

UNIVERSIDAD COMPLUTENSE DE MADRID

FACULTAD DE VETERINARIA

**MÁSTER UNIVERSITARIO EN I+D+i EN LA INDUSTRIA
ALIMENTARIA**

TRABAJO FIN DE MÁSTER



**CREACIÓN DE MAPAS DE COBERTURA DE MALAS
HIERBAS PARA DAR SOPORTE A ESTRATEGIAS
AGROECOLÓGICAS**

Realizado por: Lúa Lázaro Recio

Madrid, 2025

**MÁSTER UNIVERSITARIO EN I+D+I EN LA INDUSTRIA ALIMENTARIA
POR LA UNIVERSIDAD COMPLUTENSE DE MADRID**

TRABAJO FIN DE MÁSTER



**CREACIÓN DE MAPAS DE COBERTURA DE MALAS
HIERBAS PARA DAR SOPORTE A ESTRATEGIAS
AGROECOLÓGICAS**

**CREATION OF WEED COVERAGE MAPS TO
SUPPORT AGROECOLOGICAL STRATEGIES**

AUTOR: Lúa Lázaro Recio

BAJO LA DIRECCIÓN

TUTOR/ES: María Guijarro Mata-García

Departamento de Arquitectura de Computadores y Automática

Luis Emmi

Centro de Automática y Robótica (CAR)-CSIC

Madrid, 2025

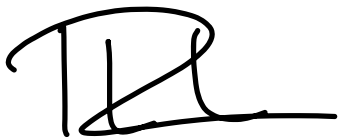
Declaración personal de buena práctica académica

D./Dña. Lúa Lázaro Recio con DNI 02599939L, estudiante del Máster Universitario en I+D+i en la Industria Alimentaria, impartido en la Facultad de Veterinaria, de la Universidad Complutense de Madrid en el curso 2024- 2025, como autor/a del Trabajo Fin de Máster titulado creación de mapas de cobertura de malas hierbas para dar soporte a estrategias agroecológicas y presentado para la obtención del título correspondiente, cuyo/s tutor/es es/son: María Guijarro Mata-García y Luis Emmi.

DECLARO QUE:

El Trabajo Fin de Máster que presento está elaborado por mí y es original. Las citas integrales, datos, ilustraciones, tablas, figuras, formulaciones, etc. incluidos por requerimiento del desarrollo del trabajo realizado se mencionan de forma clara y estricta su origen, tanto en el cuerpo del texto como en las referencias bibliográficas. Así mismo, declaro que los datos son veraces y que no he hecho uso de información no autorizada de cualquier fuente. De igual manera, soy plenamente consciente de que el hecho de no respetar estas directrices es objeto de sanciones universitarias y/o de otro orden.

En Madrid, a 12 de septiembre de 2025



Fdo: Lúa Lázaro Recio

Propiedad intelectual y difusión del trabajo

La **propiedad intelectual** del Trabajo Fin de Máster se ha acordado que sea:

Propiedad conjunta, del estudiante y del tutor/es.

Conforme con el acuerdo establecido

Firma tutora (1)

GUIJARRO
MATA-
GARCIA
MARIA -
75244418X

Firmado digitalmente por GUIJARRO MATA-GARCIA MARIA - 75244418X
Fecha: 2025.09.11 17:22:42 +02'00'

Firma Tutor (2)

EMMI LUIS
ALFREDO
- DNI
Y0797675
A

Firmado digitalmente por EMMI LUIS ALFREDO - DNI Y0797675A
Nombre de reconocimiento (DN): c=ES, o=CONSEJO SUPERIOR DE INVESTIGACIONES CIENTIFICAS, ou=CERTIFICADO ELECTRONICO DE EMPLEADO PUBLICO, ou=CENTRO DE AUTOMATICA Y ROBOTICA, ou=00009100, serialNumber=ICES-Y0797675A, sn=EMMI, givenName=LUIS ALFREDO, cn=EMMI LUIS ALFREDO - DNI Y0797675A
Fecha: 2025.09.12 10:14:14 +02'00'

Firma estudiante


Lúa Lázaro Recio

Fdo.:

Fdo.:

Fdo.:

No se autoriza la difusión de la versión electrónica del Trabajo Fin de Máster en la web de la Facultad y del Máster.

Firma tutora (1)

Firma Tutor (2)

Firma estudiante


Lúa Lázaro Recio

Fdo.:

Fdo.:

Fdo.:

AUTOR

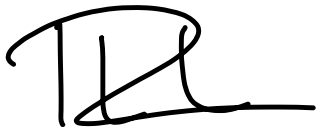
Nombre y apellidos: Lúa Lázaro Recio

Teléfono: 651519561

e-mail: lualazar@ucm.es

Orientación (Profesional/Investigadora): Profesional

Itinerario de Especialización: Automatización, Control y Robótica en la Industria Alimentaria



Fdo: Lúa Lázaro Recio

Vº Bº PARA PRESENTAR A DEFENSA

TUTORA (1)

Nombre y apellidos: María Guijarro Mata-García

Departamento/Sección Departamental: Departamento de Arquitectura de Computadores y Automática

Facultad: Facultad de Informática

Teléfono: 639004255

e-mail: mguijarro@fdi.ucm.es

Vº Bº para presentar a defensa

GUIJARRO Firmado
MATA- digitalmente por
GARCIA GUIJARRO MATA-
MARIA - GARCIA MARIA -
75244418X 75244418X
Fecha:
2025.09.11
17:22:42 +02'00'

Fdo.:

TUTOR (2)

Nombre y apellidos: Luis Emmi

Departamento/Sección/Área: Grupo de Robótica de Exteriores y de Servicios (FSR).

Facultad/Entidad/Empresa: Centro de Automática y Robótica (CSIC-UPM).

Teléfono: 6030415654

e-mail: luis.emmi@car.upm-csic.es

Vº Bº para presentar a defensa

**EMMI LUIS
ALFREDO
- DNI
Y0797675
A**

Firmado digitalmente por EMMI
LUIS ALFREDO - DNI Y0797675A
Nombre de reconocimiento
(DN): c=ES, o=CONSEJO
SUPERIOR DE INVESTIGACIONES
CIENTIFICAS, ou=CERTIFICADO
ELECTRONICO DE EMPLEADO
PUBLICO, ou=CENTRO DE
AUTOMATICA Y ROBOTICA,
ou=00009100,
serialNumber=IDCES-
Y0797675A, sn=EMMI,
givenName=LUIS ALFREDO,
cn=EMMI LUIS ALFREDO - DNI
Y0797675A
Fecha: 2025.09.12 10:14:14
+02'00'

Fdo.:

AGRADECIMIENTOS:

A mis compañeros del CAR: Kai, Daniel, Eduardo, Alain y Ana por no dudar en brindarme su experiencia, acompañarme en este importante desafío y hacerme sentir desde el inicio parte del equipo. De no ser por ellos, quizá todavía seguiría tratando de descubrir qué es la terminal del ordenador.

En Madrid, a 12 de septiembre de 2025

RESUMEN

La creciente dependencia de herbicidas sintéticos en los sistemas agrícolas ha generado impactos negativos en la salud ambiental, la biodiversidad y la sostenibilidad de los agroecosistemas. A través de este trabajo se propone una metodología innovadora para la identificación y localización de malas hierbas mediante el uso de visión artificial, procesamiento de imágenes y técnicas de clasificación automática, con el fin de optimizar la gestión de cultivos y reducir el uso de agroquímicos.

El estudio se llevó a cabo en un campo de cultivo de caquis en Valencia, utilizando un robot autónomo. A partir de la captura de imágenes se generaron nubes de puntos 3D y ortoimágenes, que permitieron aplicar técnicas de segmentación de vegetación, mejora de imagen y detección de puntos clave con el propósito de aislar las malas hierbas de forma individual. Posteriormente, las zonas de interés fueron analizadas con herramientas de clasificación, desarrolladas por terceros, para identificar especies vegetales de forma automática.

Los resultados evidencian que la metodología permite identificar especies de malas hierbas en condiciones reales de campo, incluso en escenarios de variabilidad lumínica y de densidad vegetal. La validación de esta clasificación se encuentra fuera del alcance de este trabajo, dado que requiere la intervención de expertos herboristas para su correcta verificación. No obstante, la metodología desarrollada posibilita la generación de mapas de cobertura precisos que facilitan la toma de decisiones agronómicas, posibilitando la aplicación focalizada de tratamientos, la reducción en el uso de herbicidas y el avance hacia prácticas agroecológicas más sostenibles.

Palabras clave: agroecología, visión artificial, malas hierbas, mapas de cobertura, sostenibilidad.

SUMMARY

The increasing dependence on synthetic herbicides in agricultural systems has generated negative impacts on environmental health, biodiversity, and the sustainability of agroecosystems. This work proposes an innovative methodology for the identification and localization of weeds through the use of computer vision, image processing, and automatic classification techniques, with the aim of optimizing crop management and reducing the use of agrochemicals.

The study was carried out in a persimmon field in Valencia using an autonomous robot. Based on the captured images, 3D point clouds and orthophotos were generated, which enabled the application of vegetation segmentation techniques, image enhancement, and keypoint detection with the purpose of isolating weeds individually. Subsequently, the areas of interest were analyzed with classification tools developed by third parties to automatically identify plant species.

The results show that the methodology is capable of identifying weed species under real field conditions, even in scenarios of light variability and plant density. The validation of this classification lies beyond the scope of this work, as it requires the intervention of expert herbalists for proper verification. Nevertheless, the developed methodology makes it possible to generate precise coverage maps that support agronomic decision-making, enabling targeted treatment applications, reducing herbicide use, and advancing toward more sustainable agroecological practices.

Keywords: agroecology, computer vision, weeds, coverage maps, sustainability.

Contenido

1. INTRODUCCIÓN	1
1.1. Desafíos actuales	1
1.1. Políticas y estrategias de la agricultura europea	2
1.2. Alternativas sostenibles y tecnologías emergentes.....	4
1.3. Proyecto AGROSUS	5
2. JUSTIFICACIÓN Y OBJETIVOS	7
3. MATERIALES Y MÉTODOS	9
3.4. Acondicionamiento de los datos.....	10
3.4.1. Carga y visualización inicial de datos	11
3.4.2. Configuración de la cámara y transformaciones espaciales.....	12
3.4.3. Creación de la nube de puntos.....	14
3.4.4. Detección de áreas verdes.	15
3.4.5. Recorte de la nube de puntos.....	19
3.4.6. Mejora de la calidad de la imagen.....	20
3.4.7. Detección de elementos clave (ORB)	22
3.5. Análisis y clasificación.....	23
4. RESULTADOS Y DISCUSIÓN.....	25
4.1. Visualización de las imágenes	25
4.2. Nube de puntos	27
4.3. Detección de zonas verdes.....	28
4.4. Mejora de la imagen.	30
4.5. Detección de puntos clave mediante ORB.	32
4.6. Resultados del análisis y clasificación.....	33

4.7. Trabajo futuro.....	35
5. CONCLUSIONES	36
6. CONCLUSIONS.....	37
7. BIBLIOGRAFÍA.....	38

Índice de figuras

Figura 3.1 Imagen satelital campo de cultivo Valencia.....	10
Figura 3.2 Cámara TRI032S-CC RGB de LUCID. Fuente: Triton Industrial Camera. Vision Labs, 2025	11
Figura 3.3 Cámara ZED 2i. Stereo Camer. Fuente:ZED 2i. Stereo Camera, 2025.....	11
Figura 3.4 Calibración cámara ZE.....	13
Figura 3.5 Calibración cámara RGB.....	13
Figura 3.6 Funcionamiento de un kernel. Fuente: (ScienceDirect Topics, 2025).....	17
Figura 3.7 Transformación morfológica:	18
Figura 3.8 Transformación morfológica:	18
Figura 3.9 Ejemplo de Región de Interés (ROI). Fuente: Elaboración propia.....	20
Figura 4.1 Imagen 401 RGB (Cámara RGB). Fuente: Elaboración propia	25
Figura 4.2 Imagen 401 RGB (cámara ZED). Fuente: Elaboración propia.....	25
Figura 4.3 Imagen 401 depth (cámara ZED).....	25
Figura 4.4 Nube de puntos. Imagen 401. Fuente: Elaboración propia.....	28
Figura 4.5 Nube de puntos recortada. Imagen 401. Fuente: Elaboración propia.....	28
Figura 4.6 Máscara binaria Imagen 401. Fuente: Elaboración propia.....	29
Figura 4.7 Máscara filtrado por área. Imagen 401. Fuente: Elaboración propia.....	29
Figura 4.8 Máscara binaria recortada. Imagen 401. Fuente: Elaboración propia.....	30

Figura 4.9 Imagen 100 antes de la mejora del brillo. Fuente: Elaboración propia.	31
Figura 4.10 Imagen 100 después de la mejora del brillo. Fuente: Elaboración propia.....	31
Figura 4.11 Imagen 401 antes de la mejora del brillo. Fuente: Elaboración propia.	32
Figura 4.12 Imagen 401 después de la mejora del brillo. Fuente: Elaboración propia.....	32
Figura 4.13 Algoritmo de detección sobre la máscara binaria. Imagen 401.....	33
Figura 4.14 Representación visual del algoritmo de detección. Imagen 401.....	33
Figura 4.15 Recorte 1 Imagen 401. Fuente: Elaboración propia.	34
Figura 4.16 Recorte 2 Imagen 401. Fuente: Elaboración propia.	34
Figura 4.17 Recorte 3 Imagen 401.Fuente: Elaboración propia.	34

Índice de ecuaciones

Ecuación 3.1 Matriz de transformación extrínseca. Fuente: Elaboración propia.....	12
Ecuación 3.2 Índice de Exceso de Verde. Fuente: Elaboración propia.....	16

1.INTRODUCCIÓN

1.1. Desafíos actuales

Actualmente, la agricultura se enfrenta a desafíos cada vez más complejos, como la degradación de los suelos, la pérdida de la biodiversidad, las precarias condiciones laborales y el envejecimiento de la población rural, impulsados por el aumento de la demanda de alimentos y el crecimiento demográfico (Rabbee et al., 2024). Para responder a esta situación, se ha intensificado la producción agrícola, a través del uso extensivo de productos fitosanitarios sintéticos (PFPs) y prácticas convencionales como la labranza intensiva, el riego abundante y el control químico de plagas y enfermedades (Abdo et al., 2025). Sin embargo, esta dependencia ha generado serias preocupaciones en torno a la sostenibilidad ambiental y la seguridad alimentaria (El jaouhari et al., 2023).

Los impactos negativos derivados de este modelo agrícola son múltiples y de gran alcance, entre ellos destaca su contribución al cambio climático y a la contaminación ambiental. Un ejemplo que demuestra el impacto que supone en el medio ambiente el uso de agricultura convencional, es el cultivo de cereales. Esta metodología ha incrementado de forma notable el potencial de calentamiento global (PCG) de los cultivos, llegando a multiplicarlo por ocho entre 1961 y 2020 (Abdo et al., 2025). La labranza, la aplicación de fertilizantes sintéticos y la irrigación explican el 90% de este aumento, mientras que el uso de fertilizantes multiplicó por diez las emisiones de gases de efecto invernadero (GEI) en el mismo periodo. A este incremento hay que sumarle el aporte de gases de efecto invernadero que generan los plaguicidas, derivados de su producción, envasado, transporte y aplicación. Además, contribuyen a la contaminación del suelo, el agua y la atmosfera debido a procesos de escorrentía y persistencia (Jafir et al., 2023).

Otro efecto relevante es la pérdida de biodiversidad del suelo. Los herbicidas son los plaguicidas más utilizados a nivel global, en particular el glifosato. Siendo la sustancia más aplicada y con un uso creciente en las últimas décadas, llegando a representar el 50% de todas las aplicaciones de plaguicidas en 2019 (El jaouhari et al., 2023). Aunque este compuesto se considera de toxicidad relativamente baja en comparación con otros plaguicidas, los grandes volúmenes liberados en el ambiente constituyen un riesgo tanto para la salud humana como para el medio ambiente (García-Delgado et al., 2019). Diversos estudios han demostrado que los herbicidas ejercen efectos negativos significativos sobre las comunidades de fauna edáfica,

contribuyendo a la erosión de la diversidad y amenazando la estabilidad de los ecosistemas (Zilnik et al., 2023). Además, el uso sinérgico de herbicidas y la supresión de malezas desencadenan efectos tróficos que alteran la red alimentaria del suelo, mientras que los residuos de plaguicidas afectan la estructura de las comunidades microbianas, disminuyendo la población total de microorganismos y modificando la composición de bacterias y hongos (Galic et al., 2024).

Estas sustancias no solo alteran la biodiversidad, sino también las interacciones ecológicas del suelo, provocando impactos en cascada que desequilibran los ecosistemas. Pudiendo favorecer la proliferación de especies invasoras que desplazan a las nativas y modifican los regímenes ecológicos (Beaumelle et al., 2023).

La dependencia a los agroquímicos sintéticos ha favorecido el desarrollo de resistencias de plagas y patógenos. El uso intensivo de insecticidas ha promovido la aparición de poblaciones de insectos resistentes (Canada, 2018). A la vez se ha documentado la emergencia de bacterias y hongos con resistencia a medicamentos, un fenómeno que puede intensificarse con el cambio climático creando un desafío adicional para la sanidad y la seguridad alimentaria (IBIS, 2025)

1.1. Políticas y estrategias de la agricultura europea

La agricultura en la Unión Europea (UE) enfrenta un "triple desafío": **(I)** garantizar la seguridad alimentaria y la nutrición, **(II)** proporcionar sustento a los actores de la cadena alimentaria y **(III)** mejorar la sostenibilidad ambiental. Aunque representa solo el 1,7% del Producto Interno Bruto (PIB) de la UE, el sector agroalimentario es un actor clave en la economía, siendo uno de los mayores exportadores e importadores de productos agroalimentarios del mundo.

La agricultura es responsable de una parte significativa de las emisiones de gases de efecto invernadero (GEI) principalmente a través de tres vías: **(I)** la fermentación entérica del ganado (emisión de metano), **(II)** el uso de fertilizantes nitrogenados (emisión de óxido nitroso) y **(III)** las prácticas de gestión del suelo y la maquinaria agrícola (emisión de dióxido de carbono). Según la Agencia Europea de Medio Ambiente, el sector agrícola representa aproximadamente el 10% de las emisiones totales de la UE, sin incluir las emisiones indirectas ligadas a la producción de fertilizantes o al transporte de alimentos (*Environmental Statement Report 2022*, 2023).

Asimismo, la agricultura actual ejerce una fuerte presión sobre los recursos naturales. El agua destinada al riego representa casi una cuarta parte de la captación total de agua en la UE, a pesar

de que únicamente un 6% de la superficie agrícola es regada (Eurostat, 2025). En varias cuencas hidrográficas europeas, las concentraciones de plaguicidas en aguas superficiales superan los límites legales, lo que supone riesgos tanto para la salud ambiental como para la humana (Pesticides in Rivers, Lakes and Groundwater in Europe, 2024).

La agricultura europea se enfrenta a una creciente vulnerabilidad climática. El cambio climático intensifica las sequías prolongadas, las olas de calor, las lluvias torrenciales y la propagación de plagas y enfermedades emergentes. Estos factores ponen en riesgo la estabilidad de la producción y los ingresos del sector: proyecciones de la Comisión Europea indican que, de no adaptarse, los agricultores europeos podrían sufrir pérdidas significativas en la productividad y hasta un 16% de reducción de ingresos hacia mediados de siglo (European Commission. Directorate General for Agriculture and Rural Development., 2023).

En respuesta a estos desafíos, la Unión Europea lanzó el Pacto Verde Europeo en diciembre de 2019, un marco estratégico que busca transformar la economía europea hacia la neutralidad climática en 2050 y reducir las emisiones netas de gases de efecto invernadero en un 55% para 2030 respecto a los niveles de 1990 (Comisión Europea, 2025b).

Dentro del Pacto Verde, destacan dos estrategias fundamentales para el sector agrícola:

- **Estrategia de la Granja a la Mesa (Farm to Fork):** Adoptada en 2020, tiene como objetivo transformar los sistemas alimentarios de la UE hacia un modelo más sostenible, saludable y justo, abordando todas las fases de la cadena: producción, procesamiento, distribución y consumo. Sus metas incluyen la reducción del 50% en el uso y riesgo de plaguicidas químicos, el aumento al 25% de la superficie agrícola bajo agricultura ecológica, y la disminución del 50% en las pérdidas de nutrientes como nitrógeno y fósforo, para mejorar la calidad del agua y la salud del suelo (Comisión Europea, 2025b).
- **Estrategia de Biodiversidad de la UE para 2030:** Busca proteger, restaurar y reforzar la resiliencia de los ecosistemas frente a amenazas como el cambio climático y la pérdida de especies. Sus objetivos principales son proteger al menos el 30% de la superficie terrestre y marina europea, restaurar ecosistemas degradados como humedales, bosques y suelos agrícolas, e integrar la biodiversidad en la agricultura mediante prácticas agroecológicas, rotación de cultivos y la reducción sustancial del uso de plaguicidas y fertilizantes químicos (Comisión Europea, 2025a).

Estas estrategias se apoyan en un marco normativo ya existente, que proporciona instrumentos jurídicos de aplicación directa en los Estados miembros. Entre ellos destacan:

- **Directiva 2009/128/CE** sobre el uso sostenible de plaguicidas, que obliga a los países de la UE a elaborar Planes de Acción Nacionales orientados a reducir riesgos y dependencia de plaguicidas, promover la gestión integrada de plagas y fomentar alternativas no químicas (BOE nº. 314, 2009)
- **Directiva 91/676/CEE** sobre nitratos, cuyo objetivo es proteger la calidad del agua frente a la contaminación producida por nitratos de origen agrícola. Establece medidas específicas para las denominadas zonas vulnerables a nitratos, limitando la aplicación de fertilizantes nitrogenados y promoviendo buenas prácticas agrícolas (Directiva 91/676/CEE, 1991)

Como se evidencia, la agricultura europea se encuentra en un punto de inflexión, donde la sostenibilidad ambiental, la resiliencia frente al cambio climático y la seguridad alimentaria deben integrarse de manera equilibrada. La transición hacia sistemas agrícolas más sostenibles no solo es necesaria para reducir los impactos ambientales y proteger los recursos naturales, sino también para garantizar la viabilidad a largo plazo del sector y la estabilidad socioeconómica de las comunidades rurales. Lograr estos objetivos requerirá innovación, colaboración entre distintos sectores y un compromiso continuo con políticas y prácticas que promuevan un modelo agrícola resiliente y responsable.

1.2. Alternativas sostenibles y tecnologías emergentes.

Ante los desafíos ambientales y productivos actuales, la búsqueda de alternativas sostenibles para la agricultura se ha convertido en una prioridad urgente.

En este contexto, la agroecología emerge como una alternativa sostenible que integra conocimientos ancestrales, principios ecológicos y participación comunitaria para construir agroecosistemas resilientes, equitativos y ambientalmente responsables buscando reducir la dependencia de insumos sintéticos, preservar la biodiversidad y fortalecer la resiliencia de los agroecosistemas a largo plazo (Barberán, 2025). Este enfoque no se limita a prácticas agrícola respetuosas con el entorno, sino que plantea una visión integral que reconoce la diversidad territorial y cultural como base para la sostenibilidad. La agroecología defiende que las estrategias deben adaptarse a las características específicas de cada escenario territorial, estableciendo técnicas adecuadas para evaluar su evolución en el tiempo.

En línea con esta perspectiva, el conocimiento de las especies de malas hierbas presentes en el cultivo es esencial para disminuir el uso de pesticidas, y con ello, mitigar su impacto ambiental. La diversificación temporal de cultivos, tanto a nivel de familiar botánicas como de especies dentro de una misma familia, reduce significativamente la dependencia a agroquímicos (Yu et al., 2024), reforzando así los principios agroecológicos mediante mecanismos naturales de regulación.

La agroecología no está reñida con la innovación tecnológica. Su implementación puede beneficiarse de la integración de tecnologías emergentes que potencian su capacidad de respuesta frente al cambio climático. Herramientas como la inteligencia artificial (IA), el aprendizaje automático (ML), el Internet de las Cosas (IoT), la robótica y la computación en la nube, entre otras, están impulsando la transformación hacia una agricultura más eficiente, automatizada y basada en datos. (Padhiary et al., 2024).

En este marco, la agricultura de precisión representa una evolución de los sistemas agrícolas tradicionales, utiliza técnicas contemporáneas para optimizar el rendimiento de los cultivos mientras minimiza el consumo de recursos (Padhiary et al., 2024). Su objetivo principal es aumentar la producción de alimentos mediante el uso eficiente de insumos agrícolas, como fertilizantes, pesticidas y agua, a través de la recopilación y análisis de datos a tiempo real. Para ello emplea instrumentos como sensores, drones, sistemas GPS y algoritmos de aprendizaje automático para analizar y abordar la variabilidad del campo.

Estas facilitan el monitoreo de cultivos, la evaluación de la salud vegetal mediante visión por computadora y redes neuronales convolucionales (CNN), y la gestión inteligente del riego y del suelo, logrando ahorros significativos en agua y energía (Mohammed et al., 2025).

1.3. Proyecto AGROSUS

Bajo este contexto surge el proyecto titulado *AGROecological strategies for SUSTainable weed management in key European crops* (AGROSUS), una iniciativa europea destinada a reducir y eventualmente eliminar el uso de herbicidas sintéticos en la agricultura (AGROSUS Consortium, 2025a). Su enfoque se centra en transformar la gestión de malezas mediante el desarrollo e implementación de estrategias agroecológicas que consideren el ecosistema agrícola en su totalidad, y no únicamente la planta individual. El objetivo es establecer técnicas que permitan una gestión de malezas sostenible, segura y equitativa en sistemas agrícolas convencionales, orgánicos y mixtos. El proyecto abarca las 11 regiones biogeográficas

europeas, desarrollando y validando estas estrategias en 30 cultivos diferentes y 83 sistemas agrícolas, con planes a corto, medio y largo plazo para fomentar su adopción por parte de los agricultores (AGROSUS Consortium, 2025b)

Los objetivos de AGROSUS están estrechamente alineados con las políticas de sostenibilidad de la Unión Europea, contribuyendo al Pacto Verde Europeo. El proyecto busca transformar la gestión de malezas para lograr una agricultura más sostenible, apoyando la meta de reducir en un 50 % el uso y el riesgo de plaguicidas químicos para 2030 (AGROSUS Consortium, 2025c). Aunque la estrategia “De la Granja a la Mesa” no se menciona explícitamente entre los objetivos del proyecto, la visión de AGROSUS coincide con sus principios, promoviendo sistemas alimentarios más justos, saludables y respetuosos con el medio ambiente, reduciendo la dependencia de insumos químicos y fomentando la salud del ecosistema y el bienestar de los agricultores.

Para lograr sus objetivos, AGROSUS adopta un enfoque con participación de múltiples actores, crucial para el desarrollo e implementación de estrategias. Esto implica la co-creación y co-validación de soluciones con la participación activa de todos los actores relevantes del sector agrícola. Para ello, el proyecto establece redes locales organizadas en "Comunidades Regionales de Actores" (RSC) y "Grupos Vinculados a Cultivos" (CLG) alrededor de cada unidad experimental. Estas redes se extienden por las 11 regiones biogeográficas europeas, involucrando a agricultores, asesores agrícolas, representantes de la agroindustria y responsables políticos. La participación se fomenta mediante encuestas, entrevistas, talleres y grupos de discusión, asegurando que las soluciones desarrolladas sean relevantes y viables para su aplicación en el campo.

2. JUSTIFICACIÓN Y OBJETIVOS

La creciente dependencia de herbicidas sintéticos ha provocado impactos negativos en la salud ambiental, la biodiversidad del suelo y la sostenibilidad de los sistemas de producción agrícola (El jaouhari et al., 2023; García-Delgado et al., 2019; Zilnik et al., 2023). Su uso intensivo, especialmente del glifosato, contribuye a la erosión de la diversidad de la fauna edáfica y a la alteración de las comunidades microbianas, afectando a la estabilidad de los ecosistemas y calidad del suelo. Además, los plaguicidas generan contaminación de recursos naturales esenciales, como el agua y el aire, debido a procesos de escorrentía, persistencia y emisiones derivadas de su producción, transporte y aplicación (Jafir et al., 2023). Esta situación evidencia la necesidad de desarrollar prácticas más respetuosas con el medio ambiente, capaces de mantener la productividad sin comprometer los recursos naturales.

En respuesta a estos desafíos, han surgido enfoques agroecológicos que integran herramientas biológicas, tecnológicas y culturales para lograr un manejo equilibrado de las malezas y del ecosistema agrícola. El proyecto AGROSUS se enmarca en esta transición, proponiendo un modelo innovador para la gestión de malezas mediante la combinación de avances técnicos, conocimientos locales y políticas públicas. Su objetivo es reducir el uso indiscriminado de herbicidas mediante la identificación y el mapeo precisos de malas hierbas, contribuyendo a minimizar el impacto ambiental y fomentar sistemas agrícolas más resilientes.

Para alcanzar estas metas, el presente trabajo plantea una metodología basada en visión por ordenador que utiliza imágenes obtenidas por un robot terrestre autónomo equipado con cámaras a color y de profundidad, además de posicionamiento mediante GPS. Esta metodología permite elaborar ortoimágenes que transforman las capturas cercanas en vistas remotas, similares a las obtenidas por satélite o drones, facilitando la creación de mapas de cobertura precisos. Dichos mapas ofrecen información detallada sobre la ubicación y distribución de las plantas, optimizando la toma de decisiones y la aplicación de tratamientos específicos, al tiempo que reducen la contaminación del suelo y del agua.

Con base en esta problemática y aprovechando las herramientas tecnológicas disponibles, el presente trabajo establece los siguientes objetivos, los cuales guiarán el desarrollo y la validación de la metodología propuesta:

1. Desarrollar método de trabajo basado en procesamiento de imágenes para identificar y localizar malas hierbas en campos de cultivo.

2. Evaluar la integración de técnicas de mejora de imagen, segmentación de vegetación y detección de puntos clave para optimizar el análisis de malezas en diferentes condiciones de iluminación y densidad vegetal.
3. Creación de un registro para poder realizar ortoimágenes. Para su posterior geolocalización.
4. Validar la metodología propuesta mediante herramientas de identificación automatizada de especies vegetales, asegurando la precisión y fiabilidad de la detección.

3. MATERIALES Y MÉTODOS

La metodología planteada se basa en el análisis de imágenes a color (RGB) y mapas de profundidad capturados mediante un robot autónomo. Dicho robot integra en su parte frontal un conjunto de cámaras, compuesto por una monocámara RGB. El modelo RGB (Red, Green, Blue) es un sistema de representación de color basado en la mezcla aditiva de luz, en el que cada color se genera combinando distintas intensidades de los tres colores primarios: rojo, verde y azul. En el ámbito digital, cada componente se codifica normalmente en un rango de 0 a 255, lo que permite representar más de 16 millones de colores distintos mediante combinaciones (Pantone, 2025)

Adicionalmente, el robot incorpora un sistema de cámaras estéreo, sincronizadas por marcas de tiempo. Los datos se organizaron y procesaron para generar una nube de puntos 3D a color, aplicando transformaciones geométricas y calibración entre cámaras.

Las imágenes se obtuvieron en un campo de cultivo de caqui en condiciones reales. Dada la naturaleza de los datos, es necesario la aplicación de estrategias de mejora de calidad para el ajuste del brillo y saturación. Una vez la calidad de la imagen es la adecuada, para detectar las malas hierbas se aplican técnicas de segmentación como el índice ExG y el filtrado en espacio HSV. El resultado de estas técnicas es una máscara que resalta las malas hierbas.

Para mejorar la calidad de dichas máscaras, se realizan operaciones morfológicas y un filtrado por área, permitiendo aislar de forma más precisa las regiones vegetales. Sobre estas regiones segmentadas mejoradas se aplica el algoritmo ORB, con el objetivo de detectar puntos clave representativos en las regiones vegetales aisladas.

Las zonas de interés se recortan y visualizan sobre la imagen RGB original para su validación. Finalmente, se analizan los recortes mediante herramientas de clasificación de malas hierbas desarrolladas por terceros, para validar que el recorte de la imagen que representa a plantas individuales permite la detección de malas hierbas.

Para el desarrollo y ejecución del código se utilizó Jupyter Notebook, un entorno interactivo que permite ejecutar y depurar el código por bloques, facilitando la identificación de errores y la mejora del mismo. Esta característica resulta especialmente útil para el procesamiento de imágenes, la calibración de cámaras y la generación de nubes de puntos 3D, donde los resultados intermedios deben visualizarse y comprobarse continuamente.

Todo el código se desarrolló en Python 2, debido a la compatibilidad con ciertas librerías empleadas para la manipulación de imágenes y nubes de puntos, como OpenCV y Open3D **referencia bibliográfica de esta librería.**

3.4. Acondicionamiento de los datos

Los datos utilizados para el estudio fueron adquiridos mediante un robot autónomo diseñado para desplazarse de forma controlada a lo largo de campos de cultivos (Véase la Ilustración 1). En concreto, los datos utilizados para la validación de la metodología presentada fueron de un campo de cultivo de caquis situado en Valencia



Figura 3.1 Imagen satelital campo de cultivo Valencia.

Fuente: (Google Earth, 2025)

El robot estaba equipado con la cámara TRI032S-CC RGB de LUCID Vision Labs (Triton Industrial Camera. Vision Labs, 2025) equipada con un objetivo SV-04514V (Véase Ilustración 2), configurando a una resolución de 2048×1536 píxeles ($\approx 3,2$ MP) y un campo de visión (FoV) de aproximadamente $59,4^\circ \times 79^\circ$ y una ZED 2i. También incluía una cámara estéreo ZED 2i (ZED 2i. Stereo Camera, 2025), que genera simultáneamente imágenes RGB (ZED image) y mapas de profundidad (depth) mediante visión estereoscópica (Véase Ilustración 3), permitiendo estimar la profundidad y la geometría tridimensional del campo a partir de dos imágenes capturadas desde puntos de vista ligeramente diferentes.



Figura 3.2 Cámara TRI032S-CC RGB de LUCID. Fuente: Triton Industrial Camera. Vision Labs, 2025



Figura 3.3 Cámara ZED 2i. Stereo Camer. Fuente: ZED 2i. Stereo Camera, 2025

Durante la toma de datos, la cámara ZED estaba configurada a una resolución media/baja (1280 x 720 píxeles). Debido a esta limitación, es necesario el uso de las imágenes de la cámara TRI032S-CC RGB para la identificación de las malas hierbas, mientras que la imagen de profundidad de la cámara ZED se utiliza para proyectar dicha identificación y, de este modo, generar las ortoimágenes.

Además, el robot presenta un receptor GPS que registra la posición geográfica de cada captura, permitiendo la georreferenciación de las imágenes y mapas de profundidad.

3.4.1. Carga y visualización inicial de datos

Los sensores están montados en el mismo robot y se emplean de manera conjunta para el estudio. La sincronización de los datos se realiza a través de marcas de tiempo, asociando a las mediciones más cercanas en el tiempo. Posteriormente, los datos se organizan de forma sistemática en archivos para facilitar su análisis.

Los archivos se organizaron en carpetas específicas y fueron ordenados alfabéticamente para asegurar la correspondencia correcta entre las distintas modalidades de imagen facilitando la posteriormente la reconstrucción 3D.

Los datos se cargaron mediante la librería Open Computer Vision (OpenCV), esta herramienta permite la lectura de archivos gráficos en diversos formatos transformándolos en estructuras con datos matrices manipulables. En concreto se utilizó la función `cv2.imread` para convertir las imágenes en un arreglo NumPy tridimensional y la función `np.load` para convertir los datos de profundidad en un arreglo NumPy binario, permitiendo el acceso directo a los valores numéricos de cada píxel facilitando el posterior procesamiento. (OpenCV, 2025b).

3.4.2. Configuración de la cámara y transformaciones espaciales

La cámara ZED posee diferentes rangos de resolución. Los datos del cultivo fueron tomados con una resolución media/baja. Para obtener una representación espacial de mayor resolución y fidelidad de color, se fusionan los datos provenientes de la cámara RGB y la nube de puntos de la cámara ZED. Esta combinación permite generar una nube de puntos más precisa y visualmente más realista, mejorando el análisis del cultivo.

Para la fusión es necesario determinar los parámetros intrínsecos y extrínsecos de ambas cámaras (Ricolfe Viala & Sánchez Salmerón, 2008).

Los parámetros intrínsecos describen las características internas de la cámara y definen la relación entre las coordenadas 3D en el espacio de la cámara y coordenadas 2D en la imagen (por ejemplo, la distancia focal o el punto principal). Estos parámetros son necesarios para corregir las distorsiones ópticas y garantizar que la geometría de las imágenes represente fielmente la realidad.

Por otro lado, los parámetros extrínsecos describen la posición y orientación de la cámara respecto a un sistema de coordenadas global o en relación con otra cámara. La orientación se representa mediante un cuaternión q o su equivalente en matriz de rotación R , mientras que la posición se representa mediante un vector de traslación t . A partir de estos elementos se construye la matriz de transformación extrínseca T (Véase Ecuación 1), que permite proyectar las coordenadas de un punto desde el sistema de la cámara a un sistema de referencia común.

$$T = \begin{bmatrix} R & t \\ 0 & 1 \end{bmatrix}$$

Ecuación 3.1 Matriz de transformación extrínseca. Fuente: Elaboración propia.

Estos parámetros son esenciales para poder superponer la imagen RGB sobre la nube de puntos 3D generada por la cámara estéreo, garantizando que cada punto de la nube corresponda con el pixel correcto de la imagen, evitando errores de alineación, mejorando la precisión en la fusión de datos.

Como se trata de cámaras diferentes, los parámetros tanto intrínsecos como extrínsecos también lo son. Por ello, fue necesaria la realización de una calibración, se utilizó la metodología desarrollada por Furgale et al. (2025), donde comparten una metodología automática para la

realización de una calibración multimodal utilizando, una herramienta desarrollada en el Autonomous Systems Lab de ETH Zurich.(Github,2025). La calibración multimodal es un proceso que alinea y relaciona la información capturada por diferentes sensores o cámaras, permitiendo determinar los parámetros intrínsecos y extrínsecos. Para llevar a cabo este proceso se utiliza de un tablero de calibración (Véase Ilustración 4 e ilustración 5), que incluye cuadrados de dimensiones conocidas similar a la distribución de un tablero de ajedrez. Al conocer la posición exacta de cada cuadrado (coordenadas 3D) se puede asociar con los píxeles de la imagen 2D de la cámara (correspondencia 2D-3D).

Se realizan capturas sincronizadas desde diferentes ángulos y distancias para cubrir todo el rango de visión de ambos sensores, asegurando que cada adquisición temporal de la cámara RGB y coincida con los datos obtenidos por la cámara ZED. A partir de estas capturas sincronizadas, se detectan los puntos característicos del patrón de calibración, estableciendo correspondencias entre las coordenadas 2D de la imagen RGB y sus posiciones 3D obtenidas por la cámara ZED.

La cámara RGB presenta una distorsión causada por la lente. Además de la sincronización entre cámaras, la calibración permite corregir dichas distorsiones en las imágenes mediante el uso de los coeficientes de distorsión, los cuales se obtienen a partir de los parámetros intrínsecos de la cámara.




Figura 3.4 Calibración cámara ZED.

Fuente: Elaboración propia

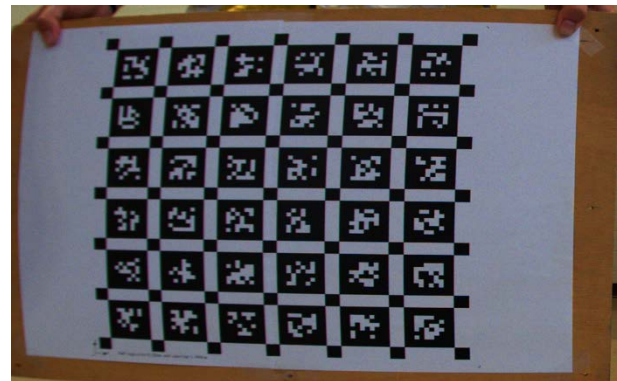


Figura 3.5 Calibración cámara RGB.

Fuente: Elaboración propia

Esta información permite calcular los parámetros intrínsecos de cada cámara y, de manera simultánea, los parámetros extrínsecos. A partir de los parámetros extrínsecos se obtienen las transformaciones extrínsecas de rotación y traslación relativa entre la cámara RGB y la cámara ZED2i (q y t).

3.4.3. Creación de la nube de puntos.

Una nube de puntos es un conjunto de puntos en un espacio tridimensional, donde cada punto posee coordenadas (X, Y, Z) representando posiciones precisas en el entorno físico. Al recolectar una cantidad considerable de puntos, se puede obtener una representación detallada de superficies reales sirviendo como base para la reconstrucción de entornos en 3D (Otepka et al., 2013).

En la metodología presentada, la nube de puntos 3D desempeña un papel fundamental al complementa la información obtenida a partir de las imágenes RGB, lo que permite localizar la detección de malas hierbas en el campo, apoyándose además en el sistema GPS integrado en el robot.

Una vez definidas y aplicadas las transformaciones extrínsecas y los parámetros intrínsecos de las cámaras, se procede a generar la nube de puntos 3D a color del cultivo. Para ello, se desarrolla un código con varias funciones que permite convertir la información de profundidad de la cámara ZED y el color de la cámara RGB en un modelo tridimensional manipulable con la biblioteca Open3D.

3.4.3.1. Construcción de la matriz extrínseca.

A partir de la matriz de rotación (r) y el vector de translación (t) se construye la matriz de transformación extrínseca T . Esta matriz permite transformar los puntos del sistema de coordenadas de la cámara al sistema de referencia global.

3.4.3.2. Generación de la nube de puntos.

Para generar la nube de puntos 3D con color, se transforman los puntos de la cámara de profundidad al sistema global y se asignan los colores de la cámara RGB. Para ello, se utiliza la matriz intrínseca K_d de la cámara de profundidad, la matriz extrínseca T y la matriz intrínseca K_{RGB} de la cámara RGB.

En primer lugar, se aplica la matriz intrínseca K_d de la cámara de profundidad, permite interpretar correctamente la información de profundidad capturada por la cámara ZED, relacionando la posición de cada píxel en la imagen con su posición real en el espacio local de la cámara. Cada píxel en la imagen de profundidad tiene asociado sus coordenadas de imagen (u, v) y un valor de profundidad z que indica la distancia desde la cámara hasta el objeto en ese punto, pero no disponemos del resto de coordenadas. Usando la matriz intrínseca K_d se calcula

la posición en el sistema de coordenadas de la cámara. De esta manera cada pixel de la imagen de profundidad se convierte en un punto 3D en el espacio local de la cámara.

Una vez obtenidas las coordenadas locales de cada punto, se aplica la transformación extrínseca T para ubicarlas en el sistema de referencia global, en este caso coincide con el sistema de referencia de la cámara RGB. En este punto, cada coordenada 3D tiene coordenadas (x, y, z) en el sistema de la cámara ZED no en el sistema de referencia global.

Al multiplicar el vector del punto por la matriz de rotación (R) se rota el punto alineándolo con el sistema global. El vector de translación (t) indica la posición de la cámara en el sistema global, al sumar el vector al punto rotado se ubica el punto en el espacio del sistema de referencia. Por último, se multiplica por la matriz de transformación extrínseca obteniendo las coordenadas en el sistema de referencia (RGB). Como tanto las coordenadas de la cámara RGB como las coordenadas de la cámara ZED están en el mismo sistema, se puede realizar la fusión de la información 3D y el color.

Para ello asignar los colores de la cámara RGB, se proyecta los puntos 3D en el plano de imagen RGB mediante la matriz intrínseca K_{RGB} . Cada punto 3D ya transformado al sistema global se convierte en coordenadas de píxel (u, v) en la imagen RGB. Obteniendo, finalmente, cada punto de la nube ZED asociado con el color de la cámara RGB.

3.4.4. Detección de áreas verdes.

Para identificar las áreas de vegetación se aplica una combinación de técnicas basadas en el análisis del color y el procesamiento morfológico sobre la información de color asociada a la nube de puntos.

El resultado de este proceso es una máscara que resalta las zonas verdes, diferenciándolas del resto de elementos de la escena. Esta segmentación permite centrar el análisis en la vegetación, eliminando información irrelevante, y además se emplea como referencia para validar los resultados obtenidos posteriormente con el algoritmo de detección. De este modo, es posible comprobar si los puntos clave identificados por el algoritmo de identificación se corresponden efectivamente con regiones vegetales, garantizando la coherencia y fiabilidad del procedimiento de detección.

3.4.4.3. Índice de Exceso de Verde

El Índice de Exceso de Verde (ExG) permite resaltar los píxeles correspondientes a la vegetación frente a otros elementos del entorno, como pueden ser rocas, suelo o ramas. Matemáticamente se calcula como:

$$\text{ExG} = 2G - R - B$$

Ecuación 3.2 Índice de Exceso de Verde. Fuente: Elaboración propia

R, valor del canal rojo del píxel.

G, valor del canal verde del píxel.

B, valor del canal azul del píxel.

Para aplicar el índice ExG, primero se separan los canales rojo, verde y azul de la imagen RGB, de manera que para cada píxel se obtiene el valor de intensidad correspondiente en cada canal. Posteriormente, se calcula el índice ExG mediante la ecuación correspondiente (Véase la Ecuación 1), los valores obtenidos se normalizan a un rango estándar de 0 a 255 para estandarizar la representación de la intensidad del verde.

A continuación, se aplica un umbral binario: los píxeles con un índice superior a 100 se consideran vegetación y se asigna a color blanco (255), mientras que los píxeles con un índice inferior a 100 se considera no vegetación y se asignan a color negro (0). Como resultado, se obtiene una máscara binaria que permite diferenciar claramente las zonas vegetales del resto de la imagen.

Para determinar el umbral de ExG, se calculó primero el índice por píxel en todas las imágenes. Luego, se generaron histogramas de frecuencia de los valores ExG, permitiendo visualizar la distribución de vegetación y fondo. A partir de este análisis, se seleccionó un umbral de 100 (escala 0–255) que maximiza la separación entre ambos y se validó comparándolo con el umbral automático obtenido mediante el método de Otsu.

El método de Otsu es una técnica automática de umbralización utilizada para segmentar una imagen en dos clases: fondo y objeto. Este enfoque es especialmente efectivo cuando el histograma de la imagen es bimodal, es decir, presenta dos picos claramente definidos que corresponden al fondo y al objeto de interés (Somasundaram & Genish, 2023).

3.4.4.4. Filtrado en espacio de color HSV

El modelo de color HSV separa la información de color de la intensidad: H (*Hue/Tono*) representa el color dominante, S (*Saturation/Saturación*) indica la intensidad del color y V (*Value/Brillo*) representa la luminosidad del píxel. Este modelo complementa al índice ExG, mejorando la detección de la vegetación en condiciones de iluminación variable o cuando el verde no es dominante.

La imagen RGB se convierte a HSV. Posteriormente, se definen los rangos de tonalidad específicos del verde (*lower_green* y *upper_green*) asignando así que valores de H, S y V corresponden a vegetación.

A partir de estos rangos se genera un umbral binario: los píxeles que se encuentran dentro del rango se asigna color blanco (255) y los píxeles fuera de rango se asigna color negro (0), creando nuevamente una máscara binaria que resalta únicamente las zonas vegetales de la imagen.

3.4.4.5. Operaciones morfológicas.

Las máscaras generadas tras aplicar el índice ExG y el filtrado por color HSV se refinan mediante operaciones morfológicas para mejorar la segmentación.

Para ello, se define un kernel de tamaño 5x5. Cada posición de esta matriz tiene un valor numérico que indica si el píxel correspondiente participa en la operación: 1 significa que el píxel participa, mientras que 0 indica que no participa. Este kernel actúa como una “plantilla” que recorre la máscara, evaluando los píxeles vecinos alrededor del píxel central y determinando cómo se modificará este durante la operación morfológica (Véase Ilustración 6).

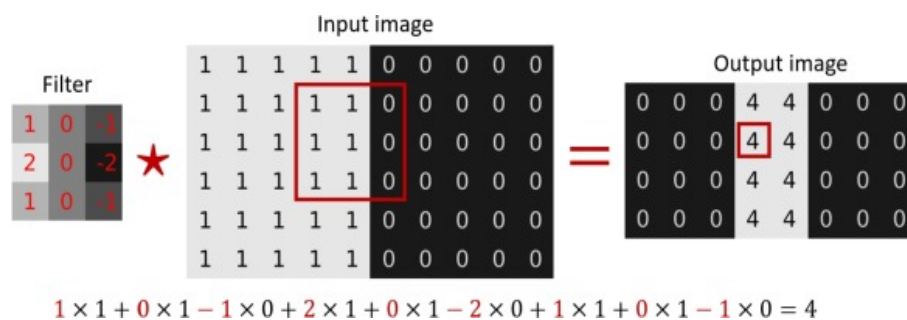


Figura 3.6 Funcionamiento de un kernel. Fuente: (ScienceDirect Topics, 2025)

En primer lugar, se aplica una apertura morfológica, que consiste en una erosión seguida de una dilatación. La erosión, como se puede observar en la Ilustración 7, reduce las regiones blancas eliminando píxeles aislados o pequeños ruidos que no corresponden a la vegetación.

Posteriormente, se aplica una dilatación, cómo se muestra en la Ilustración 8 devuelve a las regiones principales su tamaño aproximado original. Esta operación permite obtener una máscara más limpia y precisa

A continuación, se realiza un cierre morfológico, que combina una dilatación seguida de una erosión. La dilatación expande las regiones blancas, rellenando huecos internos dentro de las zonas vegetales y uniendo áreas cercanas, mientras que la posterior erosión restaura las formas generales preservando la forma original, pero sin huecos pequeños ni separaciones. El resultado es una máscara más uniforme, donde las áreas de vegetación son más coherentes y continuas, facilitando su identificación y posterior análisis.



*Figura 3.7 Transformación morfológica:
Erosión. Fuente: (Open CV, 2025)*



*Figura 3.8 Transformación morfológica:
Dilatación. Fuente:(Open CV, 2025)*

3.4.4.6. Filtrado por área.

La máscara obtenida tras las operaciones morfológicas se refina mediante un filtro por área utilizando la función `cv2.connectedComponentsWithStats` de la biblioteca OpenCV. Esta función analiza la máscara binaria y detecta los componentes conectados, asignando a cada región un identificador numérico único que permite que OpenCV diferencie cada región detectada.

Para eliminar detecciones pequeñas o irrelevantes, se establece un umbral mínimo de área de 500 píxeles. Todas las regiones con un tamaño inferior a este umbral se descartan, eliminando así posibles ruidos o zonas aisladas que no representan vegetación significativa.

La máscara final se construye asignado valor 255 (blanco) a los píxeles pertenecientes a componentes que superan el umbral, mientras que los píxeles de las regiones descartadas se asigna valor 0 (negro). De esta manera, la máscara resultante contiene únicamente las zonas verdes relevantes, eliminando pequeñas manchas o píxeles dispersos.

Esta máscara se aplica sobre la imagen original mediante la función `cv2.bitwise_and`. Conservando únicamente los píxeles de la imagen original que corresponden a las regiones blancas de la máscara, generando así una imagen final en la que se destacan únicamente las zonas verdes relevantes, mientras que el resto de la imagen se vuelve negro.

3.4.4.7. Operaciones morfológicas adicionales.

Para mejorar la compactación y visibilidad de las áreas vegetales detectadas, la máscara final se somete a operaciones morfológicas adicionales utilizando un kernel de mayor tamaño (25x25). Este kernel permite que las transformaciones consideren un vecindario más amplio de píxeles, lo que ayuda a unir regiones cercanas y rellenar huecos mayores dentro de las áreas vegetales.

Estas operaciones morfológicas garantizan que la máscara final represente de manera precisa las áreas vegetales, minimizando falsos positivos y falsos negativos, y proporcionando una base confiable para análisis posteriores, como conteo de plantas o identificación de especies.

Para facilitar su visualización, la máscara final se representa sobre un fondo blanco, asignando valores negros a los píxeles correspondientes a las áreas vegetales y valores blancos al resto de la imagen. De esta manera, la vegetación aparece en negro sobre un fondo blanco, lo que permite una identificación visual clara y rápida de las regiones de interés.

3.4.5. Recorte de la nube de puntos

Una vez identificada la zona de estudio gracias al proceso de detección de áreas verdes, se definen límites espaciales de la región de interés (ROI) en los ejes X y Z de la nube de puntos para facilitar el estudio. El rango en X se fija estableciendo un `x_min` y un `x_max`, mientras que para el eje Z se toma el valor mínimo de todos los puntos de la columna Z (`z_min`), que corresponde con el punto más cercano a la cámara, y se define un límite superior sumándole 0.5, delimitando así un rango de interés.

Los puntos cuyas coordenadas se encuentran dentro de estos rangos constituyen la ROI, la cual abarca un área que considera el movimiento del robot, que avanza a 0.4 m/s, y la frecuencia de adquisición de imágenes, que es de un fotograma por segundo; esto permite capturar toda la información relevante, incluso si existe cierto solapamiento entre mediciones consecutivas. Finalmente, la nube de puntos se proyecta en el plano del suelo, considerando que el robot se desplaza por un campo de cultivo plano y sin obstáculos, lo que facilita el análisis de los datos.

Para validar que el recorte de la nube de puntos contiene las malas hierbas, se define un rectángulo delimitador que se dibuja sobre una copia de la imagen original (Véase Ilustración 9), a la cual se le ha aplicado la máscara binaria final resultante del proceso de filtrado por área. Esto permite visualizar con claridad si los objetos de estudio se encuentran dentro de la región de interés definida. De esta manera, se facilita la identificación visual de la zona de estudio y se asegura que las operaciones de análisis se aplican únicamente a las regiones relevantes.




Figura 3.9 Ejemplo de Región de Interés (ROI). Fuente: Elaboración propia.

3.4.6. Mejora de la calidad de la imagen

El análisis de las malas hierbas se realiza sobre la imagen RGB. Dado que estas imágenes se obtienen en entornos reales, presentan niveles de iluminancia variables debido al efecto de las sombras de los cultivos, lo que puede afectar a la percepción del color y segmentación de los objetos de interés. Por ello, es necesario aplicar previamente un proceso automático de mejora de imagen, cuyo objetivo es aclarar las imágenes demasiado oscuras y resaltar los detalles de las malas hierbas, aumentando así la precisión del proceso de detección.

En primer lugar, se define un rango representativo del brillo de todas las imágenes. Para ello, se calcula automáticamente el canal L (luminosidad) del espacio de color LAB, este canal permite clasificar los colores de forma más precisa en términos de color, brillo y saturación.

A partir de este canal se obtiene un valor medio de luminancia ($mean_L$), almacenándose en una lista que incluye todas las imágenes de la carpeta de estudio. Posteriormente, se convierten estos

valores a un array de NumPy para poder calcular los percentiles 5 y 95, estableciéndolos como límites inferior (L_{min}) y superior (L_{max}) de brillo. Este enfoque evita que imágenes extremadamente oscuras distorsionen los rangos representativos.

Con estos límites se decide cuando aplica la función de mejora:

Si $mean_{L_{imagen}} < L_{min}$, la imagen está demasiado oscura y se aplica la mejora de brillo.

Una vez establecido cuándo se debe usar la mejora, se crea la función encargada de mejorar la iluminancia de las imágenes.

La función recibe la imagen RGB original, y la convierte al espacio de color LAB, separando los canales L (luminosidad), A (rojo-verde) y B (azul-amarillo). A continuación, se calcula un factor de corrección (definido manualmente) basado en la relación entre el brillo objetivo y el brillo medio de la imagen. Este factor es limitado por el rango obtenido anteriormente para evitar cambios extremos.

El factor de corrección se aplica al canal L, multiplicando sus valores, y posteriormente se aplica los parámetros *Contrast Limited Adaptive Histogram Equalization* (CLAHE) para mejorar el contraste local de la imagen.

Los parámetros de CLAHE permiten realizar el contraste de manera localizada evitando que las zonas oscuras queden planas o que las zonas claras se quemen: *clipLimit* define el límite máximo de contraste que se puede aplicar a cada región local, y *tileGridSize* determina el número de subdivisiones que se divide la imagen para aplicar la ecualización (OpenCV, 2025a).

La imagen LAB resultante se reconstruye con el canal L ajustado y se convierte nuevamente a RGB.

Para reforzar los tonos verdes, la imagen se transforma al espacio HSV, se separan los canales y se multiplica la saturación por el factor de saturación de verdes definido previamente de manera manual. Este canal de color almacena la información en un canal dedicado tono (H), otro la saturación (S) y otro el brillo (V), lo que permite ajustar los colores evitando que la intensidad de la luz afecte a los resultados.

La imagen HSV se reconstruye y se convierte de nuevo a RGB, obtenido así una imagen final mejorada, con un brillo uniforme y colores más saturados, lo que facilita la posterior segmentación y análisis de la vegetación mediante el algoritmo de detección.

3.4.7. Detección de elementos clave (ORB)

Tras los pasos previos, se han extraído las áreas verdes de la imagen; sin embargo, para lograr una detección precisa de las malas hierbas, es necesario que cada planta esté aislada individualmente. Esta tarea se complica en entornos reales debido a factores como el solapamiento de hojas o la alta densidad de vegetación, los cuales dificultan separar cada planta del fondo o de otras plantas cercanas.

Para superar estas dificultades se utiliza una metodología basada en el algoritmo *Oriented FAST and Rotated BRIEF* (ORB), que permite detectar y describir de manera precisa los puntos clave de cada planta, incluso ante rotaciones o deformaciones leves. Gracias al algoritmo, es posible extraer y analizar cada ejemplar de forma individual dentro de la región de interés, asegurando que el proceso de detección de malas hierbas sea más preciso y confiable.

El algoritmo ORB es un detector y descriptor de puntos clave en imágenes. En primer lugar, identifica los puntos de interés de la imagen (*keypoints*), es decir, aquellos donde la intensidad de los píxeles cambia significativamente. A continuación, asigna una orientación a cada punto clave basada en el patrón local de intensidad, permitiendo que las rotaciones de la imagen no afecten a la identificación. Luego, se calcula un descriptor binario *BRIEF* para cada *keypoint*, para ello se analiza el área alrededor del punto y genera un código de unos y ceros que representa las características locales de la imagen permitiendo comparar rápidamente los puntos clave de diferentes imágenes (OpenCV, 2025c). Gracias a estas características, ORB es capaz de identificar de manera confiable los puntos más relevantes de una imagen, convirtiéndolo en una herramienta ideal para la identificación de las malas hierbas.

El algoritmo se aplica sobre la máscara binaria, donde la vegetación destaca en color negro sobre un fondo blanco. Esta característica resulta idónea para la detección, ya que el contraste marcado favorece la identificación precisa de las regiones de interés. Para verificar el resultado, se dibujan cajas alrededor de los *keypoints* detectados y se visualiza, asegurando que la detección se ha realizado correctamente. Posteriormente, con el fin de analizar las plantas detectadas, las cajas generadas se superponen sobre la imagen RGB original.

El proceso comienza con el recorte de la máscara binaria, delimitando la región de interés mediante los parámetros $v_{\min}:v_{\max}$ y $u_{\min}:u_{\max}$, definidos previamente en el apartado 3.1.5. (Recorte de la nube de puntos). A continuación, la máscara recortada se convierte a escala de grises mediante la función `cv2.cvtColor` de OpenCV, ya que el algoritmo ORB únicamente

trabaja con un único canal de color, por lo que no puede procesar directamente imágenes binarias en blanco y negro.

La detección de puntos clave se realiza sobre esta máscara en escala de grises. Una vez obtenidos y filtrados, se procede a la visualización sobre la imagen RGB recortada correspondiente a la misma región de interés. Para ello, se crea una función que genera una representación gráfica de los puntos detectados. Esta función recibe como entrada la imagen RGB recortada, los *keypoints* filtrados y el parámetro *crop_multiplier*, que determina el tamaño de las cajas que rodean cada *keypoint*.

El resultado es una imagen RGB en la que cada punto clave aparece resaltado mediante un rectángulo. Esta representación permite identificar de manera clara y rápida las áreas relevantes detectadas por ORB, facilitando la validación visual del proceso.

3.5. Análisis y clasificación

Para validar la metodología propuesta, se procesan los recortes generados a partir de las cajas que rodean los *keypoints* detectados. Estos recortes se extraen de la imagen RGB y se mejoran visualmente si es necesario. Posteriormente, se evalúa la calidad de dicho recorte mediante técnicas de inteligencia artificial desarrolladas por terceros, comprobando si son capaces de identificar correctamente la planta contenida en cada caja.

Para ello, se utiliza la aplicación Pl@ntNet, desarrollada por un consorcio de instituciones científicas, entre ellas CIRAD, INRA, INRIA, IRD, y la red Tela Botánica, en un proyecto financiado por la Fundación Agropolis. Esta plataforma permite la recopilación, anotación e identificación de plantas a partir de fotografías, utilizando la inteligencia artificial y validación comunitaria. Reconoce miles de especies vegetales, tanto silvestres como ornamentales y cultivadas, provenientes de distintos continentes (Ministerio para la Transición Ecológica y el Reto Demográfico, 2025).

Pl@ntNet resulta idónea para esta metodología por su sencillez, accesibilidad y eficacia. El proceso consiste en subir una fotografía del recorte a la aplicación, donde la IA analiza la imagen y la compara con una extensa base de datos de especies vegetales. Originalmente, el sistema se basaba en redes neuronales convolucionales (CNN), pero recientemente ha adoptado el modelo de red neuronal Vision Transformer (ViT), capaz de realizar un análisis más preciso y detallado de las imágenes, mejorando la identificación de especies con características visuales similares.

Como resultado, la aplicación genera una lista de posibles identificaciones acompañadas de una puntuación de confianza. Cuanto mayor es la puntuación, más fiable será la identificación propuesta. Estas sugerencias pueden ser revisadas y validadas por los usuarios, contribuyendo a la mejora de su funcionamiento (Pl@ntNet, 2025)

4. RESULTADOS Y DISCUSIÓN

4.1. Visualización de las imágenes


La adquisición de los datos se realizó de forma exitosa, permitiendo disponer de las imágenes RGB de la cámara TRI032S-CC (Véase Ilustración 10), así como de las imágenes RGB (Véase Ilustración 11) y los mapas de profundidad (Véase Ilustración 12) de la cámara ZED 2i, asegurando que el proceso de sincronización mediante marcas de tiempo y la organización sistemática de los archivos se ha llevado a cabo correctamente, garantizando la correspondencia precisa entre las distintas modalidades de imagen.



*Figura 4.1 Imagen 401 RGB (Cámara RGB).
Fuente: Elaboración propia*



*Figura 4.2 Imagen 401 RGB (cámara ZED).
Fuente: Elaboración propia.*



*Figura 4.3 Imagen 401 depth (cámara ZED).
Fuente: Elaboración propia*

Los datos adquiridos permiten confirmar que la sincronización entre la información de profundidad y color se ha realizado correctamente, lo que garantiza una reconstrucción 3D coherente del entorno agrícola. Sin embargo, la calidad final de la nube de puntos depende directamente de las características técnicas de las cámaras utilizadas.

La cámara ZED, aunque especializada en la captura de profundidad mediante visión estéreo, fue configurada con una resolución reducida para optimizar el procesamiento en campo. Esta configuración, si bien suficiente para obtener mapas de profundidad funcionales, limita la definición espacial y la riqueza visual de la nube de puntos generada exclusivamente con sus datos. Las texturas aparecen suavizadas, los bordes menos definidos y los detalles finos de la vegetación pueden perderse, lo que afecta negativamente a aplicaciones que requieren alta precisión.

Por otro lado, la cámara RGB utilizada en paralelo cuenta con una resolución significativamente superior. Aunque no proporciona información de profundidad por sí sola, su capacidad para capturar imágenes con gran nitidez, contraste y riqueza cromática permite mejorar sustancialmente la calidad visual de la nube de puntos cuando se fusiona con los datos de profundidad de la ZED. Esta fusión permite asignar colores más precisos a cada punto 3D, mejorar la definición de estructuras vegetales y facilitar la segmentación de elementos del terreno.

En la imagen de profundidad podemos observar el mapa de profundidad generado por la cámara ZED. En esta representación, cada pixel codifica la distancia entre la cámara y los objetos presentes en la escena, utilizando una escala de colores para facilitar la interpretación visual. En este caso el gradiente cromático va desde tonos oscuros (como púrpura y negro) en las zonas más cercanas o sin datos, hasta colores más brillantes (amarillo y verdes) en las regiones más alejadas. La parte superior de la imagen revela contorno de vegetación, como árboles o follaje, mientras que las áreas negras indican zonas con bajas reflectancia consecuencia de la luminosidad de la imagen.

La claridad con la que se distingue la variación de profundidad indica que la cámara ZED ha capturado correctamente la geometría del entorno. Aunque la resolución es limitada en comparación con cámaras RGB, la información espacial que aporta es esencial para los procesos posteriores de segmentación, clasificación y generación de la nube de puntos.

Las imágenes confirman que el sistema de adquisición de datos funciona correctamente y que la calidad de los datos de profundidad y color son suficientes para construir modelos tridimensionales a color y la identificación de las plantas presentes en el cultivo.

4.2. Nube de puntos


A partir de la combinación de la información de color de la cámara RGB y los datos de profundidad de la cámara ZED, se generó una nube de puntos 3D a color del cultivo.

La nube de puntos se genera específicamente a partir de la región de interés (ROI), previamente delimitada en el proceso de adquisición. Esta selección permite centrar el análisis en las zonas del terreno donde se encuentra vegetación activa, descartando áreas irrelevantes o vacías. Al trabajar sobre una ROI, se optimiza el procesamiento de datos, se reduce el ruido espacial y se garantiza que los resultados obtenidos sean representativos del objetivo del estudio.

La ilustración 13 y la ilustración 14 muestran esta proyección, donde es posible identificar con claridad la densidad y la extensión de la vegetación a lo largo del campo. La nube de puntos se visualiza con buena definición, tanto en la distribución espacial como en la representación cromática, lo que indica que el proceso de captura, sincronización y fusión de datos se ha ejecutado correctamente. Esta representación simplificada permite centrar los análisis en las áreas relevantes y descartar zonas de mala calidad visual y estructural es fundamental, ya que permite distinguir con precisión las zonas con vegetación, los espacios vacíos y las áreas de transición, facilitando la interpretación del entorno.

Permitiendo centrar el análisis en las áreas relevantes y descartar las zonas sin vegetación o con información irrelevante, asegurando que los siguientes procesos de segmentación y detección se aplican sobre datos coherentes. Confirmando que el proceso de generación y proyección de la nube de puntos se ha ejecutado correctamente y proporciona la base para la segmentación de áreas de interés, tal como se planteó en la metodología.

Además, como se menciona en la metodología la nube de datos se proyecta sobre el plano, permitiendo una vista cenital del terreno. Esta proyección facilita el análisis horizontal de la cobertura vegetal, ya que elimina el componente vertical permitiendo visualizar la distribución espacial de las plantas en la superficie.



*Figura 4.4 Nube de puntos. Imagen 401.
Fuente: Elaboración propia.*




Figura 4.5 Nube de puntos recortada. Imagen 401. Fuente: Elaboración propia

4.3. Detección de zonas verdes.

Los resultados obtenidos mediante la aplicación de la metodología descrita confirman la eficacia del enfoque propuesto para la identificación precisa de zonas vegetales en el entorno analizado. La combinación de técnicas basadas en el análisis del color (Índice de Exceso de Verde y filtrado en espacio HSV), junto con operaciones morfológicas y filtrado por área, ha permitido generar máscaras binarias que destacan de forma clara y coherente las regiones correspondientes a vegetación (Véase Ilustración 15).

La máscara final, proyectada sobre fondo blanco con las zonas vegetales en negro, ofrece una representación visual limpia, compacta y fácilmente interpretable. Esta claridad en la segmentación permite validar que las áreas detectadas se corresponden efectivamente con regiones de vegetación activa, descartando elementos irrelevantes como suelo, rocas o sombras. Además, la aplicación de operaciones morfológicas adicionales con *kernels* de mayor tamaño ha mejorado la continuidad de las regiones vegetales, uniendo fragmentos dispersos y rellenando huecos internos, lo que refuerza la coherencia espacial de los resultados.

El uso del Índice de Exceso de Verde (ExG) ha demostrado ser eficaz para resaltar la vegetación en condiciones de iluminación estándar, mientras que el filtrado en espacio HSV ha complementado esta detección en situaciones de variabilidad lumínica o cuando el verde no es dominante. La integración de ambos enfoques ha permitido una segmentación robusta frente a variaciones cromáticas y ambientales. Por otro lado, el filtrado por área ha eliminado regiones pequeñas o aisladas que no representan vegetación significativa, reduciendo el ruido en la segmentación y mejorando la precisión del análisis. Esta depuración garantiza que las zonas detectadas sean relevantes desde el punto de vista agronómico.



Figura 4.6 Máscara binaria Imagen 401. Fuente: Elaboración propia.

Tras aplicar las técnicas de segmentación basadas en el índice de Exceso de Verde (ExG) y el filtrado en espacio de color HSV, se generaron máscaras binarias que identifican las zonas vegetales presentes en la imagen RGB. Sin embargo, estas máscaras iniciales pueden contener ruido, regiones pequeñas o píxeles dispersos que no representan vegetación significativa. Para depurar estos resultados, se aplicó un filtrado por área, el resultado de este filtrado se muestra en la Ilustración 16: una máscara final más limpia y coherente donde se puede observar la vegetación en su color original mientras que las regiones no vegetales se ven de color negro.

Esta máscara facilita la validación visual, pudiendo comprobar que las áreas conservadas coinciden con estructuras vegetales reales. Esta coherencia entre la segmentación y la escena natural confirma que el sistema ha sido capaz de distinguir correctamente la vegetación del resto de elementos del entorno.

La aplicación del ROI, delimitada con un rectángulo rojo, demuestra que la metodología permite focalizar el análisis espacial, evitando procesar zonas irrelevantes, optimizando el rendimiento del sistema, garantizando que los resultados obtenidos son representativos.




Figura 4.7 Máscara filtrado por área. Imagen 401. Fuente: Elaboración propia.

Una vez identificada la zona de estudio, se recorta la máscara binaria siguiendo las dimensiones del ROI para posteriormente poder aplicar el algoritmo de detección (Véase Ilustración 17).



Figura 4.8 Máscara binaria recortada. Imagen 401. Fuente: Elaboración propia.

En conjunto, los resultados obtenidos validan la metodología empleada, ya que las máscaras generadas permiten centrar los análisis posteriores en las zonas verdes relevantes. Además, estas máscaras sirven como referencia para verificar la coherencia de los puntos clave detectados por algoritmos de identificación, asegurando que se aplican sobre regiones vegetales reales. Esto refuerza la fiabilidad del sistema de detección y proporciona una base sólida para tareas posteriores como el conteo de plantas, la clasificación de especies o la planificación de estrategias de manejo.

4.4. Mejora de la imagen.

Para comprobar que la función de mejora de brillo y saturación de las imágenes RGB funciona de manera correcta se evaluaron dos casos representativos:

1. Imagen oscura, que requiere un aumento de brillo para poder identificar de manera satisfactoria la vegetación y facilitar su posterior análisis (Véase Ilustración 18).
2. Imagen dentro del rango de brillo normal, por lo que no necesita que se aplique la función (Véase Ilustración 20).

Los resultados obtenidos tras aplicar el proceso automático de mejora de imagen confirman que la metodología empleada ha cumplido su objetivo: homogeneizar el brillo y mejorar la visibilidad de las malas hierbas en las imágenes RGB utilizadas para el análisis. Las imágenes originales presentaban niveles de luminosidad muy variables, lo que dificultaba la identificación precisa de vegetación en condiciones de baja luz o contraste insuficiente.

Gracias al cálculo del canal L en el espacio de color LAB y al establecimiento de límites de luminancia mediante percentiles, se ha logrado detectar de forma automática qué imágenes requerían ajuste. Las imágenes con valores de brillo inferiores al umbral definido fueron correctamente aclaradas.

El resultado sobre aquellas imágenes oscuras muestra una imagen con brillo uniforme (Véase Ilustración 19), la transformación al espacio HSV y el refuerzo de la saturación verde han permitido que las malas hierbas se destaquen con mayor claridad frente al fondo, incluso en condiciones de iluminación compleja. Esta mejora tiene un impacto directo en la eficacia del algoritmo de detección, ya que los detalles de las plantas son ahora más visibles, los bordes más definidos y las texturas más contrastadas. Esto se traduce en una mayor precisión en la identificación de zonas vegetales, una reducción de falsos negativos y una mejora general en la fiabilidad del sistema.

Por el contrario, como se puede observar en la Ilustración 21, a aquellas imágenes que tienen un brillo adecuado no se les aplica la función de mejora del brillo.

En conjunto, los resultados obtenidos validan que el proceso de mejora de imagen ha funcionado correctamente, adaptándose a las condiciones lumínicas de cada escena y proporcionando una base visual sólida para el análisis de malas hierbas en el entorno.



Figura 4.9 Imagen 100 antes de la mejora del brillo. Fuente: Elaboración propia.



Figura 4.10 Imagen 100 después de la mejora del brillo. Fuente: Elaboración propia.



Figura 4.11 Imagen 401 antes de la mejora del brillo. Fuente: Elaboración propia.



Figura 4.12 Imagen 401 después de la mejora del brillo. Fuente: Elaboración propia.

4.5. Detección de puntos clave mediante ORB.

La Ilustración 22 muestra resultados obtenidos tras aplicar el algoritmo ORB sobre la máscara binaria, esta representación confirma que la metodología empleada permite una detección precisa y coherente de puntos clave en las regiones vegetales del terreno. La aplicación del algoritmo sobre una máscara binaria, en la que la vegetación aparece en negro sobre fondo blanco, proporciona un contraste óptimo para la identificación de patrones locales de intensidad, lo que favorece la localización de keypoints en zonas con textura y variación tonal.

La visualización de los resultados, mediante la superposición de cajas sobre la imagen RGB (Véase Ilustración 23), permite validar que los puntos clave detectados se encuentran efectivamente sobre zonas vegetales. Las cajas generadas por la función `draw_orb_box` destacan con claridad las áreas de interés, facilitando la interpretación visual y la verificación del proceso.

La correcta localización de keypoints en las imágenes analizadas demuestra que ORB ha sido capaz de identificar patrones texturales característicos de las malas hierbas, incluso en condiciones de iluminación variable o en presencia de elementos de fondo. Esto valida que el enfoque metodológico —basado en la segmentación previa, el recorte espacial, la conversión a

escala de grises y la visualización sobre imagen RGB— proporciona una base sólida para la detección automatizada de vegetación.

En conjunto, los resultados reflejan que el sistema de detección mediante ORB funciona de manera eficaz, identificando con precisión las zonas vegetales relevantes dentro de la región de estudio.



Figura 4.13 Algoritmo de detección sobre la máscara binaria. Imagen 401.

Fuente: Elaboración propia.



Figura 4.14 Representación visual del algoritmo de detección. Imagen 401.

Fuente: Elaboración propia.

4.6. Resultados del análisis y clasificación.

Los resultados obtenidos tras aplicar el algoritmo de identificación de especies vegetales de Pl@ntNet sobre los recortes generados por el sistema de detección confirman que la metodología propuesta es funcional y coherente con los objetivos del estudio. Cada recorte está formado por una planta aislada, y ha sido analizada individualmente para determinar su correspondencia con especies vegetales conocidas.

Es importante señalar que este trabajo no dispone de bases de datos anotadas ni de la validación de expertos que permitan confirmar de manera definitiva si la especie identificada es correcta. Por este motivo, el análisis mediante Pl@ntNet se emplea únicamente con fines de evaluación,

verificando que se obtiene al menos algún resultado. Cabe destacar, que en aquellas situaciones en las que la imagen carece de información útil, la plataforma no produce resultados de identificación.

En la imagen general, los resultados muestran una diversidad de especies con puntuaciones de confianza bajas, lo cual es esperable dado que la imagen contiene múltiples elementos vegetales, algunos parcialmente visibles o en condiciones de iluminación no óptima. Aun así, se identifican especies como *Hirschfeldia incana*, *Brassica oleracea* y *Plantago major*, todas pertenecientes a familias comunes en ambientes agrícolas o ruderal, lo que sugiere que el sistema está captando vegetación coherente con el entorno.



Figura 4.15 Recorte 1 Imagen 401. Fuente: Elaboración propia.




Figura 4.16 Recorte 2 Imagen 401. Fuente: Elaboración propia.



Figura 4.17 Recorte 3 Imagen 401. Fuente: Elaboración propia.

La Ilustración 24 corresponde al primer recorte, donde se observa una mejora en la identificación, con puntuaciones más altas como *Arabidopsis thaliana* (1.9%) y *Ranunculus sceleratus* (1.5%). Esto indica que el recorte realizado sobre esta región ha capturado una planta con características morfológicas más definidas. Además, se repiten especies como *Plantago major* y *Tulipa gesneriana*, lo que refuerza la consistencia del sistema al detectar patrones similares en distintas cajas.

La Ilustración 25 corresponde al segundo recorte. En este caso, los resultados muestran especies de menor tamaño y cobertura, pero el sistema logra identificar alguna especie como *Poa annua*, *Poa infirma* y *Ornithogalum umbellatum*, todas con puntuaciones bajas pero coherentes con la morfología observada en la imagen. La presencia de varias especies de la familia Poaceae sugiere que el sistema ha detectado correctamente vegetación herbácea de porte bajo, típica de zonas con cobertura dispersa.

La Ilustración 26 corresponde al último recorte de la imagen 401, el cual presenta mayor calidad es por ello que se observa una identificación más precisa de especies como *Plantago major* (1.6%) y *Plantago lanceolata* (1.2%). a coherencia entre las especies detectadas en Caja 3 y las observadas en otras cajas refuerza la fiabilidad del sistema de detección.

Aunque las puntuaciones de confianza son relativamente bajas (<2%), esto es esperable en un entorno no controlado, con imágenes tomadas en campo, bajo iluminación variable y con plantas parcialmente visibles. Lo importante es que el el sistema es capaz de identificar especies al proporcionar los recortes de las imágenes.

En conjunto, estos resultados demuestran que la metodología de detección de malas hierbas es capaz de identificar vegetación real en las imágenes analizadas. Pudiendo mejorar los resultados al obtener imágenes más centradas o de mayor calidad.

4.7. Trabajo futuro.

La metodología desarrollada abre nuevas líneas de investigación y aplicación en el ámbito del análisis geoespacial automatizado. Una de las principales proyecciones es la generación de ortoimágenes de alta precisión. Gracias a la obtención de nubes de puntos mediante la sincronización de la cámara ZED i2 y la cámara RGB, es posible construir mapas que permitan la geolocalización de especies de malas hierbas, en base a imágenes captadas por un robot.

Además, la integración de la nube de puntos con la identificación de especies vegetales mediante PI@ntNet, permite avanzar hacia la creación de mapas de cobertura vegetal detallados. Estos mapas no solo representan la distribución espacial de la vegetación, sino que también incorporan información taxonómica, permitiendo distinguir entre especies cultivadas, ornamentales y no deseadas. Esta capacidad de clasificación precisa es especialmente útil en entornos agrícolas, donde la detección temprana y localizada de malas hierbas puede facilitar la toma de decisiones estratégicas en cuanto a control biológico, aplicación de herbicidas o modificación de prácticas de cultivo.

5. CONCLUSIONES

1. El método combina un flujo de trabajo integral que combina la captura de datos mediante sensores multicanal (RGB, profundidad y GPS), la mejora de imágenes y la segmentación de vegetación. Ha demostrado ser eficaz para la detección de malezas en entornos agrícolas reales. Contribuyendo a la automatización de la identificación de malas hierbas, una tarea que tradicionalmente requiere intervención manual y experiencia especializada, y mejorando la precisión y eficiencia en el manejo de cultivos.
2. La integración de técnicas de mejora de imagen, segmentación de vegetación y detección de puntos clave mediante algoritmos de detección, ha permitido obtener resultados consistentes incluso en condiciones de iluminación variable y densidad vegetal heterogénea. Confirmando que la metodología es versátil, escalable y adaptable a diferentes escenarios agrícolas.
3. La metodología propuesta contribuye a avanzar hacia estrategias de manejo de malas hierbas más sostenibles. La identificación automatizada permite reducir la dependencia de herbicidas químicos, promoviendo alternativas basadas en datos y tecnología. La combinación de visión artificial, procesamiento de imágenes y geolocalización posiciona este enfoque dentro del marco de la agricultura inteligente, fomentando la automatización, la eficiencia y la toma de decisiones basada en información precisa.
4. La validación mediante herramientas de identificación automatizada de especies vegetales como Pl@ntNet, demuestra que la metodología propuesta es fiable y precisa. Los resultados obtenidos muestran que el sistema es capaz de reconocer correctamente distintas especies de malezas, reforzando la confianza en su uso práctico.
5. La posibilidad de generar un registro espacial de la vegetación a partir de la creación de ortoimágenes geolocalizadas facilita la planificación y seguimiento de los cultivos. Este desarrollo proporciona una herramienta de valor estratégico para la agricultura de precisión, permitiendo identificar la ubicación de las malas hierbas y evaluar su evolución temporal, contribuyendo a un manejo más preciso y sostenible.

6. CONCLUSIONS

1. The method combines an integrated workflow that merges data acquisition through multichannel sensors (RGB, depth, and GPS), image enhancement, and vegetation segmentation. It has proven effective for weed detection in real agricultural environments, contributing to the automation of weed identification—a task that traditionally requires manual intervention and specialized expertise—while improving accuracy and efficiency in crop management.
2. The integration of image enhancement techniques, vegetation segmentation, and keypoint detection algorithms has enabled consistent results even under variable lighting conditions and heterogeneous vegetation density, confirming that the methodology is versatile, scalable, and adaptable to different agricultural scenarios.
3. The proposed methodology contributes to advancing more sustainable weed management strategies. Automated identification reduces reliance on chemical herbicides and promotes data-driven, technology-based alternatives. The combination of computer vision, image processing, and geolocation positions this approach within the framework of smart agriculture, fostering automation, efficiency, and data-driven decision-making.
4. Validation using automated plant species identification tools, such as Pl@ntNet, demonstrates that the proposed methodology is reliable and precise. The results show that the system is capable of correctly recognizing different weed species, reinforcing confidence in its practical application.
5. The ability to generate a spatial record of vegetation from georeferenced orthophotos facilitates crop planning and monitoring. This development provides a strategic tool for precision agriculture, allowing the identification of weed locations and the assessment of their temporal evolution, contributing to more precise and sustainable management.

7. BIBLIOGRAFÍA

- Abdo, A. I., Sun, D., Shi, Z., Abdel-Fattah, M. K., Zhang, J., & Kuzyakov, Y. (2025). Conventional agriculture increases global warming while decreasing system sustainability. *Nature Climate Change*, 15(1). <https://doi.org/10.1038/s41558-024-02170-4>
- AGROSUS Consortium. (2025a). *AGROSUS: Agroecological strategies for sustainable weed management in key European crops*. <https://agrosus.eu/>
- AGROSUS Consortium. (2025b). *Investigación financiada por la UE para impulsar la agroecología... Open Research Europe*. <https://open-research-europe.ec.europa.eu/articles/5-211>
- AGROSUS Consortium. (2025c). *Objectives*. <https://agrosus.eu/objectives/>
- Barberán, J. M. (2025). Sistemas agroecológicos como alternativa para enfrentar el cambio climático. *Revista Ciencia Agraria*, 4(1), 7–21. <https://doi.org/10.35622/j.rca.2025.01.001>
- Beaumelle, L., Tison, L., Eisenhauer, N., Hines, J., Malladi, S., Pelosi, C., Thouvenot, L., & Phillips, H. R. P. (2023). Pesticide effects on soil fauna communities: A meta-analysis. *Journal of Applied Ecology*, 60(7), 1239–1253. <https://doi.org/10.1111/1365-2664.14437>
- Boletín Oficial del Estado. (2009). *Directiva 2009/128/CE del Parlamento Europeo y del Consejo, de 21 de octubre de 2009, por la que se establece el marco de la actuación comunitaria para conseguir un uso sostenible de los plaguicidas* (BOE núm. 314). <https://www.boe.es/buscar/doc.php?id=DOUE-L-2009-82204>
- Canada, A., & Agri-Food. (2018, octubre 12). Molecular approach to insecticide resistance development and monitoring in potato insect pests [Sound]. Agriculture and Agri-Food Canada. <https://agriculture.canada.ca/.../molecular-approach-insecticide-resistance>
- Comisión Europea. (2025a). *Biodiversity strategy for 2030*. https://environment.ec.europa.eu/strategy/biodiversity-strategy-2030_en
- Comisión Europea. (2025b). *Farm to fork strategy*. https://food.ec.europa.eu/horizontal-topics/farm-fork-strategy_en
- Consejo de la Unión Europea. (1991). *Directiva 91/676/CEE relativa a la protección de las aguas contra la contaminación producida por nitratos utilizados en la agricultura*, 375 OJ L. <http://data.europa.eu/eli/dir/1991/676/oj/spa>
- El Jaouhari, M., Damour, G., Tixier, P., & Coulis, M. (2023). Glyphosate reduces the biodiversity of soil macrofauna and benefits exotic over native species in a tropical agroecosystem. *Basic and Applied Ecology*, 73, 18–26. <https://doi.org/10.1016/j.baae.2023.10.001>
- European Environment Agency. (2023, septiembre 18). *Environmental statement report 2022*. <https://www.eea.europa.eu/en/analysis/publications/environmental-statement-report-2022>

- European Commission, Directorate-General for Agriculture and Rural Development. (2023). *EU agricultural outlook 2023–2035*. Publications Office. <https://data.europa.eu/doi/10.2762/722428>
- Eurostat. (2025). *Agri-environmental indicator: Irrigation*. https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Agri-environmental_indicator_-_irrigation
- Galic, I., Bez, C., Bertani, I., Venturi, V., & Stankovic, N. (2024). Herbicide-treated soil as a reservoir of beneficial bacteria: Microbiome analysis and PGP bioinoculants in maize. *Environmental Microbiome*, 19(1), 107. <https://doi.org/10.1186/s40793-024-00654-6>
- García-Delgado, C., Barba-Vicente, V., Marín-Benito, J. M., Igual, J. M., Sánchez-Martín, M. J., & Rodríguez-Cruz, M. S. (2019). Influence of different agricultural management practices on soil microbial community over dissipation time of two herbicides. *Science of the Total Environment*, 646, 1478–1488. <https://doi.org/10.1016/j.scitotenv.2018.07.395>
- GitHub. (2014/2025). *ETHZ ASL [Software]*. <https://github.com/ethz-asl/kalibr>
- Google Earth. (2025). *Google Earth [Software]*. <https://earth.google.com/web>
- IBIS. (2025). Collectively charting the landscape of antifungal and fungicide resistance. *Nature Microbiology*, 10(9), 2109–2110. <https://doi.org/10.1038/s41564-025-02104-6>
- Jafir, M., Irfan, M., Zia-ur-Rehman, M., Hafeez, F., Ahmad, J. N., Sabir, M. A., Zulfiqar, U., Iqbal, R., Zulfiqar, F., & Moosa, A. (2023). The global trend of nanomaterial usage to control the important agricultural arthropod pests: A comprehensive review. *Plant Stress*, 10, 100208. <https://doi.org/10.1016/j.stress.2023.100208>
- Ministerio para la Transición Ecológica y el Reto Demográfico. (2025). *Aplicaciones de plantas: Pl@ntNet y PlantSnap*. <https://www.miteco.gob.es/es/ceneam/recursos/pag-web/plantner-plantsnap.html>
- Mohammed, S. P., Deepika, J., Sritharan, N., Ravichandran, V., Prasanthrajan, M., & Kannan, P. (2025). A systematic literature review on artificial intelligence in transforming precision agriculture for sustainable farming: Current status and future directions. *Plant Science Today*, 12(2). <https://doi.org/10.14719/pst.6175>
- OpenCV. (2025a). *Transformaciones morfológicas*. https://docs.opencv.org/4.x/d9/d61/tutorial_py_morphological_ops.html
- OpenCV. (2025b). *Histogram equalization*. https://docs.opencv.org/4.x/d5/daf/tutorial_py_histogram_equalization.html
- OpenCV. (2025c). *Image file reading and writing*. https://docs.opencv.org/4.x/d4/da8/group_imgcodecs.html#ga7d3d792ccd4c2cdef157850e1b907506

- OpenCV. (2025d). *ORB (Oriented FAST and Rotated BRIEF)* [Tutorial]. https://docs.opencv.org/4.x/d1/d89/tutorial_py_orb.html
- Otepka, J., Ghuffar, S., Waldhauser, C., Hochreiter, R., & Pfeifer, N. (2013). Georeferenced point clouds: A survey of features and point cloud management. *ISPRS International Journal of Geo-Information*, 2(4), 1038–1065. <https://doi.org/10.3390/ijgi2041038>
- Padhiary, M., Saha, D., Kumar, R., Sethi, L. N., & Kumar, A. (2024). Enhancing precision agriculture: A comprehensive review of machine learning and AI vision applications in all-terrain vehicle for farm automation. *Smart Agricultural Technology*, 8, 100483. <https://doi.org/10.1016/j.atech.2024.100483>
- Pantone. (2025). *Mezcla de color aditivo: Additive color models*. X-Rite. <https://www.xrite.com/es/blog/what-is-additive-rgb-color-mixing>
- Pesticides in rivers, lakes and groundwater in Europe. (2024, diciembre 10). *European Environment Agency*. <https://www.eea.europa.eu/en/analysis/indicators/pesticides-in-rivers-lakes-and>
- Pl@ntNet. (2025). *Cómo funciona el modelo de identificación*. <https://docs.plantnet.org/es/understand/how-the-identification-model-works/>
- Rabbee, M. F., Ali, M. S., Islam, M. N., Rahman, M. M., Hasan, M. M., & Baek, K.-H. (2024). Endophyte mediated biocontrol mechanisms of phytopathogens in agriculture. *Research in Microbiology*, 175(8), 104229. <https://doi.org/10.1016/j.resmic.2024.104229>
- Ricolfe Viala, C., & Sánchez Salmerón, A. J. (2008). Procedimiento completo para el calibrado de cámaras utilizando una plantilla plana. *Revista Iberoamericana de Automática e Informática Industrial RIAI*, 5(1), 93–101. [https://doi.org/10.1016/S1697-7912\(08\)70126-2](https://doi.org/10.1016/S1697-7912(08)70126-2)
- ScienceDirect Topics. (2025). *Kernel convolution*. <https://www.sciencedirect.com/topics/computer-science/kernel-convolution>
- Somasundaram, K., & Genish, T. (2023). Modified Otsu thresholding technique. In M. Sharma (Ed.), *Image processing methods* (pp. xx–xx). https://doi.org/10.1007/978-3-642-28926-2_49
- Triton Industrial Camera. (2025). *Triton industrial camera*. LUCID Vision Labs. <https://thinklucid.com/triton-gige-machine-vision/>
- Yu, T.-S., Park, K., Han, K.-H., & Kwak, I.-S. (2024). Morphological and genetic analysis for the diversity conservation of rare species, *Thamnaconus multilineatus* (Tetraodontiformes: Monacanthidae). *PLOS ONE*, 19(2), e0292916. <https://doi.org/10.1371/journal.pone.0292916>
- ZED 2i Stereo Camera. (2025). *ZED 2i stereo camera*. Stereolabs. <https://www.stereolabs.com/en-es/store/products/zed-2i>

Zilnik, G., Bergeron, P. E., Chuang, A., Diepenbrock, L., Hanel, A., Middleton, E., Moretti, E., & Schmidt-Jeffris, R. (2023). Meta-analysis of herbicide non-target effects on pest natural enemies. *Insects*, *14*(10), 787. <https://doi.org/10.3390/insects14100787>