the ‘diameter’ variable. This map was called Calibre Map. This map shows that most of the oranges had a size between the second and fifth categories.



Figure 7. Screenshot of the Output Map.

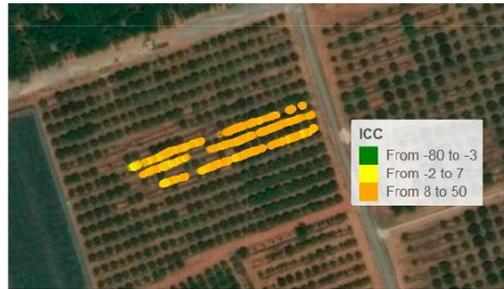


Figure 8. Screenshot of the Colour Map. ICC: Index of Citrus Colour.

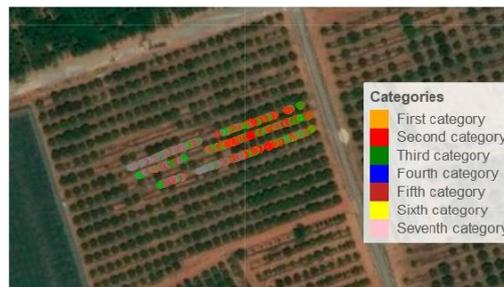


Figure 9. Screenshot of the Calibre Map.

Descriptive information was also provided along with the maps. For instance, Figure 10 shows the stacked bar diagram associated with the 'output bin' variable, where the dashboard presents the information associated with the maps in a more visual manner. It can be seen here that the percentage of fruits classified in output bin 2 for swath 3 (7.64%) was higher than for the rest of the swaths. From Figure 7, it can be deduced from the orange colour of the dots and their intensity that the largest amount of fruit harvested for output bin 1 was in the first half of the third swath, while all the harvested fruit with lower quality was located in the second half of the swath, which may indicate that there was some problem with the crop in that area. Comparing this with the harvesting scheme in Figure 2, it can be seen that this area was the one with the largest number of trees with harvested fruits and, hence, the information shown in the dashboard allowed us to deduce that the relatively smaller size of these oranges in the final section of the third swath depended on factors affecting that specific area, such as irrigation, nutrients, state of the soil, etc.

Hence, the information provided allows the farmer to know detailed information about the production for each swath and plot. Those areas where production is deficient can be located so that the farmer can find out in the location in the field and fix the problems that affect production in that area.

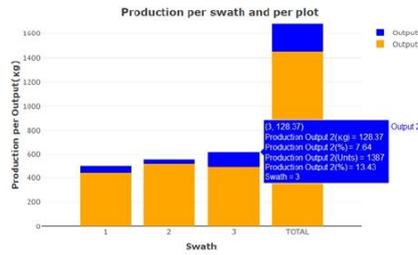


Figure 10. Screenshot of one of the bar charts according to the 'output' variable.

Other useful information that was generated was the variability of the data obtained for each swath with respect to the 'estimated weight' variable (Figure 11). Swath 3 had a greater number of fruits harvested with lower weights, which was reflected in the graph where the median (0.15 kg) and the mean (0.1492 kg) were the lowest of the three. The high number of atypical data from 0.29 kg onwards in swath 3 indicated that there was a clear difference in production in that swath, which corroborated what has been outlined above. Through this information, the farmer can take into account the differences in production among the different swaths for further crop handling.

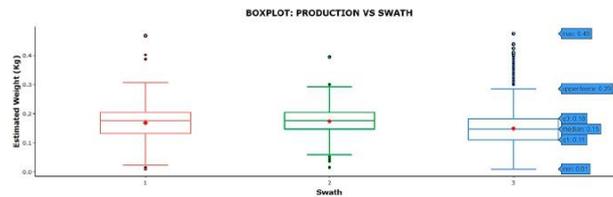


Figure 11. Screenshot of one of the box plots created by the dashboard.

The quality indicators of the classified fruit are shown in tables (Figure 12). In all, 76.78% of the harvested oranges were deposited in output bin 1, which indicated that more than three quarters of the harvested produce had that quality and that there were differences between swaths as the third swath had the highest percentage of oranges deposited in output bin 2 (13.43%).

Swath	Classified fruit quality (%)	Classified fruit quality in Output 1 (%)	Classified fruit quality in Output 2 (%)
1	28.72	22.63	6.09
2	31.06	21.37	3.7
3	40.21	26.78	13.43
TOTAL	100	76.78	23.22

Figure 12. Classified fruit quality.

Other important information provided was related to the performance of the harvesting (productivity) and inspection process. Figure 13 shows a table generated by CitrusYield that reflects the performance of the vision system. The field experience showed an average performance lower than 17% for each of the swaths, with an overall mean of 13.8%. This means that the fruit was harvested very slowly and that the computer vision system was working well below its capacity. In the case of the tests carried out, this result was expected due to the low number of day labourers who

carried out the harvesting. A low value indicates to the farmer that there is potential for improvement in the harvesting process.

Show 10 entries Search:

Swath	Total Time (s)	Inspected fruits (Uts)	Inspection capacity of vision system (Uts)	Vision system performance (%)
1	3125	2966	2500	11.86
2	3027	3298	24216	13.25
3	3202	4153	25616	16.21
TOTAL	9354	10327	74832	13.8

Showing 1 to 4 of 4 entries Previous Next

Figure 13. Vision system performance.

The productivity indicators obtained are shown in Figure 14. The results showed that the swath with the highest number of harvested oranges per hour of operation was the third (696.42 kg h⁻¹). The data offer an estimation of the performance per ha and also reflect and allow the user to make an estimation of the quality of the fruit in each swath when the ratio between units and kg is calculated. In this way, the farmer can know the exact degree of effectiveness and efficiency of the harvesting process.

Show 10 entries Search:

Swath	Kg/h	Uts/h	Kg/ha	Uts/ha
1	575.99	3409.2	11723.52	69389.86
2	665.32	3818.05	11737.02	67372.31
3	696.42	4666.29	12783.28	85653.59
TOTAL	646.07	3971.92	12096.22	74377.37

Showing 1 to 4 of 4 entries Previous Next

Figure 14. Productivity indicators.

4. Discussion

From an overall perspective, the use of CitrusYield facilitates the access to useful information about the farm operation to the farmer. CitrusYield presents a number of advantages and novelties with respect to previous similar works or applications. For instance, the main differences between the maps created by Schueller et al. [6] or Molin et al. [7] and those generated automatically by CitrusYield are the way to obtain the information in the field and the automation of the processing of the data collected. The use of the harvest-assist machines with sensors allows the extraction of fruit quality parameters during the harvest process and, with the use of this dashboard, the useful information is automatically obtained without the need of computer skills. Unlike the rest of the commercial and non-commercial GIS software, CitrusYield has the ability to calculate production, classify fruits by categories in terms of their quality, georeference the categorised information in maps and perform statistical analyses automatically for each swath and for the orchard, showing the data using statistical graphs. This facilitates intra-crop and different season comparisons. The main advantage of knowing the differences in production between the swaths and areas inside the crop is to provide the grower with information to make accurate decisions for localised crop handling.

The Crop Auditor program, for instance, does not make it possible to know how much of the fruit meets the requirements for fresh consumption, as the production is not classified during harvesting. Neither does this program carry out georeferencing on orographic maps, which makes it difficult for the farmer to visualise the information captured graphically on the map, nor does it perform a statistical analysis of the data to find differences in the production of the different boxes or areas of the plot. In contrast, CitrusYield has been proved to be a relevant tool in industry 4.0 for (1) representing the spatial distribution of citrus in each swath, (2) automating the development of maps and calculating the production and quality of the fruits, (3) performing the exploratory data analysis

to detect differences and anomalies, and (4) also for calculating yields in the plot of interest. This dashboard can process, analyse and visualise information in an intuitive and easily manageable setting. This automation process is effective and practical for the immediate study of the spatial variability in production and quality in a field. It also provides accurate information, analyses data and creates maps, tables and graphs of spatial yield, which will increase the efficiency of field management and traceability of the fruit. As a consequence, it can contribute to a more precise management of other tasks, such as fertilisation, irrigation, pest and disease control, etc. This work has been carried out and tested on citrus, but the tool developed is easily configurable to collect and process diverse data from other different crops.

5. Conclusions

A new tool for the analysis and management of data in precision agriculture has been developed. CitrusYield was designed with R software due to the large number of libraries available for spatial data analysis and processing. This tool processes agricultural data and converts it into useful information for the farmer to manage the field. This is done through specific algorithms, statistical analysis and the ability to display information on plots and practical maps. The tool was tested with data collected from a citrus orchard by different sensors, analysing data related to the production and quality of the fruit and relating the information obtained with the exact point of harvest to create different types of maps. The ability to analyse and make comparisons between different areas within the field has also been tested.

Author Contributions: Developed the CitrusYield web application, M.G.G.G.; supervised the creation of CitrusYield, J.G.; contributed to the decision-making for the capabilities of CitrusYield, M.G.G.G., P.C., J.B, J.G.-S. and E.S.-O.; conceived, designed and performed the field harvesting tests, M.G.G.G. and P.C. All the authors organised the writing of the paper. All authors have read and agreed to the published version of the manuscript.

Funding: This work was partially funded by Instituto Nacional de Investigaciones y Tecnología Agraria (INIA) through projects RTA2014-00025-C05-01 and RTA2014-00025-C05-05, Generalitat Valenciana-Instituto Valenciano de Investigaciones Agrarias (GVA-IVIA) project 51918 and Fondo Europeo de Desarrollo Regional (FEDER) funds. María Gyomar González González thanks INIA for the FPI-INIA grant CPD2016-0007, partially supported by European Union social funds (FSE).

Acknowledgments: Thank-you to the staff at the Centro de Agroingeniería of IVIA for their help during the field harvesting test.

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

References

1. Faostat. Available online: <http://www.fao.org/faostat/es/#data/QC> (accessed on 7 October 2019).
2. Volumen de naranjas producidas al año en el mundo desde 2011 hasta 2018. Available online: <https://es.statista.com/estadisticas/508983/produccion-mundial-de-naranjas/> (accessed on 7 October 2019).
3. Volumen de mandarinas, clementinas y satsumas producidas al año en el mundo desde 2011 hasta 2018. Available online: <https://es.statista.com/estadisticas/501272/produccion-mundial-de-mandarinas-clementinas-satsumas/> (accessed on 7 October 2019).
4. Chueca, P.; Garcerá, C.; Castro García, S.; Martín-Gorri, B.; Mateu, G.; Gonzalez-Gonzalez, M.G.; Torregrosa, A. La importancia de la mecanización en la citricultura. *Horticultura*. **2019**, *341*, 28–35.
5. Qiao, J.; Sasao, A.; Shibusawa, S.; Kondo, N.; Morimoto, E. Mapping yield and quality using the mobile fruit grading robot. *Biosyst. Eng.* **2005**, *90*, 135–142.
6. Schueller, J.K.; Whitney, J.D.; Wheaton, T.A.; Miller, W.M.; Turner, A.E. Low-cost automatic yield mapping in hand-harvested citrus. *Comput. Electron. Agric.* **1999**, *23*, 145–153.
7. Molin, J.P.; Mascarin, L.S. Colheita de citros e obtenção de dados para mapeamento da produtividade. *Engenharia Agrícola*. **2007**, *27*, 259–266.
8. Mateu, G.; Torregrosa, A.; Juste, F.; Castro, S.; Arenas, F.J.; Hervalejo, A.; Chueca, P. Recolección mecanizada de cítricos: Equipos y características de las plantaciones para su uso. *Levante Agrícola*. **2017**, *435*, 63–68.

9. Kohno, Y.; Kondo, N.; Iida, M.; Kurita, M.; Shiigi, T.; Ogawa, Y.; Kaichi, T.; Okamoto, S. Development of a mobile grading machine for citrus fruit. *Eng. Agric. Environ. Food*. **2011**, *4*, 7–11.
10. Gutiérrez, A.; Blasco, J.; Chueca, P.; Garcerá, C.; Alegre, S.; López, S.; Moltó, E. Harvesting and in-field sorting of citrus with a self-propelled machine. In Proceedings of the I International Symposium on Mechanical Harvesting and Handling Systems of Fruits and Nuts, Lake Alfred, FL, USA, 6 November 2012, 149–152.
11. Chinchuluun, R.; Lee, W.S.; Ehsani, R. Machine vision system for determining citrus count and size on a canopy shake and catch harvester. *Appl. Eng. Agric.* **2009**, *25*, 451–458.
12. Castro García, S.; Sola Guirado, R.R.; Blanco Roldán, G.L.; Gil Ribes, J.A. Sistemas sacudidores de copa laterales para la recolección mecanizada de cítricos con destino industria. *Horticultura*. **2018**, *335*, 34–39.
13. Cubero, S.; Aleixos, N.; Albert, F.; Torregrosa, A.; Ortiz, C.; García-Navarrete, O.; Blasco, J. Optimised computer vision system for automatic pre-grading of citrus fruit in the field using a mobile platform. *Precision Agric.* **2014**, *15*, 80–94.
14. Ping, J.L.; Dobermann, A. Processing of yield map data. *Precision Agric.* **2005**, *6*, 193–212.
15. Sudduth, K.A.; Drummond, S.T. Yield editor. *Agron. J.* **2007**, *99*, 1471–1482.
16. Landau, E.C.; Guimarães, D. P.; Hirsch, A. Uso de Sistema de Informaciones Geográficas para espacialización de datos del área de producción agrícola. In *Manual de Agricultura de Precisión*, 1st ed; Chartuni Mantovaní, E., Magdalena, C., Eds.; PROCISUR y IICA: Montevideo, Uruguay, 2014, pp. 22–29.
17. Zagórdá, M.; Walczykova, M. The application of various software programs for mapping yields in precision agriculture. *BIO Web Conf.* **2018**, *10*, 01018.
18. Uva, M.; Campanella, O. AP-SIG: Un SIG con funciones específicas para Agricultura de Precisión. In Proceedings of XI Workshop de Investigadores en Ciencias de la Computación, San Juan, Argentina, 7–8 May 2009, pp. 531–535.
19. Tan, L.; Haley, R.; Wortman, R. Cloud-based harvest management system for specialty crops. In Proceedings of 2015 IEEE Fourth Symposium on Network Cloud Computing and Applications (NCCA 2015), Munich, Germany, 11–12 June 2015, pp. 91–98.
20. Gonzalez-de-Santos, P.; Ribeiro, A.; Fernandez-Quintanilla, C.; Lopez-Granados, F.; Brandstötter, M.; Tomic, S.; Perez-Ruiz, M. Fleets of robots for environmentally-safe pest control in agriculture. *Precision Agric.* **2017**, *18*, 574–614.
21. Leroux, C.; Jones, H.; Pichon, L.; Guillaume, S.; Lamour, J.; Taylor, J.; Tisseyre, B. GeoFIS: An open source, decision-support tool for precision agriculture data. *Agriculture* **2018**, *8*, 73.
22. Ampatzidis, Y.; Tan, L.; Haley, R.; Whiting, M.D. Cloud-based harvest management information system for hand-harvested specialty crops. *Comput. Electron. Agric.* **2016**, *122*, 161–167.
23. Cubero, S.; Moltó, E.; Gutiérrez, A.; Aleixos, N.; García-Navarrete, O.L.; Juste, F.; Blasco, J. Real-time inspection of fruit on a mobile harvesting platform in field conditions using computer vision. *Prog. Agric. Eng. Science*. **2010**, *6*, 1–16.
24. Jiménez-Cuesta, M.; Cuquerella, J.; Martínez-Javaga, J.M. Determination of a color index for citrus fruit degreening. *Proc. Int. Soc. Citriculture*. **1982**, *2*, 750–753.
25. Vidal, A.; Talens, P.; Prats-Montalbán, J.M.; Cubero, S.; Albert, F.; Blasco, J. In-line estimation of the standard colour index of citrus fruits using a computer vision system developed for a mobile platform. *Food Bioprocess. Tech.* **2013**, *6*, 3412–3419.
26. Decker, B.L. World geodetic system 1984. *Def. Mapp. Agency Aerospace Center St. L. Afs Mo.* **1986**.
27. R Software. Available online: <https://www.r-project.org/> (accessed on 7 October 2019).
28. Leaflet package for R. Available online: <https://rstudio.github.io/leaflet/> (accessed on 7 October 2019).
29. Plotly package for R. Available online: <https://cran.r-project.org/web/packages/plotly/index.html> (accessed on 7 October 2019).



© 2019 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/>).

2. **Gonzalez-Gonzalez, M. G.,** Blasco, J., Cubero, S., & Chueca, P. (2021). Automated Detection of *Tetranychus urticae* Koch in Citrus Leaves Based on Colour and VIS/NIR Hyperspectral Imaging. *Agronomy*, 11(5), 1002.
DOI: 10.3390/agronomy11051002. Factor de impacto: 2.603 (Q1)



Article

Automated Detection of *Tetranychus urticae* Koch in Citrus Leaves Based on Colour and VIS/NIR Hyperspectral Imaging

María Gyomar Gonzalez-Gonzalez, Jose Blasco *, Sergio Cubero and Patricia Chueca *

Agricultural Engineering Centre, Instituto Valenciano de Investigaciones Agrarias (IVIA), CV-315, km 10,7, Moncada, 46113 Valencia, Spain; gonzalez_margond@gva.es (M.G.G.-G.); cubero_ser@gva.es (S.C.)

* Correspondence: blasco_josiva@gva.es (J.B.); chueca_pat@gva.es (P.C.)

Abstract: *Tetranychus urticae* Koch is an important citrus pest that produces chlorotic spots on the leaves and scars on the fruit of affected trees. It is detected by visual inspection of the leaves. This work studies the potential of colour and hyperspectral imaging (400–1000 nm) under laboratory conditions as a fast and automatic method to detect the damage caused by this pest. The ability of a traditional vision system to differentiate this pest from others, such as *Phyllocnistis citrella*, and other leaf problems such as those caused by nutritional deficiencies, has been studied and compared with a more advanced hyperspectral system. To analyse the colour images, discriminant analysis has been used to classify the pixels as belonging to either a damaged or healthy leaves. In contrast, the hyperspectral images have been analysed using PLS DA. The rate of detection of the damage caused by *T. urticae* with colour images reached 92.5%, while leaves that did not present any damage were all correctly identified. Other problems such as damage by *P. citrella* were also correctly discriminated from *T. urticae*. Moreover, hyperspectral imaging allowed damage caused by *T. urticae* to be discriminated from healthy leaves and to distinguish between recent and mature leaves, which indicates whether it is a recent or an older infestation. Furthermore, good results were achieved in the discrimination between damage caused by *T. urticae*, *P. citrella*, and nutritional deficiencies.

Keywords: two-spotted spider mite; red spider mite; integrated pest management; citrus damage; optical sensors; image processing; automated monitoring pest

Citation: Gonzalez-Gonzalez, M.G.; Blasco, J.; Cubero, S.; Chueca, P. Automated Detection of *Tetranychus urticae* Koch in Citrus Leaves Based on Colour and VIS/NIR Hyperspectral Imaging. *Agronomy* 2021, 11, 1002. <https://doi.org/10.3390/agronomy11051002>

Academic Editor: Silvia Arazuri

Received: 20 April 2021
Accepted: 10 May 2021
Published: 18 May 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 (<http://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Spain is the world's sixth largest producer of citrus and the first exporter of fruit for the fresh market [1]. Therefore, the external quality of fruits is a key factor in the purchase decision, and the pests that cause direct damage to these fruits are of crucial importance [2,3]. Among pests, mites are one of the major problems of citrus, including the citrus rust mite and the citrus red mite. *Tetranychus urticae* Koch (Acari: *Tetranychidae*), also called the two-spotted spider mite, is one of the economically most important pests in a wide range of outdoor and protected crops worldwide [4]. In Spain, *T. urticae* is a key pest of citrus [5–7] and affects especially clementine mandarin trees [8–10] because they are susceptible to outbreaks of this mite [11].

In summer, under Mediterranean conditions, *T. urticae* colonies are preferably located on the underside of the citrus leaves, where they are protected with silk threads. The mite feeds on the content of the epidermal and parenchyma cells of the leaves [12]. As a result of their feeding, they cause discolouration and desiccation, which in most cases is manifested by chlorotic (yellowish and rarely brown) spots and bulges on the upper side of the leaves [13]. Two-spotted spider mite damage also produces webbing and fine stippling. However, where it is most damaging is on the fruit because it causes rusty spots that spread throughout the fruit [6]. These injuries result in significant re-

ductions in the quality of clementine tangerines, which downgrades the fruit and severely lowers the fresh market prices [14,15].

Under the integrated pest management (IPM) strategy, producers assess the presence of this pest on a weekly or biweekly basis between July and September, depending on the incidence of the pest [10]. This evaluation is carried out manually by placing two rings, 56 cm in diameter, in the crown of the tree and counting the number of rings with more than two symptomatic leaves (yellowish spots). This technique makes these evaluations an expensive, time-consuming, and labour-intensive task.

Remote sensing, specifically proximal sensing, can provide an effective alternative in pest monitoring [16,17]. The use of proximal sensors has advantages over manual methods because it allows the vegetation conditions to be inferred in a suitable, faster, and more agile way, while it is also a non-invasive and non-destructive technique. Some studies have been carried out in other non-citrus crops for the detection of *T. urticae* using a spectrometer. Martin and Latheef [18] used a ground-based multispectral optical sensor as a remote sensing tool to evaluate foliar damage caused by this pest on greenhouse-grown cotton, and they distinguished various levels of infestation at the beginning of the season. Herrmann et al. [19] used multispectral images of pepper leaves in a greenhouse to calculate vegetation indices, which allowed the early detection of damage caused by this pest. In lab-based strawberry leaves, Fraulo et al. [20] employed diffuse reflectance spectroscopy in the visible and near-infrared portions of the spectrum to identify spectral regions altered by the presence of *T. urticae*. Crockett et al. [21] used spectroscopy and visible and near infrared (VNIR) imaging on the leaves of different strawberry cultivars to characterise the reflectance patterns of the damage, which revealed the existence of differences in varietal susceptibility. In spectral methods based on cameras, Nieuwenhuizen et al. [22] studied the images obtained by an RGB camera and three multispectral cameras to detect red spider mite damage in greenhouse tomato leaves; the results showed discriminant spectral bands between healthy and damaged leaves. Moreover, Uygun et al. [23] developed an innovative image processing technique to determine the level of damage in greenhouse cucumber plants infected by this pest.

Red spider mite causes discolouration and desiccation when they feed the leaf, which, in most cases, results in yellowish spots and/or bulges in the upper side of the leaves [24]. The larva of *Phyllocnistis citrella* Stainton (Lepidoptera: *Gracillariidae*) feeds on the leaf in the area between the parenchyma and the cuticle. It traces a winding gallery that grows as the larva grows. The cuticle of the affected leaves breaks, causing water loss in the cells; consequently, the leaf coils dry and break [24]. Nutritional deficiencies in citrus leaves, when severe, are also manifested in symptoms that can be recognised visually [25]. Some symptoms can be similar in colour to the chlorotic spots caused by *T. urticae*. Nitrogen deficiency occurs in old leaves first and causes a significant yellowing in the veins. In contrast, iron deficiency occurs in recent leaves and produces a loss of their deep green colour that evolves into shades ranging from light green to pale yellow, depending on the intensity of the condition. However, the veins of the leaves characteristically remain dark green and appear marked on a lighter background, resembling a kind of mesh or lattice [26]. Manganese deficiency leads to chlorosis in the interveinal tissue of the leaves, but the veins remain dark green. Sometimes, Mn deficiency can be confused with Fe and Zn deficiency. Recent leaves usually show a reticulate pattern on a lighter green background that is less marked than in Zn or Fe deficiencies. The pattern becomes a green band along the midrib and the principal lateral veins in mature leaves, with light green areas between the veins [27].

Leaf characteristics can be linked to spectral features statistically. In hyperspectral remote sensing, spectral data are typically high-dimensional, fine spectral bands that are highly correlated with each other [28]. Hyperspectral imaging generates a massive amount of redundant and frequently highly correlated data that needs to be processed [29]. This fact may lead to multicollinearity problems and overfitting when using conventional multivariate regression for empirical modelling [30,31]. To handle such a large

amount of data and extract useful information, computational statistical methods are needed. These methods connect original variables with the essential spectral information to classify and/or quantify important characteristics [32,33]. Partial Least Squares (PLS) is one of the most popular methods for constructing predictive models. This method is commonly used in hyperspectral imaging to extract and summarise spectral information from hyperspectral images, reduce the high dimensionality of the spectral data, and overcome the problem of multicollinearity [34]. PLS discriminant analysis (PLS-DA) is a variant of PLS regression in which the independent variable is categorical, expressing the class membership of the samples. It is performed to sharpen the separation between groups by maximising the covariance between the spectra and the independent variable, so that a maximum separation among classes is obtained.

This work aims to investigate the potential use of both colour and hyperspectral imaging as a practical tool to detect the presence and the age of the damage caused by *T. urticae* in tangerine leaves. Another goal is to discriminate this damage from that caused by other pests and from nutritional deficiencies.

2. Materials and Methods

2.1. Leaf Samples

A total of 142 tangerine (cv. 'Clemenules') leaves were collected from two commercial orchards located in El Puig de Santa María and Chiva (Valencia, Spain) in September 2019. After collecting the leaves, they were stored in a cool chamber at 5 °C. The selection of the leaves was established as follows (Table 1).

Sixty leaves with visible damage caused by *T. urticae* and 60 leaves with no external symptoms of any damage were chosen to evaluate the ability of an automated system to detect the presence of damage caused by this pest in the leaves. Since recent damage occurs typically in recent leaves [24], to determine whether the damage corresponded to an active pest or an old one, half of the selected leaves, with damage or without, were recent, while the other half were old.

Twenty-two leaves were selected to test the ability to discriminate between *T. urticae* and other problems, 10 of which were affected by *P. citrella* and the remaining 12 were affected by various nutritional deficiencies whose aspect was compatible with N (6 leaves) and Fe, Mn, or Zn deficiencies (6 leaves) [35]. These leaves presented a discoloured appearance similar to the damage caused by *T. urticae* but with different geometrical patterns.

Another 20 leaves were selected, 10 with *T. urticae* damage and 10 with various deficiencies, to determine the geometric characteristics of the patterns caused by the damage and the deficiencies in the leaves and to tune the algorithm used to process the colour images.

Table 1. Classification of the sets and subsets of the leaves for analysis.

Name of the Set	Name of the Subset	Leaves	Symptom	Age
G1	G1.1	30	Healthy	Recent
	G1.2	30	Healthy	Mature
G2	G2.1	30	<i>Tetranychus urticae</i>	Recent
	G2.2	30	<i>Tetranychus urticae</i>	Mature
G3	G3.1	10	<i>Phyllocnistis citrella</i>	Recent and mature
G4	G4.1	6	N deficiency	Recent and mature
	G4.2	6	Fe, Mn, or Zn deficiency	Recent and mature

The damage observed in the leaves had well-defined characteristics, such as colour and shape, which made it possible to draw a visual distinction among them. Figure 1 shows images of the leaf samples on both sides for each subset.

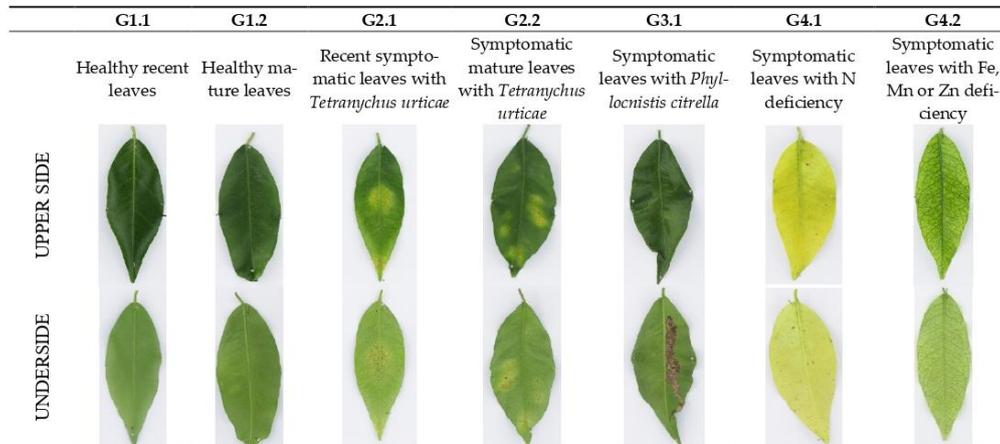


Figure 1. Images of the leaves (upper and underside of the leaf) for each subset.

2.2. Detection of *T. Urticae* Damage Using Colour Imaging

2.2.1. Colour Image Acquisition and Segmentation

Colour images with a resolution of 0.03 mm/pixel were captured using a digital camera (EOS 700D, Canon Inc, Tokio, Japan) arranged inside a square inspection chamber that included a calibrated and uniform illumination system composed of eight fluorescent tubes (BIOLUX 18 W/965, 6500 K, Osram GmbH, Germany). The angle between the lens axis and the illumination sources was approximately 45° [36], and cross-polarisation was used [37] to avoid direct reflections towards the camera. Images were captured on the day after leaf collection, and the samples were kept at room temperature (22–25 °C) for 30 min before acquiring the images. Images of the leaves were captured from both the upper side and the underside over a uniform white background.

The images were processed using customised software developed by our group at IVIA (FooColor-Inspector v4.0, available at <http://www.cofilab.com>). The processing consisted in performing an image segmentation based on colour features. However, the damage caused by *T. urticae* and the colour changes caused by the nutritional deficiencies cannot be differentiated by using the colour feature alone. Thus, a second step was carried out to classify the leaves according to some geometric features of the objects found, as the two types of damage have a very different appearance. Moreover, using only colour information, it is impossible to determine whether the damage caused by *T. urticae* is new or old, and therefore, the sets G2.1 and G2.2 were joined together to form group G2.

In the segmentation based on colour features, four classes were predefined as follows: background, green area (which corresponds to the healthy part of the leaf), yellow area (which corresponds to *T. urticae* or deficiency spots), and brown area (which corresponds to *P. citrella* spots). Prior to the segmentation, a supervised training process was necessary. For this purpose, another set of 20 leaves, different from those described in Table 1, was used. The training consisted in manually selecting representative regions of interest (ROI) belonging to the predefined classes in the leaves used for this purpose. The colour values (RGB) of the pixels in each region were stored together with the class to which they belonged. These values were later used as input to build a Bayesian linear discriminant analysis (LDA) [38]. This type of LDA relies on the Bayes theorem shown in the Equation (1):

$$P(x|w_i) = \frac{p(x|w_i)P(w_i)}{\sum_{j=1}^m p(x|w_j)P(w_j)}, i = 1, \dots, m \quad (1)$$

where x was the three-dimensional observed vector (in our case, the average RGB values of an object), w_i ($i = 1, \dots, m$) was one of the m different classes, m was the number of classes, $P(x|w_i)$ was the probability that the observed x belonged to class w_i , $P(w_i)$ was the a priori probability of an object belonging to class w_i (this probability was considered to be the same for each class), and $p(x|w_i)$ was the conditional density function of the RGB values in class w_i .

The technique used for image segmentation was pixels-wise. Therefore, for each pixel in the image, the probability of belonging to each class was estimated, assigning the pixel to the class with the highest probability. After segmentation, all pixels found in the image were classified based on the predefined classes.

2.2.2. Definition of the Discrimination Parameters

As stated, the colour of the damage caused by the deficiencies and by *T. urticae* is similar. Therefore, the segmentation process could not separate them into different classes. However, the appearance and geometrical pattern of the damage were completely different. For these reasons, the decision was made to analyse some geometrical properties of the objects initially classified as *T. urticae*. In the analysis, a distinction was drawn between these objects from leaves damaged by *T. urticae* and leaves damaged by deficiencies. The purpose of this analysis was to determine the discriminative properties for identifying *T. urticae* damage, not the detection or identification of deficiencies. Taking into account that damage caused by *T. urticae* is generally detected as objects with an approximately round shape, the geometrical properties considered for the analysis were [39]:

- The number of damaged areas detected per leaf.
- The total damaged area (mm²) of the leaf, as the sum of the areas of all the objects found.
- The area (A), roundness (R), compactness (C), perimeter (P), and elongation (E) of each object found in the leaf.

Each of these properties was analysed through an analysis of variance (ANOVA) to know whether there were significant differences between those corresponding to the damage actually caused by *T. urticae* and the discolourations due to deficiencies. Discriminative properties were included in the discrimination algorithm to separate between *T. urticae* and deficiencies.

2.3. Detection of *T. Urticae* Damage Using Hyperspectral Imaging

2.3.1. Hyperspectral Image Acquisition

The hyperspectral imaging system was composed of a camera (CoolSNAP ES, Photometrics, Tucson, AZ, USA) and a liquid crystal tuneable filter (Varispec NIR-07, Cambridge Research & Instrumentation, Inc., Hopkinton, MA, USA) that allowed images to be captured in the operating spectral range from 450 to 1000 nm. The camera was configured to acquire images with a size of 1392 × 1040 pixels and a spatial resolution of 0.14 mm/pixel. A total of 56 monochrome images were acquired for each side of the leaf in 10-nm intervals. To optimise the dynamic range of the camera, prevent saturated images, and correct the spectral sensitivity of the different elements of the system, a calibration of the integration time was performed for each band. This consisted in setting the individual integration time for each band required to obtain 90% of the reflectance of a white target reference (Spectralon 99%, Labsphere, Inc, NH, USA).

The scene was illuminated by twelve halogen spotlights (37 W) (Eurostar IR Halogen MR16, Ushio America, Inc., CA, USA) powered by direct current (12 V). The lamps were arranged equidistant from each other inside a hemispherical aluminium diffuser to

illuminate the samples indirectly. Two images per leaf (upper and underside of the leaf) were acquired in reflectance mode using customised software developed at IVIA (Figure 2). The reflectance captured was corrected to obtain the relative reflectance using a dark and the white reference through Equation (2) [40]:

$$\rho_{xy}(x, y, \lambda) = \frac{R^{abs}}{R_{white}^{abs}} = \rho^{Ref}(\lambda) \frac{R(x, y, \lambda) - R_{black}(x, y, \lambda)}{R_{white}(x, y, \lambda) - R_{black}(x, y, \lambda)} \quad (2)$$

where $\rho^{Ref}(\lambda)$ is the standard reflectance of the white reference target (99% in this work), $R(x, y, \lambda)$ is the reflectance of the fruit captured by the CCD sensor of the camera in the pixel located at (x, y) coordinates, $R_{white}(x, y, \lambda)$ is the reflectance captured by the CCD of the white reference target, and $R_{black}(x, y, \lambda)$ is the reflectance captured by the CCD while avoiding any light source so as to be able to quantify the electronic noise of the CCD.



Figure 2. Images captured at 650 nm and colour of the two sides of a leaf affected by *T. urticae*.

Therefore, a tagged database of 204 hyperspectral images was obtained (Table 2). Three ROIs with a size of 10×10 pixels were selected for each side of the leaf for the case of healthy leaves (G1), the leaves with *P. citrella* (G3), and the leaves with deficiencies (G4). In the leaves affected by *T. urticae* (G2), three ROIs were selected from the damaged area and another three were selected from the asymptomatic area for each side of the leaf. Thus, a total of 972 ROIs were obtained from both sides. These ROIs were considered to be the samples for the analysis.

Table 2. Classification of the tagged database for analysis.

Subset	Leaves	Number of Hyperspectral Images (Both Sides of the Leaf)	Total Number of ROI
G1.1	10	20	60
G1.2	10	20	60
G2.1	30	60	360
G2.2	30	60	360
G3.1	10	20	60
G4.1	6	12	36

G4.2	6	12	36
TOTAL	102	204	972

The average reflectance spectrum of all pixels in each ROI was extracted and organised in a table with 56 columns corresponding to the reflectance value of each band and the class to which they belong. The use of adequate object features leads to more stable classification models, as the mean spectrum decreases the amount of data [41]. This approach prevents classification by pixels when objects from different classes contain many similar pixels and are easily wrongly assigned to the opposite class.

2.3.2. Multivariate Data Analysis

Three experiments were planned. The first one was conducted in order to know the ability of a model to discriminate between areas that are healthy and those damaged by *T. urticae*. Sets G1 and G2 were included in this experiment. The aim of the second experiment was to assess the ability of the model to discriminate between new and old damage, and therefore, subsets G2.1 and G2.2 were included. The third experiment explored the capability of the model to discriminate between *T. urticae* damage and damage caused by other problems in the leaves. Therefore, all the sets were used to build the models.

To perform the multivariate analysis, PLS-DA was used. In PLS-DA, the regression results are values of Y close to the values assigned to each class. In this analysis, the independent variables (X) were the spectrum of each sample, while the dependent variable Y was a categorical variable representing each class [42]. Thus, a numerical value was assigned to the variable Y representing the class. For the first experiment, to detect the damage caused by *T. urticae*, a value of 0 was set for damaged leaves and 1 was set for healthy ones. In the second experiment, which was conducted to differentiate between leaves with recent *T. urticae* and leaves with mature *T. urticae* damages, a value of 0 was assigned for recent and a value of 1 was set for mature leaves. Finally, in the third experiment, aimed at discriminating among all the different types of damage, the response values were set as 1, 2, 3, 4, and 5 for G1, G2, G4.1, G4.2, and G3, respectively.

In this study, the method used to reduce the huge amount of redundant and correlated data captured by the hyperspectral systems between contiguous wavelengths [33] and to select the optimal wavelengths was based on the vector of the regression coefficients. It measures the association between each variable and the response and selects variables in two steps: (i) the PLS model is fitted to the data, and (ii) the selection of variables is based on a threshold [43]. Variables with a high absolute value can be selected because they make the highest contribution to the classification, and those with a small absolute value can be ignored [44]. In this work, the regression coefficients were obtained from the PLS models.

In all cases, 70% of the samples were used to train and validate the model using cross-validation. The remaining 30% of the samples were used as an independent or prediction test set. Results are given for the test set.

The input spectra for the PLS-DA models were normalised using mean-centring [45]. A single 10-fold Venetian blind cross-validation (i.e., splitting the data evenly into 10 sets and leaving each of the sets out in each iteration of the validation procedure) was used to choose the optimal number of latent variables (LVs) as well as to obtain an estimate of the error rate of the PLS models [46]. Usually, the first latent variables explain most of the variance in the dependent variables, and thus, the dependent variables can be modelled by a reduced number of latent variables (LVs). In a PLS model, the explanatory power of the model increases as the number of PLS factors or variables increases. However, the prediction accuracy of the model may decrease with an increase in model complexity [47]. The software used to construct these PLS models was The Unscrambler X 10.4 (CAMO Software, Oslo, Norway).

2.3.3. Model Performance Evaluation

When a regression method is used to build a classification model, one of the most important parameters to define is the cut-off value, that is, the acceptance interval in which a new sample is considered correctly classified in the class. Similar to [48,49], the PLS-DA cut-off value for the discrimination of samples based on the presence of damage caused by *T. urticae* was set at 0.5. If the predicted value of a sample was less than 0.5, the sample was classified as damaged; otherwise, it was considered healthy. Likewise, in the second experiment to discriminate the age of the damage, those with a predicted value of 0.5 were deemed to be recent leaves, while those with higher values were considered to be mature leaves and hence old damage. The third experiment contained a higher number of classes, and therefore, intervals were set for each of them. The interval [0.5–1.5] corresponded to healthy leaves, [1.5–2.5] was set for *T. urticae*, [2.5–3.5] was set for N deficiency, [3.5–4.5] was set for other deficiencies, and [4.5–5.5] was set for damage caused by *P. citrella*.

For all cases, the results of the PLS-DA models were expressed as a percentage of correct classification. The precision and the predictive capacity of the PLS-DA models were evaluated using the coefficient of determination (R^2). The root mean square error between the predicted and the measured values of the reference parameter in the test set (RMSEP) was used for calibration, cross-validation, and prediction.

3. Results and Discussion

3.1. Detection of *T. Urticae* Damage Using Colour Imaging

3.1.1. Discrimination Parameters

In general, the defects caused by *T. urticae* and those found due to other problems, such as deficiencies, are very different (Figure 3). Although they could not be separated by colour, the geometrical properties allowed good discrimination to be achieved. Geometric properties were calculated for each defect found in the leaves. Furthermore, the total number of defects per leaf and the total damaged area were added together. One-factor analysis of variance [50] was used to know if these properties were significantly different in these two groups and could be used to separate true *T. urticae* from other damaged areas not caused by the pest. Table 3 shows that most properties were significantly different in the two groups (high F-score, p -value < 0.005). Hence, for the sake of simplicity, the amount of damage per leaf, the total area, and the individual area of the damage were considered in order to classify the leaf as affected by *T. urticae* or not. Therefore, if the area of the objects found, the amount of damage found in a leaf, and the total area of this damage were within the mean plus/minus the standard deviation of those corresponding to *T. urticae*, the leaf was considered to be affected by *T. urticae*.

Table 3. Analysis of variance (ANOVA) of the geometrical properties of the objects found in the test images. The objects correspond to actual damages caused by *T. urticae* and nutritional deficiencies (not *T. urticae*).

	True <i>T. Urticae</i>		Not <i>T. Urticae</i>		Statistical Parameters of ANOVA *	
	Mean	Typical Deviation	Mean	Typical Deviation	F	p -Value
Elongation	1.539	0.272	4.230	4.596	8.161	0.0053
Roundness	0.506	0.163	0.252	0.155	44.362	0.0000
Individual area	67,293.94	39,350.89	224,056.90	233,071.55	9.476	0.0036
Compactness	34.98	17.41	83.82	75.29	15.092	0.0002
Perimeter	3260.06	2932.77	1848.61	2928.42	5.699	0.0187
Damages per leaf	1.69	0.855	9.000	6.890	11.208	0.0032
Total damaged area	82,321.75	35,703.98	1,176,298.75	517,992.91	83.652	0.0000

* Degrees of freedom: 1, 95.

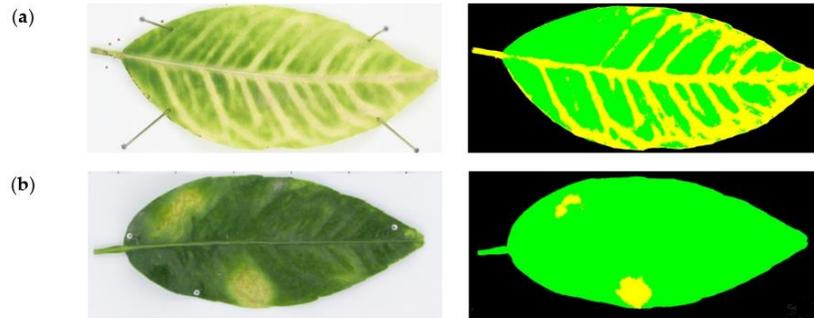


Figure 3. Examples of image segmentation of leaves. (a) Leaf with symptoms compatible with N deficiencies. (b) Leaf affected by *T. urticae*.

3.1.2. Detection of the Damage

Table 4 shows the classification of the damage detected for each set and subset according to the side of the leaf. The method based on colour information correctly determined 100% of sound leaves in all cases, regardless of whether they were recent or old. The detection of *T. urticae* damage was also high in all cases, reaching an overall success rate of 92.5% (91.67% with the underside and 93.33% with the upper side of the leaf). Most errors were due to damage that went undetected, and only in two cases, in the underside of old leaves, were they confused with damage caused by *P. citrella*, which was probably due to browning caused by ageing of the *T. urticae* damage in the leaf. *P. citrella* was successfully discriminated in 100% of cases when the underside was examined, as this pest is located in this part of the leaves. Finally, the discrimination between damage due to deficiency was different depending on the nutrient. N deficiency could not be correctly discriminated as the main symptom was the lightening of the green colour, but it did not follow any particular pattern. The system was unable to establish a valid general threshold to determine when a leaf had N deficiency or was just light green. The case of other deficiencies performed better, but only in 50% of cases were they correctly discriminated from the damage caused by *T. urticae*. However, they were separated from *T. urticae* in 100% of the cases, despite the similarities in colour.

Table 4. Results of the detection of *T. urticae* damage on each side of the leaf using colour information.

Sets and Subsets	Underside (%)					Upperside (%)				
	G1	G2	G3	G4.1	G4.2	G1	G2	G3	G4.1	G4.2
G1	100	0	0	0	0	100	0	0	0	0
G2	5.00	91.67	3.33	0	0	6.67	93.33	0	0	0
G3	0	0	100	0	0	90.0	10.00	0	0	0
G4.1	100	0	0	0	0	83.33	0	0	16.67	0
G4.2	41.67	0	8.33	0	50.0	50.0	0	0	0	50.0

3.2. Detection of *T. Urticae* Damage Using Hyperspectral Imaging

3.2.1. Detection of *T. Urticae* Damage

Figure 4 shows the average reflectance spectra obtained from the upper side and the underside of healthy and damaged regions of sets G1 and G2 according to age. Both healthy and damaged spectra follow the typical pattern of the reflectance of healthy and

stressed plants [51]. Most differences between healthy and damaged areas were found in the visible region due to changes in the colouration of the plants, as the damage by *T. urticae* causes a chlorotic spot characterised by a yellow discolouration. This discolouration is caused by a loss of pigments due to the effect of the pest. Leaf pigments (mainly chlorophyll, carotene, and xanthophyll) are an essential factor in energy absorption by leaves in the 400–700 nm region [52]. Specifically, for healthy areas, the absorption level in the 530–600 nm region was lower, and therefore, the reflectance was higher than in the adjacent blue and red regions, its highest point being around 550 nm [53]. This fact is responsible for the perception of the green colour in the leaves.

In contrast, the damaged regions did not show any peak around 550 nm due to discolouration on the leaf caused by the pest. In this case, the curve extended between the green and red regions in the visible spectrum, reaching its midpoint around 600 nm and showing the peak in different areas of this range of the spectrum. As of 700 nm, a transition was observed in the chlorophyll absorption zone with the progressive rise in the spectrum value to the 740–750 nm bands. This sharp rise in the curve between the red and the NIR region is known as red-edge. The slope and the red-edge position have been correlated with chlorophyll concentrations, and therefore, the position and slope of the red border also change in damaged leaves because healthy ones continue to have active photosynthesis [54].

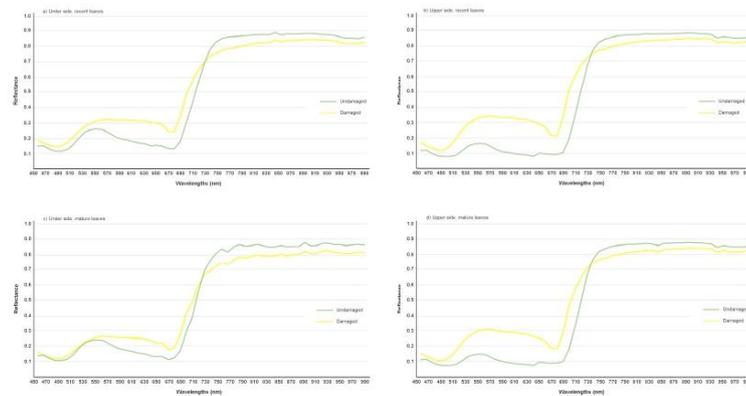


Figure 4. Mean spectra of healthy and damaged regions extracted from sets G1 (undamaged) and G2 (damaged) at each age and on (a) under side, recent leaves; (b) upper side recent leaves; (c) under side mature leaves, and (d) upper side mature leaves.

Two classification models were built based on supervised PLS-DA using all of the 56 wavelengths in the spectral range 450–1000 nm and using only the selected wavelengths. Figure 5 shows the vector of regression coefficients on each side and for each age of the leaf. Those wavelengths with the highest absolute regression coefficients were selected as essential wavelengths. In the case of the upper side, apparent visual differences are observed between the green of the healthy regions (530 nm) and the yellow chlorotic spots of the damaged areas (600 nm). However, the most important wavelengths were three identified around the red and the red-edge regions (670, 700, and 740 nm).

Variations in spectral variables (X) and categorical variables (Y) were described by only seven LVs. This relatively small number of LVs suggests a low correlation in the spectra of different classes but similarities in the spectra within classes. Furthermore, the low number of LVs indicated the excellent differentiation between the classes that were constructed. Moreover, for the use of all and the selected wavelengths, the values of RMSEP did not show a great difference for calibration and validation, respectively,

which exhibited good agreement, thus indicating that the calibration error is a reasonable estimation of the standard error of prediction observed in the test set. Furthermore, the test set yielded results similar to those of the calibration set, with an R^2 greater than 0.87 in all cases, thus indicating the excellent performance of the model for the classification of damage. Indeed, the rate of successful classification achieved was 100% for all cases. The models could detect 100% of cases of damage by *T. urticae* in mature and recent leaves and on the upper and the undersides.

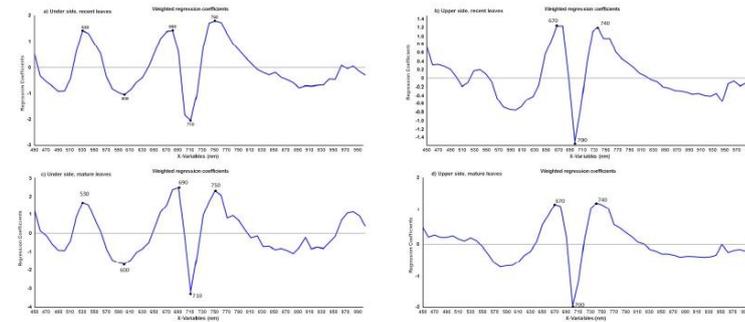


Figure 5. Vector of regression coefficients of the PLS model using mean spectra and with the optimal wavelengths selected at each age and on (a) under side, recent leaves; (b) upper side recent leaves; (c) under side, mature leaves; and (d) upper side mature leaves.

3.2.2. Detection of the Age of the *T. urticae* Damage

In order to determine whether the damage was caused by a recent or an old infestation of *T. urticae*, Figure 6 shows the mean spectral reflectance obtained from the damage caused by this pest for each side as a function of the age of the leaf. Some differences were observed between recent and mature leaves with damage on both sides of the leaves. The reflectance of the damage of the mature leaves is lower than the reflectance of recent leaves, especially in the visible part of the spectrum. This could be due to differences in the pigmentation. A low pigmentation content results in higher reflectance and vice versa. Therefore, in a recent leaf affected by *T. urticae*, the breaking down of chlorophylls causes the presence of carotenes and xanthophyll to be more evident, thus producing a sharp increase in the reflectance [55]. Another possible reason could be the changes in the spectral properties of plant leaves during the growing season. The very recent folded, compact, and underdeveloped leaves exhibit a lack of chlorophyll that increases the reflectance, while leaves with a brown appearance diminish the near-infrared reflectance [55].

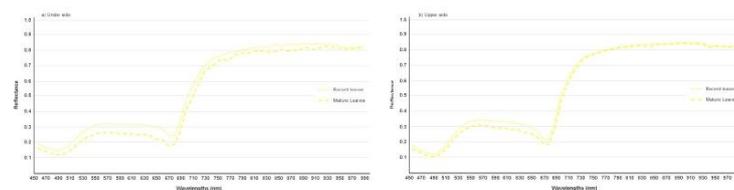


Figure 6. Mean spectra of damaged regions caused by *T. urticae* on (a) under side and (b) upper side of recent and mature leaves.

Five wavelengths were obtained from the vector of regression coefficients per underside and seven per upper side of the leaf (Figure 7). The spectral bands selected as essential are mostly located behind the red-edge, the 850-nm spectral band being typical for both sides of the leaf.

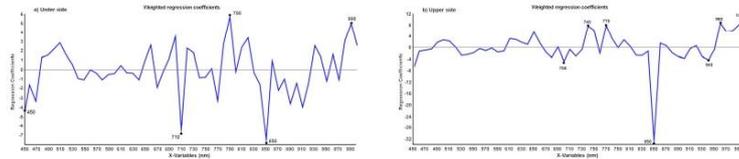


Figure 7. Vector of regression coefficients of the PLS model using mean spectra and with the optimal wavelengths selected on (a) under side and (b) upper side of the leaf.

Table 5 shows the results obtained for PLS-DA classification according to the age of the damage. For both models, a high percentage of damage was correctly classified according to the age of the damage (>92% for all cases). It is noticeable that the success rate of 100% was achieved for the underside, since it is the part of the leaf where the mite feeds and the damage is quite apparent.

For the underside, the RMSEP values obtained in the optimal wavelengths PLS model were higher compared to the model with all wavelengths. Both showed agreement between calibration and validation, also obtaining an R^2 higher than 0.87 in all cases. On the other hand, the upper side of the leaf showed a very low R^2 for prediction, with a value of 0.65 for the model based on all wavelengths.

Table 5. Classification of age of *T. urticae* damage (%) for the validation set by PLS-DA using all and selected wavelengths on each side of the leaf.

		Latent Variables	Class	
			Recent	Mature
Underside	All wavelengths	7	Recent mature	100 0
	Selected wavelengths	5	Recent mature	100 0
Upper side	All wavelengths	7	Recent mature	88.89 3.70
	Selected wavelengths	5	Recent mature	86.73 1.02

3.2.3. Discrimination between *T. urticae* and Other Damage

The mean reflectance spectra of healthy leaves, damage by *T. urticae* and *P. citrella*, and leaves with different deficiencies were evaluated for each side of the leaf (Figure 8).

In the spectral range from green to red, the differences could be observed between the various types of damage. The set G2 (*T. urticae*) and the subsets G4.1 (N deficiency) and G4.2 (damage due to other deficiencies) presented a peak at around 550–570 nm on both sides of the leaf, but with a level of a different intensity. On the other hand, the set G3 (*P. citrella*) presented a different behaviour depending on the side of the leaf, since the gallery created by the larva during its feeding is quite visible only on one side of the leaf.

The valley in the 670–690 nm region was marked in all cases, indicating the absorption of chlorophyll to a greater or lesser extent. In the 700 to 750 nm region, the spectrum value increased, but not with the same level of intensity for all cases. G3 obtained low reflectance values in the NIR for the other types of damage, which indicated that this vegetation was quite diseased or that it had a considerable lack of humidity. In this spectral region, valleys and peaks can be seen quite clearly in different spectral bands for

each type of damage. On both sides of the leaf, the peak at 760 nm and the valley at 770 nm are typical for damage not caused by *T. urticae*. The same happened with the peak at 900 nm.

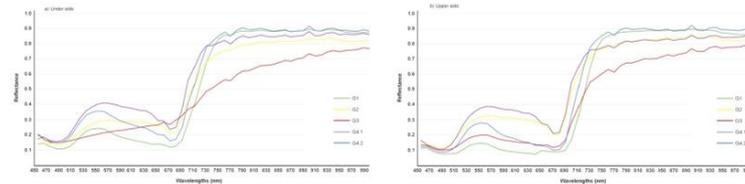


Figure 8. Mean spectra of healthy leaves (G1), damage by *T. urticae* (G2) and *P. citrella* (G3), and leaves with N deficiency (G4.1) and with other deficiencies (G4.2) on (a) under and (b) upper side.

The wavelengths that made the biggest contribution to the classification were obtained through the regression coefficients from the PLS model (Figure 9). This vector of regression coefficients showed nine wavelengths on the underside and eleven on the upper side of the leaf.

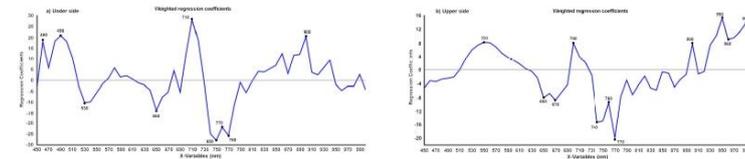


Figure 9. Vector of regression coefficients of the PLS model using mean spectra and with the optimal wavelengths selected on (a) under side and (b) upper side of the leaf.

The RMSEP values for calibration and validation in the models with the full spectrum and the selected wavelengths were similar. The prediction R^2 for the two sides showed values of 0.85 and 0.84 using all the wavelengths and 0.80 and 0.86 using the selected wavelengths.

Table 6 shows the results obtained for the damage classification based on the groups of samples. All models, using all and the optimal wavelengths, showed a low percentage of correctly classified damage (<50%), with the lowest value for the damage caused by other deficiencies (0% on both models on each side of the leaf).

Table 6. Damage classification according to the presence of different types of damage of the validation set by PLS-DA using all and selected wavelengths on each side of the leaf.

	Latent Variables	Set	Class (%)				
			G1	G2	G3	G4.1	G4.2
Underside	All wavelengths	G1	100	0	0	0	0
		G2	0	75.93	1.85	16.67	5.56
		G3	0	0	100	0	0
		G4.1	0	33.33	0	66.67	0
		G4.2	20	80	0	0	0
	Selected wavelengths	G1	100	0	0	0	0
		G2	0	69.67	1.85	22.92	5.56
		G3	0	0	100	0	0
		G4.1	0	33.33	0	66.67	0
		G4.2	0	100	0	0	0

Upper side	All wavelengths	7	G1	95.83	4.17	0	0	0
			G2	0	81.48	1.85	12.96	3.70
			G3	0	0	100	0	0
			G4.1	0	16.67	16.67	66.67	0
	G4.2	20	80	0	0	0		
	Selected wavelengths	4	G1	95.83	4.17	0	0	0
			G2	0	94.20	1.85	3.95	0
			G3	0	0	100	0	0
G4.1			0	33.33	0	66.67	0	
G4.2	0	100	0	0	0			

It is worth noting the potential of the system to detect damage caused by *P. citrella* that is almost invisible from the upper side of the leaves, as can be seen in Figure 1 and Figure 10a. Although this was not the aim of this research, which focused on damage caused by *T. urticae*, this finding is relevant. *P. citrella* is a severe and dangerous pest that is difficult for any automated surveillance system to detect, as the visible damage is caused in the underside. However, using a wavelength of 770 nm, which the PLS analysis identified as one of the most important for the problem, it was possible to see the damage that could not be detected using the colour vision system. Figure 10a shows the comparison between the upper side of a leaf photographed with a colour camera and in the 770 nm band. In general, as shown in Figure 10b, the damaged area presents a lower reflectance in the NIR region, which is in agreement with most scientific works on the reflectance of stressed plants.

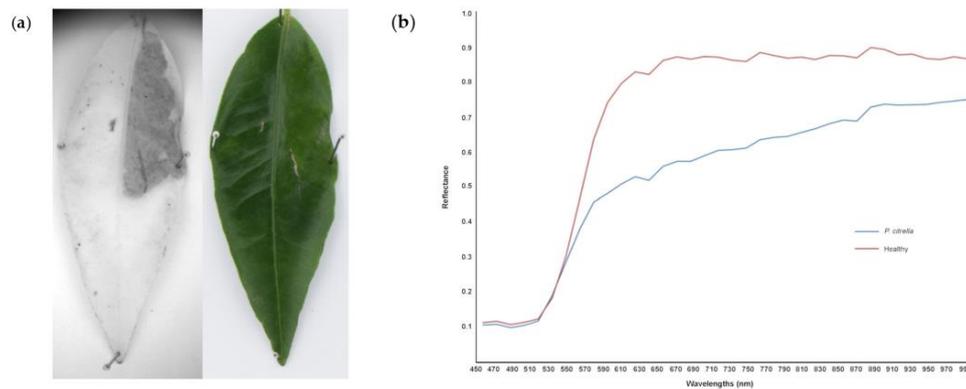


Figure 10. (a) Comparison of the image of the upper side of a leaf captured at 700 nm with the hyperspectral camera and the image of the same leaf captured with the colour camera. (b) Spectra of the healthy and damaged regions of this leaf.

4. Conclusions

Colour and VIS/NIR hyperspectral imaging were evaluated under laboratory conditions to detect the damage caused by *T. urticae* and if it is recent or old. Likewise, they were tested to determine their capacity to discriminate it from other damage, as the caused by *P. citrella*, and other nutritional deficiencies on tangerine leaves.

In colour imaging, a success rate of 100% was obtained to identify leaves without damages while the leaves with the presence of *T. urticae* were correctly identified in 92.5% of cases. Most errors were caused by confusion with some deficiencies. However, this method was not capable of discriminating between old and recent damage caused by *T. urticae*.

In hyperspectral imaging, the PLS-DA model was able to separate sound from damaged areas in 100% of cases. On the one hand, recent infestations were distinguished from old ones in 92% of cases, with a 100% success rate for the underside of the leaves, as the damage is more evident on this surface. On the other hand, the models for exploring their capability to discriminate between *T. urticae* and damage caused by other problems showed a percentage of correctly classified damage of less than 50%. More specifically, for the discrimination of damage caused by other deficiencies versus *T. urticae*, it was impossible to establish discriminatory differences.

Although it was not the objective of this research, a relevant finding has been the potential of hyperspectral systems to detect the damage caused by *P. citrella*. This pest is difficult to detect by any automatic surveillance system because the damage is hidden on the underside of the leaves, and hence, it is difficult to see beyond a certain distance.

The results indicated the potential of colour and hyperspectral imaging to detect the chlorotic spots caused by *T. urticae* in citrus leaves as fast and automatic techniques that represent an improvement on manual methods.

Author Contributions: Conceptualisation, J.B. and P.C.; Data curation, M.G.G.-G.; Formal analysis, M.G.G.-G.; Funding acquisition, J.B. and P.C.; Investigation, M.G.G.-G.; Methodology, J.B.; Project administration, P.C.; Software, J.B. and S.C.; Supervision, P.C.; Validation, S.C.; Writing—original draft, M.G.G.-G.; Writing—review and editing, J.B. and P.C. All authors have read and agreed to the published version of the manuscript.

Funding: This work was partially funded by the Generalitat Valenciana–Instituto Valenciano de Investigaciones Agrarias (GVA-IVIA) project 51918 and the European Regional Development Funds (ERDF). María Gyomar González-González thanks INIA for the FPI-INIA grant CPD2016-0007, partially supported by European Social Funds (FSE).

Acknowledgments: In addition, we thank the owners of the Chiva and El Puig de Santa María crops for providing the leaves, the staff at the Centro de Agroingeniería-IVIA for technical support, and Ana Quiñones (from CDAS-IVIA) for advice in nutritional deficiencies.

Conflicts of Interest: The authors declare no conflict of interest. The funders had no role in the design of the study; in the collection, analyses, or interpretation of data; in the writing of the manuscript, or in the decision to publish the results.

Abbreviations

ANOVA	Analysis of variance
C	Calibration
CV	Cross-validation
CCD	Charge-coupled device
LDA	Linear discriminant analysis
LV	Latent variables
NIR	Near-infrared
NP/NND	No pest/No nutritional deficiencies
P	Prediction
P/ND	Pest/Nutritional deficiencies
PC	Principal component
PCA	Principal component analysis
<i>P.citrella</i>	<i>Phyllocnistis citrella</i>
PLS	Partial least squares
PLS-DA	Partial least squares discriminant analysis
R ²	Coefficient of determination
RGB	Red–Green–Blue
RMSE	Root mean square error
ROI	Region of interest
<i>T.urticae</i>	<i>Tetranychus urticae</i>
VIS	Visible
VNIR	Visible and near infrared

References

1. FAO/STAT. Food and agriculture organisation of the United Nations 2021. Available online: <http://faostat.fao.org> (accessed on 2 May 2021).
2. Hare, J.D. Sampling Arthropod Pests in Citrus. In *Handbook of Sampling Methods for Arthropods in Agriculture*; Pedigo, L.P., Buntin, G.D., Eds.; CRC Press: Boca Raton, FL, USA, 1994; pp 417–431.
3. Jacas, J.A.; Urbaneja, A. Biological Control in Citrus in Spain: From Classical to Conservation Biological Control. In *Integrated Management of Arthropod Pests and Insect Borne Diseases*; Springer Science and Business Media LLC: Berlin/Heisenberg, Germany, 2010; pp. 61–72.
4. Van Leeuwen, T.; Vontas, J.; Tsagakarakou, A.; Dermauw, W.; Tirry, L. Acaricide resistance mechanisms in the two-spotted spider mite *Tetranychus urticae* and other important Acari: A review. *Insect Biochem. Mol. Biol.* **2010**, *40*, 563–572, doi:10.1016/j.ibmb.2010.05.008.
5. Martínez-Ferrer, M.T.; Jacas, J.A.; Ripollés-Moles, J.L.; Aucejo-Romero, S. Approaches for Sampling the Twospotted Spider Mite (Acari: Tetranychidae) on Clementines in Spain. *J. Econ. Entomol.* **2006**, *99*, 1490–1499, doi:10.1603/0022-0493-99.4.1490.
6. Aucejo, S.; Foó, M.; Ramis, M.; Troncho, P.; Gómez-Cadenas, A.; Jacas, J.A. Evaluación de la eficacia de algunos acaricidas contra la araña roja, *Tetranychus urticae* Koch (Acari: Tetranychidae), en clementino. *Bol. San. Veg. Plagas.* **2003**, *29*, 453–459.
7. Ansaloni, T.; Pascual-Ruiz, S.; Hurtado, M.A.; Jacas, J.A.; Jaques, J.A. Can summer and fall vegetative growth regulate the incidence of *Tetranychus urticae* Koch on clementine fruit? *Crop. Prot.* **2008**, *27*, 459–464, doi:10.1016/j.cropro.2007.07.016.
8. Fenollosa, E.A.; Gual, M.V.I.; Ruiz, M.H.; Hurtado, M.; Jacas, J. Effect of ground-cover management on spider mites and their phytoseiid natural enemies in clementine mandarin orchards (I): Bottom-up regulation mechanisms. *Biol. Control.* **2011**, *59*, 158–170, doi:10.1016/j.biocontrol.2011.06.013.
9. Aucejo-Romero, S.; Gómez-Cadenas, A.; Jacas-Miret, J.-A. Effects of NaCl-stressed citrus plants on life-history parameters of *Tetranychus urticae* (Acari: Tetranychidae). *Exp. Appl. Acarol.* **2004**, *33*, 55–67, doi:10.1023/b:appa.0000030026.77800.0c.
10. Pascual-Ruiz, S.; Aguilar-Fenollosa, E.; Ibáñez-Gual, V.; Hurtado-Ruiz, M.A.; Martínez-Ferrer, M.T.; Jacas, J.A.; Jaques, J.A. Economic threshold for *Tetranychus urticae* (Acari: Tetranychidae) in clementine mandarins *Citrus clementina*. *Exp. Appl. Acarol.* **2013**, *62*, 337–362, doi:10.1007/s10493-013-9744-0.
11. Urbaneja, A.; Pascual-Ruiz, S.; Pina, T.; Abad-Moyano, R.; Vanaclocha, P.; Montón, H.; Dembilio, Ó.; Castañera, P.; Jacas, J.A.; Jaques, J.A. Efficacy of five selected acaricides against *Tetranychus urticae* (Acari: Tetranychidae) and their side effects on relevant natural enemies occurring in citrus orchards. *Pest Manag. Sci.* **2008**, *64*, 834–842, doi:10.1002/ps.1572.
12. Fonte, A.; Garcerá, C.; Tena, A.; Chueca, P. CitrusVol Validation for the Adjustment of Spray Volume in Treatments against *Tetranychus urticae* in Clementines. *Agronomy* **2019**, *10*, 32, doi:10.3390/agronomy10010032.
13. Soler-Salcedo, E.; Rodrigo, E.; Ferragut, F. Colonización, comportamiento alimenticio y producción de daños en las arañas rojas *Tetranychus urticae* y *T. turkestanii* (Acari: Tetranychidae). *Boletín Sanid. Veg. Plagas* **2006**, *32*, 523–534.
14. Jeppson, L.R.; Keifer, H.H.; Baker, E.W. *Mites Injurious to Economic Plants*; University of California Press: Berkeley, CA, USA, 1975.
15. Chueca, P.; Garcerá, C.; Moltó, E.; Jacas, J.A.; Urbaneja, A.; Pina, T. Spray Deposition and Efficacy of Four Petroleum-Derived Oils Used Against *Tetranychus urticae* (Acari: Tetranychidae). *J. Econ. Entomol.* **2010**, *103*, 386–393, doi:10.1603/ec09242.
16. Rey, B.; Aleixos, N.; Cubero, S.; Blasco, J. Xf-Rovim. A Field Robot to Detect Olive Trees Infected by *Xylella fastidiosa* Using Proximal Sensing. *Remote Sens.* **2019**, *11*, 221, doi:10.3390/rs11030221.
17. Cubero, S.; Marco-Noales, E.; Aleixos, N.; Barbé, S.; Blasco, J. RobHortic: A Field Robot to Detect Pests and Diseases in Horticultural Crops by Proximal Sensing. *Agriculture* **2020**, *10*, 276, doi:10.3390/agriculture10070276.
18. Martin, D.E.; Lathief, M.A. Remote Sensing Evaluation of Two-spotted Spider Mite Damage on Greenhouse Cotton. *J. Vis. Exp.* **2017**, *122*, e54314, doi:10.3791/54314.
19. Herrmann, I.; Berenstein, M.; Sade, A.; Kamieli, A.; Bonfil, D.J.; Weintraub, P.G. Spectral monitoring of two-spotted spider mite damage to pepper leaves. *Remote Sens. Lett.* **2012**, *3*, 277–283, doi:10.1080/01431161.2011.576709.
20. Fraulo, A.B.; Cohen, M.; Liburd, O.E. Visible/near infrared reflectance (VNIR) spectroscopy for detecting twospotted spider mite (Acari: Tetranychidae) damage in strawberries. *Environ. Entomol.* **2009**, *38*, 137–142, doi:10.1603/022.038.0117.
21. Crockett, C.; Liburd, O.; Abd-Elrahman, A. Development of image based detection methods for two-spotted spider mite, *Tetranychus urticae* Koch, on strawberries. In Proceedings of the Entomological Society of America Annual Meeting 2014, Portland, OR, USA, 16–19 November 2014.
22. Nieuwenhuizen, A.; Kool, J.; Suh, H.; Hemming, J. Automated spider mite damage detection on tomato leaves in greenhouses. *Acta Hort.* **2020**, *1268*, 165–172, doi:10.17660/actahortic.2020.1268.21.
23. Uygun, T.; Ozguven, M.M.; Yanar, D. A new approach to monitor and assess the damage caused by two-spotted spider mite. *Exp. Appl. Acarol.* **2020**, *82*, 335–346, doi:10.1007/s10493-020-00561-8.
24. Urbaneja, A.; Catalán, J.; Tena, A.; Jacas, J.A. Plagas y Enfermedades. Tetraniquidos. Araña Roja. In *Gestión Integrada de Plagas de Cítricos*; Urbaneja, A., Catalán, J., Tena, A., Jacas, J.A., Eds.; IVIA: Moncada, Spain, 2020. Available online: <http://gipcitricos.ivia.es/area/plagas-principales/tetraniquidos/arana-roja> (accessed on 2 May 2021).
25. Quiñones, A.; Martínez-Alcántara, B.; Primo-Millo, E.; Legaz, F. Fertigation: Concept and Application in Citrus. In *Advances in Citrus Nutrition*; Springer Science and Business Media LLC: Berlin/Heisenberg, Germany, 2012; pp. 281–301.

26. Futch, S.H.; Tucker, D.P.H. A Guide to Citrus Nutritional Deficiency and Toxicity Identification. University of Florida IFAS Extension Publication HS-797. 2000. Available online: <https://edis.ifas.ufl.edu/pdffiles/CH/CH14200.pdf> (accessed on 2 May 2021).
27. Zekri, M.; Obreza, T. Manganese (Mn) and Zinc (Zn) for Citrus Trees. Publication #SL403 of the Department of Soil and Water Sciences, UF/IFAS Extension. 2019. Available online: <https://edis.ifas.ufl.edu/pdffiles/SS/SS61600.pdf> (accessed on 2 May 2021).
28. Landgrebe, D. Hyperspectral image data analysis. *IEEE Signal Process. Mag.* **2002**, *19*, 17–28, doi:10.1109/79.974718.
29. Rivera, N.V.; Gómez-Sanchis, J.; Chanona-Pérez, J.; Carrasco, J.J.; Millán-Giraldo, M.; Lorente, D.; Cubero, S.; Blasco, J. Early detection of mechanical damage in mango using NIR hyperspectral images and machine learning. *Biosyst. Eng.* **2014**, *122*, 91–98, doi:10.1016/j.biosystemseng.2014.03.009.
30. Kumar, T.K. Multicollinearity in Regression Analysis. *Rev. Econ. Stat.* **1975**, *57*, 365, doi:10.2307/1923925.
31. Hawkins, D.M. The Problem of Overfitting. *J. Chem. Inf. Comput. Sci.* **2004**, *44*, 1–12, doi:10.1021/ci0342472.
32. Amigo, J.M.; Martí, I.; Gowen, A. Hyperspectral Imaging and Chemometrics. In *Multivariate Pattern Recognition in Chemometrics, Illustrated by Case Studies*; Elsevier BV: Amsterdam, The Netherlands, 2013; Volume 28, pp. 343–370.
33. Lorente, D.; Aleixos, N.; Gomez-sanchis, J.; Cubero, S.; García-Navarrete, O.L.; Blasco, J. Recent Advances and Applications of Hyperspectral Imaging for Fruit and Vegetable Quality Assessment. *Food Bioprocess Technol.* **2012**, *5*, 1121–1142, doi:10.1007/s11947-011-0725-1.
34. Vinzi, V.E.; Chin, W.W.; Henseler, J.; Wang, H. *Handbook of Partial Least Squares*; Springer: Berlin/Heisenberg, Germany, 2010.
35. Tagliavini, M.; Quiñones, A. Nutrizione e Concimazione. In *Glo Agrumi*; Tribulato, E., Inglese, P., Eds.; Bayer CropScience: Milano, Italy, 2012, pp. 183–193.
36. Diago, M.P.; Tardáguila, J.; Aleixos, N.; Millán, B.; Prats-Montalban, J.M.; Cubero, S.; Blasco, J. Assessment of cluster yield components by image analysis. *J. Sci. Food Agric.* **2014**, *95*, 1274–1282, doi:10.1002/jsfa.6819.
37. Elmasry, G.; Cubero, S.; Moltó, E.; Blasco, J. In-line sorting of irregular potatoes by using automated computer-based machine vision system. *J. Food Eng.* **2012**, *112*, 60–68, doi:10.1016/j.jfoodeng.2012.03.027.
38. Blasco, J.; Cubero, S.; Gómez-Sanchis, J.; Mira, P.; Moltó, E. Development of a machine for the automatic sorting of pomegranate (*Punica granatum*) arils based on computer vision. *J. Food Eng.* **2009**, *90*, 27–34, doi:10.1016/j.jfoodeng.2008.05.035.
39. Blasco, J.; Aleixos, N.; Cubero, S.; Gómez-Sanchis, J.; Moltó, E. Automatic sorting of satsuma (*Citrus unshiu*) segments using computer vision and morphological features. *Comput. Electron. Agric.* **2009**, *66*, 1–8, doi:10.1016/j.compag.2008.11.006.
40. Gat, N. Imaging spectroscopy using tunable filters: A review. *Wavelet Appl. VII* **2000**, *4056*, 50–65, doi:10.1117/12.381686.
41. Williams, P.J.; Kucheryavskiy, S. Classification of maize kernels using NIR hyperspectral imaging. *Food Chem.* **2016**, *209*, 131–138, doi:10.1016/j.foodchem.2016.04.044.
42. Brereton, R.G. *Applied Chemometrics for Scientists*; Wiley: Hoboken, NJ, USA, 2007.
43. Mehmood, T.; Liland, K.H.; Snipen, L.; Sæbø, S. A review of variable selection methods in Partial Least Squares Regression. *Chemom. Intell. Lab. Syst.* **2012**, *118*, 62–69, doi:10.1016/j.chemolab.2012.07.010.
44. Munera, S.; Amigo, J.M.; Aleixos, N.; Talens, P.; Cubero, S.; Blasco, J. Potential of VIS-NIR hyperspectral imaging and chemometric methods to identify similar cultivars of nectarine. *Food Control.* **2018**, *86*, 1–10, doi:10.1016/j.foodcont.2017.10.037.
45. Rinnan, Å.; Berg, F.V.D.; Engelsen, S.B. Review of the most common pre-processing techniques for near-infrared spectra. *TrAC Trends Anal. Chem.* **2009**, *28*, 1201–1222, doi:10.1016/j.trac.2009.07.007.
46. Hastie, T.; Friedman, J.; Tibshirani, R. Model Assessment and Selection. In *Linear and Generalized Linear Mixed Models and Their Applications*; Springer Science and Business Media LLC: Berlin, Germany, 2001; pp. 193–224.
47. Kuhn, M.; Johnson, K. *Applied Predictive Modeling 26*; Springer: New York, NY, USA, 2013.
48. Cortés, V.; Rodríguez, A.; Blasco, J.; Rey, B.; Besada, C.; Cubero, S.; Salvador, A.; Talens, P.; Aleixos, N. Prediction of the level of astringency in persimmon using visible and near-infrared spectroscopy. *J. Food Eng.* **2017**, *204*, 27–37, doi:10.1016/j.jfoodeng.2017.02.017.
49. Chen, Y.; Xie, M.-Y.; Yan, Y.; Zhu, S.-B.; Nie, S.-P.; Li, C.; Wang, Y.-X.; Gong, X.-F. Discrimination of *Ganoderma lucidum* according to geographical origin with near infrared diffuse reflectance spectroscopy and pattern recognition techniques. *Anal. Chim. Acta* **2008**, *618*, 121–130, doi:10.1016/j.aca.2008.04.055.
50. Snedecor, G.W.; Cochran, W.G. *Statistical Methods*, 8th Ed.; Iowa State University Press: Ames, IA, USA, 1989.
51. Reid, N.J. ES&T Views: Remote Sensing and Forest Damage. *Environ. Sci. Technol.* **1987**, *21*, 428–429, doi:10.1021/es00159a602.
52. Alonso, C.; Moreno, V.; Rodríguez, E. Determinación Experimental de la Firma Espectral de la Vegetación. Una Sencilla Práctica de introducción a la teledetección. In *TELEDETECCIÓN. Avances y Aplicaciones*; VIII Congreso Nacional de Teledetección: Albacete, Spain, 1999, pp. 429–443.
53. Arnon, D.I. The Light Reactions of Photosynthesis. *Proc. Natl. Acad. Sci. USA* **1971**, *68*, 2883–2892, doi:10.1073/pnas.68.11.2883.
54. Rock, B.N.; Vogelmann, J.E.; Williams, D.L.; Hoshizaki, T. Remote Detection of Forest Damage. *Bioscience* **1986**, *36*, 439–445, doi:10.2307/1310339.
55. Roy, P.S. Spectral reflectance characteristics of vegetation and their use in estimating productive potential. *Plant Sci.* **1989**, *99*, 59–81, doi:10.1007/BF03053419.