UNIVERSIDAD POLITÉCNICA DE MADRID

ESCUELA TÉCNICA SUPERIOR DE INGENIEROS INDUSTRIALES

**CONTRIBUCIONES AL DESARROLLO DE
UN SISTEMA EFECTIVO PARA LA INSPECCIÓN
DE CULTIVOS**

TESIS DOCTORAL

JOSÉ MARÍA BENGOCHEA GUEVARA

Ingeniero de Telecomunicación
Máster en Automática y Robótica

2017

**DEPARTAMENTO DE AUTOMÁTICA,
INGENIERÍA ELÉCTRICA Y ELECTRÓNICA E
INFORMÁTICA INDUSTRIAL**

ESCUELA TÉCNICA SUPERIOR DE INGENIEROS INDUSTRIALES

**CONTRIBUCIONES AL DESARROLLO DE
UN SISTEMA EFECTIVO PARA LA INSPECCIÓN
DE CULTIVOS**

TESIS DOCTORAL

Autor: José María Bengochea Guevara
Ingeniero de Telecomunicación
Máster en Automática y Robótica

Directora: Ángela Ribeiro Seijas
Dra. en Ciencias Físicas

2017

CONTRIBUCIONES AL DESARROLLO DE UN SISTEMA EFECTIVO PARA LA INSPECCIÓN DE CULTIVOS

Autor: José María Bengochea Guevara

Tribunal

Presidente: Dr. José María Sebastián y Zúñiga

Secretario: Dr. Antonio Barrientos Cruz

Vocal A: Dr. Gonzalo Pajares Martinsanz

Vocal B: Dr. Francisco Rovira Más

Vocal C: Dr. José Dorado Gómez

Suplente A: Dr. Arturo de la Escalera Hueso

Suplente B: Dr. Álvaro Sánchez Miralles

Acuerdan otorgar la calificación de:

Madrid,

de

de 2017

Agradecimientos

Al fin. Hace unos años lo veía tan lejano... pero lo conseguí. Dejé un mundo que no me llenaba por estudiar el Máster en Automática y Robótica, con la idea de, a continuación, realizar el Doctorado y conseguir hacer la tesis... Ha habido momentos malos, pero siempre lo tuve claro. Y he procurado disfrutar del camino. Aunque haya sido un trayecto largo y duro, he intentado darme cuenta de todo lo que suponía poder dedicarme a esto: la robótica, investigar, trabajar en una cosa que me gusta... era lo que yo quería. Esta época de mi vida ha sido una etapa que me ha llenado, y espero que no acabe y poder seguir disfrutándola.

Durante este tiempo he madurado y evolucionado, he crecido tanto personal como profesionalmente, he vivido momentos buenos, momentos malos, pero creo que ahora soy mejor y el contacto con el ámbito de la investigación me ha hecho tener una mente más abierta.

Aún con todo, este último año ha sido especialmente duro. Ha sido mi año más aislado del mundo, y desde aquí pido mil disculpas a todas las personas que este año he tenido más abandonadas porque necesitaba tiempo para la tesis. Espero que sepáis perdonarme. Ahora ya volveré a ser Chema.

Y después de esta retahíla, al lío.

Quería empezar dando las gracias a todas las personas relacionadas con la realización de esta tesis.

En primer lugar, a mi directora, Ángela, por haber confiado en mí. Buscaba esto y ella me acogió, confió en mí y me ha permitido hacerlo realidad. Gracias por todo, Ángela, por formarme como investigador, por tu ayuda tanto a nivel técnico como humano, y por todas esas horas de charlas para desconectar del trabajo.

A Jesús, por todo. No pude tener mejor compañero de despacho. Por todo lo que aprendí de él, sus bromas, lo bien que se portó conmigo, nuestras charlas, su ayuda, etc. Sin ti esta tesis no habría sido posible.

A Dioni, por el impulso que me dio, por ser un ejemplo a seguir, por toda su colaboración y por tantas horas de furgoneta. De mayor quiero ser como tú.

A Damián, por su dominio de la electrónica, su predisposición a ayudar y su humor ácido.

A Nadir, por tantos ratos de experimentación y de coche juntos, por ser tan buen tío y por ver la vida de otra manera.

A Karla, la siguiente en doctorarse, por su buen corazón.

A Javi H., por su buen humor y ser tan concienzudo. Esa rejilla no habría sido posible sin ti.

A Lisa y Antonio, por todas esas amenas charlas en el despacho que nos hacían desconectar.

A Kiko, Ignacio, Néstor, etc., por todos los ratos de experimentación pasados.

Al personal técnico y de apoyo del Centro de Automática y Robótica, por haber colaborado a que esta tesis llegara a buen puerto. Así como a todas las personas que forman o formaron parte del Centro durante mi estancia allí, por hacerla más agradable.

A los doctores José Dorado, César Fernández-Quintanilla, Jordi Recasens, D. Francisco Valencia, D. Pedro Hernáiz, todo el equipo de la finca de la Poveda y a Codorníu, S.A., por su colaboración en todos los experimentos realizados en los distintos campos de cultivo.

Al Ministerio de Educación, Cultura y Deporte, por la financiación aportada para los proyectos AGL2011-30442-C02-02 y AGL2014-52465-C4-3-R, sin los cuales no habría sido posible el desarrollo de esta tesis.

Aparte de todos estos agradecimientos, quería darles las gracias a varias personas que llenan mi vida y sin las cuales tampoco podría haber conseguido hacer esta tesis. Quería dar las gracias:

A mis padres, por haber hecho posible que consiguiera esto, sin vosotros no habría llegado a ser cómo soy. Os quiero.

A mis hermanos, Miguel y Javi, las personas que más quiero. Siempre estaré ahí para lo que necesitéis.

A Rarraw, terima kasih telah membuatku bahagia, aku cinta kamu.

A Sandra (y Sarela y Dani), por ser así, por estar siempre ahí, por su buen corazón y por presentarme a Sare, que me hizo cambiar el chip. ¿Entón?

A Víctor y Edu, por acompañarme durante tantos años, por su amistad y por todos los momentos juntos. Y que siga.

A Isa y Álvaro (y Daniela y Álvaro Jr.), por abrirme las puertas de su casa y estar ahí cuando lo necesito. Sois los mejores.

A mis amigos y compañeros de equipo durante tantos años: Javi, Miguel Ángel, Eze, Ivi, Víctor y Juan, por tanto tiempo de amistad... y por haberme hecho ganar una liga mientras hacía la tesis, ya podré retirarme tranquilo.

A Fer, María, Fran, Chema, Nuria y Xavi, porque con ellos empezó todo esto y por seguir disfrutando de su compañía en las quedadas. Sois todos unos cracks.

A Bea y Jesús, una de las mejores parejas que he conocido, por transmitirme tanto.

A Shahad, aún en la distancia, te siento cerca.

A Manolo, Azu, Pablo, Noe, María, Víctor y Joaquín, por lo bien que me hicieron sentir cuando estaba en Teldat y por lo bien que me hacen sentir cada vez que les veo.

A Arte, por tratarme siempre tan bien y por su conocimiento sin igual.

A Chuy, mi fiel compañero. Llegaste a mí cuando comencé la tesis y me dejaste al final. Gracias por toda la compañía que me diste, amigo, va por ti.

A todos los profesores y compañeros que he tenido, porque sin ellos no habría llegado hasta aquí.

A todos los investigadores, por su labor y dedicación, por intentar que éste sea un mundo mejor.

A todas las personas que han pasado por mi vida, porque de todas he aprendido algo.

Gracias a todos,

Chema

Resumen

Tradicionalmente, las prácticas de cultivo se han orientado hacia una gestión uniforme del campo, ignorando la variabilidad espacial y temporal de los cultivos. En los últimos años, gracias al desarrollo de diversas tecnologías, ha surgido el concepto de Agricultura de Precisión, que propone la adaptación de la gestión de los cultivos a la variabilidad que estos presentan. Entre las principales ventajas de adoptar un manejo de precisión está la reducción tanto de los costes de producción como de la cantidad de agroquímicos utilizada, lo que conlleva una importante mejora en la salud humana y la calidad medioambiental. Una etapa fundamental para la implantación de un esquema de Agricultura de Precisión es la monitorización o inspección continua de los cultivos. Para este fin, los vehículos equipados con sensores embarcados son considerados como una de las tecnologías más prometedoras. El uso de vehículos de pequeña/mediana envergadura para inspeccionar un cultivo con cobertura total es una opción adecuada frente a máquinas grandes ya que se minimiza tanto el daño sobre la planta como la compactación del suelo. En definitiva, este tipo de vehículos permiten realizar más de un muestreo a lo largo de una campaña lo que favorece el seguimiento continuo del estado del cultivo.

El objetivo de esta tesis es investigar en el desarrollo de los distintos elementos que deben componer un sistema autónomo de inspección efectiva terrestre de cultivos. Entre otras cosas, el sistema de inspección debe estar compuesto por una plataforma móvil autónoma en la que se integren un conjunto de sensores. Con el fin de explorar las posibilidades de diferentes vehículos, se ha trabajado con un robot comercial, se ha realizado la automatización de un vehículo disponible en la mayoría de explotaciones agrícolas, en concreto una cuatrimoto o ATV (del inglés *All Terrain Vehicle*) con motor de explosión y se ha llevado a cabo la automatización de un vehículo eléctrico comercial. Además, se han desarrollado una serie de conductas que permiten que el vehículo de inspección navegue autónomamente por el campo siguiendo visualmente una línea de cultivo.

Por otra parte, la generación de mapas que describan de forma precisa el estado del cultivo es una etapa esencial para llevar a cabo la implantación de un modelo de Agricultura de Precisión. En esta tesis se presenta un método para generar mapas de distribución de la cubierta vegetal (línea de cultivo y malas hierbas) en cultivos sembrados con una separación entre líneas que permite visualmente distinguirlas. Los mapas se construyen a partir de la información suministrada por una cámara réflex comercial y un receptor GPS-RTK, todos dispositivos embarcados en la plataforma de

inspección. El método desarrollado, además elimina los efectos de los movimientos no deseados de la cámara debidos a las irregularidades del terreno.

Asimismo, este trabajo de tesis aborda la reconstrucción 3D estudiando diferentes métodos para finalmente implementar un algoritmo que proporciona buenos resultados en la reconstrucción de grandes áreas a partir de la información suministrada directamente por un sensor RGB-D. Además, se resuelve el problema de las deformaciones que aparecen en la reconstrucción como consecuencia de la deriva, más acentuadas cuanto mayor es el área reconstruida. El método desarrollado se ha probado con muy buenos resultados en cultivos leñosos, en concreto en la reconstrucción 3D de líneas de viñedos comerciales. Finalmente, a partir de la reconstrucción 3D corregida, se han desarrollado diferentes procedimientos para estimar ciertos parámetros del cultivo como la altura, la anchura o el volumen de las copas. Todos los parámetros estimados se pueden situar en sus coordenadas geográficas reales, por lo que se pueden presentar como mapa.

Abstract

Traditionally, agronomic tasks are carried out considering fields as uniform units, applying inputs homogeneously. The spatio-temporal variability is usually ignored. Lastly, the development of new agricultural technologies is increasing. Thus, a new concept has arisen: Precision Agriculture (PA). PA takes into consideration the spatial variability of crops managing the fields accordingly. The adoption of these technologies reduces production costs and the use of agrochemicals. Thus, the environmental impact and human health is improved. PA requires various steps. Crop monitoring is of high importance in the final quality of agricultural production. The continuous monitoring recreates the reality of the field. The use of small and medium size vehicles or platforms equipped with sensing technologies are considered as one of the most promising challenge in agricultural development. Small machinery reduces crop damages and soil compaction. Thus, these vehicles could sample a large area during cropping seasons while reducing big machinery problems. In addition, the continuous monitoring creates information for a better crop management increasing yield while reducing the environmental impact.

The goal of this thesis is to investigate in the development of the different elements that must compose an effective autonomous system of inspection of crops. Inspection system must be composed of an autonomous mobile platform in which a set of sensors are integrated. In order to explore the possibilities of different vehicles, a commercial robot was used, the automation of an All-Terrain Vehicle with a four-stroke engine, common vehicle in most of farms, was carried out, and the automation of a commercial electric vehicle was performed. In addition, a set of behaviours, that allow the inspection vehicle to navigate autonomously along the field tracking a crop row, was developed.

The monitoring processes create maps describing crop status. The accuracy of maps is essential to develop of PA plans. The thesis also shows a method for plant mapping. A system for crop and weed monitoring was developed. The system creates weed cover and crop cover maps in row crops. The system works from wide to narrow row crops. The mapping system fused the information of a commercial RGB camera and a GPS RTK receiver. All the sensing devices were installed on-board of the inspection platform. The developed method reduces and eliminates the movement of the camera due to the irregularities of the fields and platform vibrations.

Additionally, the use of 3D reconstruction methods was developed in this thesis. Different

methodologies were used for the implementation of a new algorithm for huge surface modelling. The input data coming from a RGB-D sensor showed promising results in crop reconstruction. Also, the deformations coming from the drift were solved. The method has been widely tested in several woody crops. The presented results show a good agreement in vineyard cultivated under different agronomic managements. The current method extracts values of crop height, with and crown volume. Every parameter is geolocalized, which creates different attribute maps for crop management.

Índice

Agradecimientos	ix
Resumen	xiii
Abstract.....	xv
Índice	xvii
Índice de Figuras	xxi
Índice de Tablas.....	xxvii
Listado de acrónimos	xxix
1. Introducción	1
1.1. Motivación.....	1
1.2. Objetivos.....	3
1.2.1. Vehículos de inspección	4
1.2.2. Reconstrucción del entorno	4
1.3. Aportaciones de la investigación	4
1.3.1. Publicaciones en revistas.....	4
1.3.2. Congresos y conferencias	6
1.3.3. Actividades de diseminación	10
1.4. Estructura de la tesis	10
2. Estado del arte	13
2.1. Agricultura de Precisión	13
2.2. Vehículos de inspección.....	15
2.3. Reconstrucción del entorno	19
3. Robot móvil comercial de pequeña envergadura.....	23
3.1. Descripción del robot.....	23
3.1.1. Arquitectura interna	24
3.1.1.1. Placa base	25
3.1.1.2. Tarjeta de control IOM.....	25
3.1.1.3. MCU	26
3.1.1.4. Sensores infrarrojos	27
3.1.2. Mejoras sobre la plataforma inicial.....	27

3.1.3.	Protocolo de comunicación	28
3.1.3.1.	Protocolo general de paquete.....	28
3.1.3.2.	Mensajes más importantes recibidos por el robot	29
3.1.3.3.	Mensajes más importantes enviados por el robot.....	30
3.2.	<i>Arquitectura del sistema</i>	30
3.2.1.	Ordenador de a bordo	31
3.2.2.	Cámara réflex	31
3.2.3.	Receptor GPS-RTK	32
3.3.	<i>Teleoperación</i>	33
3.3.1.	Interfaz GUI.....	33
3.3.1.1.	Opción <i>Controls</i>	34
3.3.1.2.	Opción <i>More Info</i>	35
3.4.	<i>Comportamiento Autónomo/Navegación autónoma</i>	35
3.4.1.	Conducta de seguimiento de línea de cultivo	37
3.4.1.1.	Procesamiento de imagen.....	37
3.4.1.1.1.	Segmentación	39
3.4.1.1.2.	Detección de la línea central del cultivo	40
3.4.1.1.3.	Extracción de la línea recta que define la línea central del cultivo	42
3.4.1.2.	Control de navegación.....	43
3.4.1.2.1.	Introducción a la lógica borrosa	44
3.4.1.2.2.	Conjuntos borrosos.....	44
3.4.1.2.3.	Funciones de pertenencia de conjuntos borrosos	45
3.4.1.2.4.	Función de pertenencia trapezoidal	45
3.4.1.2.5.	Función de pertenencia singleton.....	46
3.4.1.2.6.	Función de pertenencia triangular.....	46
3.4.1.2.7.	Reglas borrosas	47
3.4.1.2.8.	<i>Borrosificador</i>	47
3.4.1.2.9.	<i>Desborrosificador</i>	47
3.4.1.2.10.	Controladores borrosos.....	48
3.4.1.2.11.	Control propuesto	48
3.4.1.2.12.	Controlador borroso de la velocidad de rotación	49
3.4.1.2.13.	Controlador borroso de la velocidad de traslación	52
3.4.2.	Conducta de detección del final de la línea de cultivo.....	54
3.4.3.	Conducta de cambio de línea	55
3.5.	<i>Resultados</i>	56
4.	Cuatrimoto con motor de explosión	63
4.1.	<i>Descripción del vehículo</i>	63
4.2.	<i>Arquitectura del sistema</i>	64
4.2.1.	Ordenador de a bordo	65
4.2.2.	Receptor GPS-RTK	65
4.2.3.	Unidad de medición inercial	65
4.2.4.	Microcontrolador	66
4.2.5.	Alimentación.....	66
4.2.6.	Sistemas de actuación.....	67
4.2.6.1.	Sistema de actuación sobre el acelerador	67
4.2.6.2.	Sistema de actuación sobre el freno.....	68
4.2.6.3.	Sistema de actuación sobre la dirección.....	70
4.2.7.	Sistema completo.....	72
4.3.	<i>Control de la velocidad de traslación y de la dirección del ATV</i>	72
4.3.1.	Control de velocidad de traslación	73
4.3.2.	Control de dirección	75
4.4.	<i>Teleoperación</i>	77
4.5.	<i>Resultados</i>	78

5. Vehículo eléctrico	81
5.1. Descripción del sistema	81
5.1.1. Vehículo eléctrico	81
5.1.2. Sensor RGB-D	83
5.2. Automatización del vehículo	84
5.2.1.1. Sistema de actuación sobre la dirección	85
5.2.1.2. Sistema de actuación sobre el acelerador	87
5.2.1.3. Sistema de actuación sobre el freno	87
5.2.2. Software	89
5.3. Teleoperación	90
5.4. Resultados	90
6. Reconstrucción 2D del entorno	93
6.1. Generación de mapa 2D georreferenciado	94
6.1.1. Extracción de las rectas que definen las tres líneas de cultivo	94
6.1.2. Estabilización de la imagen	97
6.1.3. Obtención de imagen cenital	97
6.1.4. Construcción del mapa	99
6.1.5. Georreferenciación	100
6.2. Resultados	101
7. Reconstrucción 3D del entorno	107
7.1. Reconstrucción 3D	107
7.1.1. Algoritmo de reconstrucción 3D	108
7.1.1.1. Representación y almacenamiento de la información	108
7.1.1.2. Integración de la información nueva	110
7.1.1.3. Seguimiento de la cámara	111
7.1.2. Generación de representación 3D	114
7.2. Deriva de la reconstrucción 3D	116
7.2.1. Filtrado	116
7.2.2. Cálculo de la línea modelo	117
7.2.3. División de la fila en secciones de la misma longitud	118
7.2.4. Corrección de cada sección	119
7.3. Extracción de información: cálculo de parámetros	122
7.3.1. Extracción de copas de cada sección	123
7.3.2. Cálculo del volumen de la copa de cada sección	123
7.3.3. Cálculo de la altura máxima del árbol en cada sección	125
7.3.4. Cálculo de la anchura proyectada máxima del árbol en cada sección	125
7.4. Resultados	125
8. Conclusiones y trabajo futuro	131
8.1. Conclusiones	131
8.1.1. Vehículos de inspección	131
8.1.2. Reconstrucción del entorno	133
8.2. Trabajo futuro	134
8.2.1. Vehículos de inspección	134
8.2.2. Reconstrucción del entorno	134
9. Bibliografía	137

Índice de Figuras

Figura 3.1. Robot mBase-MR7 de Movirobotics.....	24
Figura 3.2 Arquitectura interna del robot mBase-MR7.....	24
Figura 3.3. Conexiones de la tarjeta LV-7FX-i7-4GB.....	25
Figura 3.4. Conexiones de la tarjeta IOM.....	26
Figura 3.5. Conexión de los motores a las tarjetas MCU	26
Figura 3.6. Conexiones de cada tarjeta MCU	27
Figura 3.7. Sensores infrarrojos frontales.....	27
Figura 3.8. Esquema de alimentación de la plataforma	28
Figura 3.9. Distribución de conectores e interruptores en el panel superior del robot	28
Figura 3.10. Estructura de paquete del protocolo de comunicación del robot	29
Figura 3.11. Arquitectura del sistema desarrollado.....	31
Figura 3.12. Localización de la cámara junto con todos los elementos del sistema y ejemplo de imagen captada por la cámara	32
Figura 3.13. Interfaz vista por el operados (Opción <i>Controls</i>).....	33
Figura 3.14. Interfaz vista por el operario (Opción <i>More Info</i>)	34
Figura 3.15. Trayectoria calculada por el planificador para que el robot mBase-MR7 recorra todas las líneas del campo de cultivo de maíz utilizado en los experimentos.	36
Figura 3.16. Posición y orientación del robot respecto a la línea central del cultivo	37
Figura 3.17. (a) Imagen característica captada por la cámara del robot (b) Región de interés de la imagen recuadrada en rojo.....	38
Figura 3.18. Diagrama de flujo del procesamiento de imagen	38
Figura 3.19. (a) Imagen original con una marcada presencia de malas hierbas (b) Imagen en escala de grises (c) Imagen segmentada	40

Figura 3.20. Imagen obtenida tras aplicar el operador Sobel a una imagen captada por el robot.....	40
Figura 3.21. (a) Imagen segmentada (b) Línea central del cultivo detectada aplicando el método de detección propuesto a la Figura 3.19 (a)	42
Figura 3.22. (a) Línea central del cultivo obtenida en la etapa anterior (b) Columnas blancas y negras definidas por el algoritmo (c) Línea recta que define la línea central del cultivo.....	43
Figura 3.23. Función trapezoidal	45
Figura 3.24. Función <i>singleton</i>	46
Figura 3.25. Función triangular.....	46
Figura 3.26. Estructura de un controlador borroso	48
Figura 3.27. Esquema visual del control desarrollado.....	49
Figura 3.28. Controlador de la velocidad de rotación. Conjuntos borrosos de las variables de entrada: (a) Desplazamiento d y (b) Ángulo de orientación α	51
Figura 3.29. Controlador de la velocidad de rotación. Conjuntos borrosos para la variable de salida.....	52
Figura 3.30. Controlador de la velocidad de traslación. Conjuntos borrosos de las variables de entrada: (a) Desplazamiento d y (b) Ángulo de orientación α	53
Figura 3.31. Controlador de la velocidad de traslación. Conjuntos borrosos para la variable de salida	54
Figura 3.32. (a) Imagen captada por el robot al final de la línea de cultivo y (b) su correspondiente imagen segmentada. El número de píxeles asociados a vegetación (píxeles blancos) es inferior al 80% del número de píxeles blancos en la imagen de referencia (Figura 3.19) y la localización del robot es muy cercana al punto de salida definido por el plan para esa línea de cultivo que se está inspeccionando. De esta forma, el robot determina que ha alcanzado el final de la línea de cultivo.....	55
Figura 3.33. Maniobras definidas para la conducta de cambio de línea	56
Figura 3.34. (a)-(c) Ejemplos de imágenes adquiridas por la cámara del robot en diferentes campos y distintos días. (a) Campo de maíz crecido con presencia de malas hierbas (b) Campo de maíz en un estado inicial con sistema de irrigación visible (c) Final de un campo de maíz con presencia de malas hierbas.....	56
Figura 3.35. Celdas de acumulación en el espacio ρ - θ	57
Figura 3.36. (a) Primer entorno de test (b) Imagen del campo de cultivo empleado en los experimentos.....	58
Figura 3.37. Primer entorno de test: (a) Evolución de la velocidad de traslación del robot (b) Evolución de la velocidad de rotación del robot (c) Evolución del desplazamiento relativo a la línea (d) Evolución del ángulo de orientación del robot relativo a la línea.....	59
Figura 3.38. Conducta de seguimiento de línea de cultivo. Las imágenes (a)-(d) muestran una secuencia de diferentes imágenes del vídeo disponible en (GPA Group Channel, 2017c).	60
Figura 3.39. Secuencia de maniobras realizadas para el cambio de línea: (a) Correspondiente a la maniobra 1 en Figura 3.33, es decir, movimiento en línea recta hacia delante; (b) Maniobra 2, movimiento en arco; (c) Maniobra 3, movimiento en línea recta hacia delante; (d) Maniobra 4,	

movimiento en arco marcha atrás y (e) Maniobra 5, movimiento en línea recta hacia delante. El vídeo de la secuencia se puede ver en (GPA Group Channel, 2017c)	60
Figura 3.40. Experimentos en un campo real: (a) Evolución de la velocidad de traslación del robot; (b) Evolución de la velocidad de rotación del robot; (c) Evolución del desplazamiento relativo a la línea y (d) Evolución del ángulo de orientación del robot relativo a la línea	62
Figura 4.1. ATV Yamaha Grizzly 700	64
Figura 4.2. Arquitectura del sistema	65
Figura 4.3. Localización de la IMU en el ATV	66
Figura 4.4. Esquema del sistema de actuación sobre el acelerador	67
Figura 4.5. Esquema eléctrico del sistema de actuación del acelerador	67
Figura 4.6. Mecanismo de giro del acelerador	68
Figura 4.7. Esquema del sistema de actuación sobre el freno	68
Figura 4.8. Esquema eléctrico del sistema de actuación sobre el freno	69
Figura 4.9. Mecanismo de actuación sobre el freno	69
Figura 4.10. Motor de dirección asistida	70
Figura 4.11. Esquema del sistema de actuación sobre la dirección	71
Figura 4.12. Esquema del sistema de actuación sobre la dirección con el detalle de los bloques que componen la tarjeta	71
Figura 4.13. Esquema eléctrico del sistema de actuación sobre la dirección	71
Figura 4.14. ATV con todos los elementos necesarios para su automatización	72
Figura 4.15. Controlador de la velocidad de traslación. Conjuntos borrosos de las variables de entrada: (a) Error de velocidad y (b) Derivada del error de velocidad	74
Figura 4.16. Controlador de la velocidad de traslación. Conjunto borroso para la variable de salida: variación en el ángulo de giro del servomotor que actúa sobre el acelerador	75
Figura 4.17. Controlador de la dirección. Conjuntos borrosos de las variables de entrada: (a) Error de orientación y (b) Derivada del error de orientación	76
Figura 4.18. Controlador de la dirección. Conjunto borroso para la variable de salida: ancho de pulso de la señal PWM	77
Figura 4.19. Interfaz para teleoperar el ATV	78
Figura 4.20. Seguimiento de velocidad de referencia	79
Figura 4.21. Seguimiento de ángulo de referencia	79
Figura 5.1. Renault Twizy. Modelo Urban 80	82
Figura 5.2. Plataforma de inspección basada en un vehículo eléctrico comercial	83
Figura 5.3. Sensor Kinect v2 de Microsoft	84
Figura 5.4. (a) Medida de la diferencia de tiempo entre la luz emitida y la recibida. Imagen extraída de (Sell & O'Connor, 2014) (b) Interior del sensor Kinect v2. Imagen extraída de (Ifixit, 2017)	84
Figura 5.5. Arquitectura del sistema	85

Figura 5.6. Motor, junto su reductor y <i>encoder</i> , utilizado para actuar sobre la dirección del vehículo.....	86
Figura 5.7. Sistema de correa de distribución para actuar sobre la dirección del vehículo	86
Figura 5.8. Estructura del pedal falso (a) Vista lateral (b) Vista cenital	87
Figura 5.9. Servomotor, carrete y cable utilizado para actuar sobre el freno del vehículo	88
Figura 5.10. Pedal de freno unido al cable que sirve para actuar sobre él	88
Figura 5.11. Esquema de nodos y temas para conseguir la automatización del sistema	89
Figura 5.12. Esquema de nodos y temas del sistema funcionando de forma teleoperada	90
Figura 5.13. Velocidad del vehículo en respuesta a la actuación sobre el pedal falso	91
Figura 5.14. Ángulo de posicionamiento del volante en respuesta a la actuación sobre la dirección.....	91
Figura 5.15. Recorrido del vehículo controlado por el <i>joystick</i> en un circuito de prueba.....	92
Figura 6.1. Imagen captada por la cámara. La región de interés o trabajo aparece dentro del rectángulo rojo	94
Figura 6.2. (a) Imagen en escala de grises e (b) imagen binaria de la región de interés de la Figura 6.1.....	95
Figura 6.3. Detección de las tres líneas de cultivo en la imagen resultante de la etapa anterior	96
Figura 6.4. (a) Puntos que determinan las tres líneas de cultivo de la Figura 6.3 y (b) extracción de las rectas que las definen.....	96
Figura 6.5. Modelo de proyección de perspectiva.....	97
Figura 6.6. En amarillo, los cuatro puntos de la imagen original que se utilizan para realizar la transformación proyectiva	98
Figura 6.7. Rejilla cuadriculada construida.....	99
Figura 6.8. Imagen cenital obtenida después de aplicar la transformación proyectiva a la imagen de la Figura 6.3	99
Figura 6.9. Imagen captada por la cámara, donde se aprecia la rodada provocada por un tractor en la calle de la derecha. También se observa que la imagen está inclinada.....	101
Figura 6.10. Secuencia de imágenes adquiridas por la cámara donde se pueden apreciar las bruscas modificaciones en la imagen debidas a las variaciones en la orientación de la cámara.....	102
Figura 6.11. (a) Desplazamientos y (b) ángulos medidos durante el recorrido del robot.....	102
Figura 6.12. Mapa construido de la línea de cultivo recorrida.....	104
Figura 6.13. (a) Imagen adquirida durante el recorrido del robot en la que aparece un rodal de mala hierba que se ha señalado en rojo (b) Zona del mapa correspondiente a esa imagen, donde se señala en rojo el rodal de mala hierba.....	105
Figura 7.1. Aspecto de una rejilla de vóxeles.....	109
Figura 7.2. Ejemplo de valores SDF.....	109
Figura 7.3. La técnica <i>raycasting</i>	110
Figura 7.4. Error entre dos superficies según (Low, 2004)	112

Figura 7.5. Entrada y salida del algoritmo Marching Cubes	114
Figura 7.6. Configuraciones básicas del algoritmo <i>Marching Cubes</i>	115
Figura 7.7. (a)-(c) Distintos ejemplos de mallas triangulares generadas en función de las diferentes posiciones de los vértices en las aristas.....	115
Figura 7.8. Deriva en la reconstrucción 3D de una fila de viñedos.....	116
Figura 7.9. (a) Fragmento de reconstrucción 3D antes del filtrado; (b) El mismo fragmento después del filtrado	117
Figura 7.10. Línea modelo de la fila de viñedos de la Figura 7.8	118
Figura 7.11. Los círculos amarillos representan los puntos extremos de la fila de árboles (Figura 7.8) añadidos a la línea modelo de la Figura 7.9	118
Figura 7.12. Parte de la fila de viñedos de la Figura 7.8 dividida en secciones	119
Figura 7.13. En amarillo, sistema de coordenadas definido y utilizado	119
Figura 7.14. En rojo el vector que conecta los puntos inicial y final del segmento donde se encuentra la sección (eje X de la sección).....	120
Figura 7.15. En rojo el eje X de la sección (<i>Xsección</i>) y en amarillo el eje X de referencia (<i>Xreferencia</i>) para la alineación.....	121
Figura 7.16. Reconstrucción 3D con deriva de una fila de viñedos (arriba) y resultado una vez eliminada la deriva (abajo)	122
Figura 7.17. A la izquierda, los vértices de la sección original sin componente de color. En el centro, los dos grupos encontrados por el algoritmo K-means aplicado sobre la componente z de los vértices. A la derecha, los dos grupos obtenidos representados en verde y marrón sobre la sección original	123
Figura 7.18. Ejemplo de contorno generado a partir de un conjunto de puntos utilizando <i>alpha shapes</i>	124
Figura 7.19. (a) Vista frontal de la copa de una sección capturada por un solo lado de la fila, (b) <i>Alpha shape</i> para la copa mostrada en (a) con $\alpha = 0.1$, (c) con $\alpha = 0.2$ y (d) con $\alpha = 0.4$; (e)-(h) Vistas laterales de las imágenes de (a) a (d).....	124
Figura 7.20. Detalle del muestreo en los viñedos de Codorníu S.A. en Raimat (Lérida) en mayo de 2016	125
Figura 7.21. (a) y (c) Imágenes RGB adquiridas por el sensor Kinect v2; (b) y (d) Imágenes de profundidad adquiridas por el sensor en el mismo instante de tiempo que (a) y (c)	126
Figura 7.22. Reconstrucción 3D de una fila de viñedos	127
Figura 7.23. Detalle de la reconstrucción 3D de un viñedo en el que se aprecia el mallado obtenido a partir de la nube de puntos.....	127
Figura 7.24. Reconstrucción 3D de una de las filas de viñedo con presencia importante de deriva	127
Figura 7.25. Reconstrucción 3D con la deriva corregida de la fila de viñedos que aparece en la Figura 7.24.....	128
Figura 7.26. 4 filas de viñedos pertenecientes a una misma parcela. Muestreo realizado el julio de 2016	128

Figura 7.27. Representación en falso color de las filas de viñedos de la Figura 7.26. El color representa la altura de los distintos puntos con respecto al suelo	129
Figura 7.28. Perfil de alturas máximas de una fila de viñedos.....	129
Figura 7.29. Anchuras proyectadas máximas de una fila de viñedos.....	130
Figura 7.30. Distribución de volúmenes de una fila de viñedos.....	130

Índice de Tablas

Tabla 3.1. Características del robot mBase-MR7	24
Tabla 3.2. Mensajes más importantes recibidos por el robot	29
Tabla 3.3. Mensajes más importantes enviados por el robot	30
Tabla 3.4. Método de detección de línea de cultivo	42
Tabla 3.5. Reglas de control borroso para la velocidad de rotación	52
Tabla 3.6. Reglas de control borroso para la velocidad de traslación.....	54
Tabla 3.7. Detección de la línea central del cultivo. Rendimiento de la estrategia propuesta y de la estrategia basada en la transformada de Hough.....	57
Tabla 3.8. Resultados obtenidos en el entorno de test.....	58
Tabla 3.9. Resultados obtenidos en un campo real.....	61
Tabla 4.1. Condiciones de trabajo del motor de dirección asistida.....	70
Tabla 4.2. Reglas de control borroso para la velocidad de traslación.....	75
Tabla 4.3. Reglas de control borroso para la velocidad de traslación.....	77
Tabla 6.1. Medidas obtenidas a partir de las imágenes durante el recorrido del robot.....	103

Listado de acrónimos

ABS	Antiblockiersystem
ATV	All Terrain Vehicle
CAN	Controller Area Network
DSS	Decision Support System
FOG	Fibre Optic Gyroscope
GIS	Geographic Information System
GNSS	Global Navigation Satellite System
GPS	Global Positioning System
GUI	Graphical User Interface
I ² C	Inter-Integrated Circuit
ICP	Iterative Closest Point
IMU	Inertial Measurement Unit
LiDAR	Light Detection And Ranging
NTRIP	Networked Transport of RTCM via Internet Protocol
PID	Proporcional Integrativo Derivativo
PWM	Pulse With Modulation
ROS	Robot Operating system
RTK	Real Time Kinematic
SDF	Signed Distance Function
SfM	Structure from Motion
SLAM	Simultaneous Localization And Mapping
TOF	Time Of Flight
TSDF	Truncated Signed Distance Function
UAV	Unmanned Aerial Vehicle

1. INTRODUCCIÓN

1.1. Motivación

A lo largo de la historia, la mecanización y la automatización de la agricultura ha permitido aumentar la producción de los cultivos en varios órdenes de magnitud ajustándose a un crecimiento continuo de la población, permitiendo además un aumento en la calidad de vida, sobre todo de los países que son grandes productores. Así la producción agrícola se ha incrementado notablemente en los últimos años gracias a la automatización (Edan, Han, & Kondo, 2009). La mecanización e intensificación agrícolas han contribuido en gran medida al desarrollo de sistemas de producción capaces de proporcionar alimentos, piensos, fibras e incluso combustible. Tanto es así, que a principios de este siglo un agricultor en Estados Unidos producía lo suficiente para alimentar a 130 personas, mientras que a principios del siglo XX su producción solo alcanzaba para 2 o, como mucho, 5 personas (Burgos Artizzu, 2009). Esta situación altamente productiva, contrasta con una situación medioambientalmente insostenible provocada por el uso abusivo de importantes y limitados recursos naturales, como el agua y el suelo, unida a la utilización poco eficiente de gran cantidad de agroquímicos (Hertwich, 2010). A modo de ejemplo, se estima que tan solo el 2% de los insecticidas pulverizados y el 5% de los herbicidas alcanzan la plaga objetivo, quedándose los porcentajes restantes en el medio, contaminando aguas y suelos (Miller, 2002).

La delicada situación medioambiental se ve abocada a agravarse debido a la necesidad de duplicar la producción agrícola en los próximos años para satisfacer la demanda de alimento de nueve mil millones de personas en 2050 (Global Harvest Initiative, 2014). En el contexto descrito, se hace imprescindible la utilización de estrategias sostenibles en la gestión agrícola cuyo objetivo sea aumentar la producción de los cultivos con un menor uso de recursos.

Tres son los factores fundamentales que han contribuido a aumentar la productividad agrícola: 1) la mecanización de la maquinaria, 2) la extracción de conocimiento modelando el comportamiento del cultivo y 3) la aplicación del conocimiento con objeto de realizar una gestión

más eficiente de la explotación. Estos factores han permitido reducir los costes de producción y el trabajo manual intensivo, y mejorar la calidad de los productos (Edan, Han, & Kondo, 2009). El siguiente paso es alcanzar una gestión de precisión del cultivo a través de la combinación de nuevos desarrollos en las líneas anteriores con la utilización de la robótica en la realización de las tareas agrícolas. En pocas palabras, el objetivo es satisfacer las futuras necesidades de producción mundial de alimentos con una importante reducción en los recursos necesarios y en el impacto medioambiental (Bergerman, Van Henten, Billingsley, Reid, & Mingcong, 2013), (Reid, 2011), (Srinivasan, 2006), (Stafford, 2000).

La investigación asociada a esta tesis ha tenido su origen y marco de trabajo en los proyectos científicos, tanto de ámbito nacional como europeo, que se citan a continuación:

- *Integración de información multisensorial y aprendizaje automático para la detección, caracterización y reconocimiento preciso de estructuras naturales en campos de cultivo* (3DWeed, 2015-2017). Proyecto del Plan Estatal de I+D+i (AGL2014-52465-C4-3-R) en el que participan el Centro de Automática y Robótica (CSIC-UPM), el Instituto de Ciencias Agrarias (CSIC), el Instituto de Agricultura Sostenible (CSIC) y la Universidad de Lleida. El objetivo principal de este proyecto es proporcionar las herramientas tecnológicas necesarias en el desarrollo de sistemas de Gestión Integrada de Malas hierbas (GIM). El proyecto se estructura en torno a dos escenarios: los sistemas de producción de cereales de secano que prevalecen en el centro de España y los sistemas de viñedo basados en el uso de riego deficitario. Para ambos escenarios se está desarrollando un sistema de inspección compuesto por una plataforma móvil terrestre que integra un sistema multisensorial. La información proporcionada por los sensores de a bordo se utiliza para la caracterización y el reconocimiento de las plantas de cultivo (cereales y vid) y malas hierbas (*B. diandrus*, *P. rhoeas*, *C. dactylon* y *C. arvensis*). Además, la información adquirida se integra en mapas de 2D y 3D de los cultivos a fin de llevar a cabo la inspección preventiva y predictiva de las plantas, que es vital para optimizar el manejo del cultivo. En pocas palabras, el propósito del proyecto es la generación de la tecnología básica sobre la cual construir un sistema de detección temprana (es decir, días antes de la detección por parte de un operario) de los síntomas en las plantas causados por plagas y enfermedades. Esta detección temprana es un paso esencial en la Gestión Integrada de Plagas y posibilita la realización de tratamientos más eficaces, ahorrando en la cantidad de pesticida utilizado.
- *Sistema de inspección terrestre en vehículos autónomos y su aplicación efectiva a la detección de malas hierbas y su control localizado* (GroW). Proyecto del Plan Nacional de I+D+i (AGL2011-30442-C02-02) coordinado durante los años 2011-2014 por el Centro de Automática y Robótica (CSIC-UPM) y en el que participó la Universidad Complutense de Madrid. El objetivo principal de este proyecto era el desarrollo de técnicas eficientes y efectivas de inspección terrestre y discriminación de malas hierbas. Se abordaba la automatización de la recogida de información en campo integrando equipos de inspección en plataformas móviles. Se analizaron distintas estrategias de inspección como la integración de los sensores (fundamentalmente cámaras) en tractores convencionales de forma que se pudiesen tomar imágenes a la vez que se realizaban otras labores en el campo o la inspección totalmente autónoma en la que se disponía de un pequeño robot móvil con una dotación sensorial adecuada, expresamente diseñado para la tarea de inspección.

- *RHEA - Robot fleets for Highly Effective Agriculture and forestry management*. Proyecto europeo (NMP-CP-IP 245986-2) dentro del VII Programa Marco de Investigación y Desarrollo tecnológico (FP7). El proyecto se llevó a cabo durante los años 2010-2014 por un consorcio formado por el Centro de Automática y Robótica del CSIC (coordinador), el Instituto de Ciencias Agrarias del CSIC, la Universidad Politécnica de Madrid, la Universidad Complutense, Case New Holland, AirRobot, Cyberbotics, Bluebotics, GogVis, Agrosap, Forschungszentrum Telekommunikation Wien, el Instituto de Agricultura Sostenible del CSIC, Irstea, la Universidad de Pisa, la Universidad de Florencia, CM Srl y Tropical. La finalidad del proyecto era el diseño, desarrollo y prueba de una nueva generación de sistemas automáticos y robóticos para la eliminación precisa y eficaz de malas hierbas y plagas en entornos agrícolas y forestales mediante medios químicos y físicos (mecánicos y térmicos). El proyecto abordaba un conjunto de escenarios muy variados con objeto de abarcar los principales cultivos europeos ya fueran de calle estrecha (cereales de invierno como el trigo y la cebada), de calle ancha (tomate, maíz, fresa, girasol y algodón) o leñosos perennes (almendros, nogales, olivos, álamos, etc.). Entre los objetivos de RHEA se encontraba la disminución del uso de herbicidas en agricultura en un 75 %, lo que conduciría a mejorar la calidad de los cultivos, la salud y la seguridad de los consumidores, y a la reducción de los costes de producción a partir de una gestión sostenible. RHEA proponía el desarrollo de una flota de pequeños robots, terrestres y aéreos, equipados con sensores avanzados y aperos mejorados y más precisos, así como el desarrollo de algoritmos sofisticados de percepción, toma de decisiones y actuación.
- *RoboCity2030*. Es un consorcio formado por seis centros madrileños líderes en I+D en el área de la robótica con más de 100 investigadores. En concreto está formado por: el Consejo Superior de Investigaciones Científicas (CSIC), la Universidad Politécnica de Madrid (UPM), la Universidad Carlos III de Madrid (UC3M), la Universidad de Alcalá (UAH), la Universidad Nacional de Educación a Distancia (UNED) y la Universidad Rey Juan Carlos (URJC). Financiado por la Comunidad de Madrid y cofinanciado con Fondos Estructurales de la Unión Europea desde el año 2006, el consorcio promueve la investigación y el desarrollo de tecnología en numerosas aplicaciones de servicio centradas en áreas metropolitanas y también en el campo. Las fuertes sinergias creadas por los socios principales y más de 20 socios industriales asociados permiten el desarrollo de docenas de proyectos europeos innovadores y programas de transferencia de tecnología. Diversos resultados de estas actividades de I+D han generado productos de valor añadido, tecnología, software y servicios.

El trabajo desarrollado en estos proyectos ha estado siempre orientado al diseño y desarrollo de tecnología para Agricultura de Precisión. Así se ha investigado en diferentes vehículos de inspección, en su automatización y navegación autónoma en campos de cultivos, además del desarrollo de diferentes técnicas para la reconstrucción del entorno agrícola a partir de la información suministrada por distinto tipo de sensores con el objetivo de facilitar la detección efectiva de plagas y mejorar la gestión y el rendimiento del cultivo.

1.2. Objetivos

El objetivo de este trabajo de investigación es el de contribuir al desarrollo de un vehículo autónomo para la inspección efectiva de cultivos, así como al desarrollo de diferentes métodos para

extraer información a partir de los datos adquiridos por los sensores a bordo del vehículo. Cada uno de estos objetivos tiene sus correspondientes subobjetivos.

1.2.1. Vehículos de inspección

- Puesta a punto, integración de sensores y automatización de distintos tipos de plataformas móviles para la inspección.
- Desarrollo de sistemas teleoperados para poder controlar los vehículos de forma remota.
- Desarrollo de un método robusto para la extracción de líneas de cultivo en tiempo real, invariante a las condiciones de iluminación, en cultivos extensivos con esquema de siembra de calle ancha a partir de la información suministrada por una cámara réflex convencional.
- Desarrollo de un control visual robusto de navegación basado en lógica borrosa para mover un vehículo siguiendo las líneas de cultivo en un cultivo extensivo con esquema de siembra de calle ancha.
- Desarrollo de una conducta de cambio de línea de cultivo.

1.2.2. Reconstrucción del entorno

- Desarrollo de un método para la generación de un mapa 2D de un cultivo extensivo con esquema de siembra de calle ancha a partir de la información suministrada por una cámara réflex convencional y un receptor GPS-RTK a bordo de una plataforma móvil.
- Desarrollo de un método para la reconstrucción 3D de cultivos leñosos a partir de la información suministrada por un sensor RGB-D de bajo coste a bordo de un vehículo de inspección.
- Caracterización del cultivo a partir de la reconstrucción 3D generada. Cálculo de volúmenes, alturas, anchuras de los árboles. Generación de mapas de todos esos parámetros.
- Verificación del funcionamiento de los métodos desarrollados con datos de cultivos reales.

1.3. Aportaciones de la investigación

La investigación llevada a cabo y descrita en esta tesis ha dado lugar a diferentes publicaciones científicas que se reseñan a continuación.

1.3.1. Publicaciones en revistas

Las publicaciones en revistas se han ordenado por importancia.

Publicación 1. Bengochea-Guevara, J. M., Conesa-Muñoz, J., Andújar, D., & Ribeiro, A. (2016). Merge fuzzy visual servoing and GPS-based planning to obtain a proper navigation behavior for a small crop-inspection robot. *Sensors*, 16(3), 276. Revista situada en el primer cuartil (Q1), Factor de Impacto: 2.677 (según los datos del Journal Citation Reports del año 2016).

El artículo describe el desarrollo de un pequeño vehículo autónomo de inspección de cultivos que minimiza el impacto en el campo de la exploración reduciendo la compactación del

suelo. El enfoque propuesto integra una cámara con un receptor GPS-RTK para obtener el conjunto de comportamientos básicos requeridos por un robot móvil autónomo que tiene que recorrer un campo de cultivo con cobertura total. Un planificador de trayectoria obtiene la mejor ruta considerando el contorno de campo, el tipo de cultivo, así como características del vehículo como el radio de giro. El artículo presenta un método de procesamiento de imágenes capaz de extraer/discriminar en tiempo real la línea de cultivo situada en el centro con iluminación natural, es decir sin controlar la iluminación de la escena. El vehículo de inspección integra una cámara réflex colocada en la parte frontal del robot. También se diseñaron y desarrollaron dos controladores borrosos para lograr la navegación guiada por visión. Se desarrolló un método para detectar visualmente el final de una línea de cultivo y poder iniciar la maniobra de giro. Además, se establecieron las maniobras necesarias para que el robot cambiara de línea. De esta forma el robot cubría de forma autónoma todo el cultivo siguiendo un plan previamente establecido y sin pisar la línea de cultivo, lo que es esencial para inspeccionar cultivos como los de maíz sin dañarlos. El contenido de este artículo se desarrolla en el Capítulo 3.

Publicación 2. Conesa-Muñoz, J., Bengochea-Guevara, J. M., Andujar, D., & Ribeiro, A. (2016). Route planning for agricultural tasks: A general approach for fleets of autonomous vehicles in site-specific herbicide applications. *Computers and Electronics in Agriculture*, 127, 204-220. Revista situada en el primer cuartil (Q1), Factor de Impacto: 2.201 (según los datos del Journal Citation Reports del año 2016).

La planificación de rutas en campos agrícolas es un reto importante estrechamente relacionado con la cantidad de insumos consumidos y la compactación del suelo asociada al paso de los vehículos. Tradicionalmente las aproximaciones propuestas se han preocupado principalmente de reducir las distancias recorridas por los vehículos no considerando otros parámetros a optimizar tales como el coste de los insumos (combustible, herbicidas, mano de obra, etc.). El artículo propone una aproximación que optimiza las rutas para una flota de vehículos autónomos considerando diferentes criterios individualmente o simultáneamente, tales como la distancia recorrida, el tiempo requerido para realizar la tarea (inspección, pulverización, etc.), los costes de insumos, distintos vehículos con, por ejemplo, diferentes velocidades de trabajo, tanto intra como entre cultivos, distintos radios de giro, diferentes consumos de combustible, distinta autonomía, etc. También se considera la variabilidad del campo, por ejemplo, la existencia de un mapa de distribución de las infestaciones, y la posibilidad de rellenar el depósito de herbicida durante el tratamiento.

La aproximación propuesta se validó a través de la resolución de varios problemas tipo y se comparó con otras aproximaciones resolviendo las situaciones propuestas por otros autores. Los resultados muestran que el planificador de rutas propuesto cubre una amplia gama de situaciones agrícolas reales y que las rutas óptimas pueden variar considerablemente dependiendo de las características de los vehículos de la flota, la variabilidad del campo y los criterios de optimización seleccionados.

En este artículo se colaboró en la definición del problema y en establecer el conjunto de tests que permitieron validar la propuesta. Asimismo, se participó en el análisis de los resultados obtenidos. La colaboración fue posible gracias a la experiencia obtenida del trabajo en campo con los vehículos descritos en los Capítulos 3 y 4. Este planificador fue utilizado para obtener la ruta del vehículo presentado en el Capítulo 3, y se describe en el apartado 3.4.

Publicación 3. Andújar, D., Dorado, J., Bengochea-Guevara, J. M., Conesa-Muñoz, J., Fernández-Quintanilla, C., & Ribeiro, A. (2017). Influence of Wind Speed on RGB-D Images in Tree Plantations.

Sensors, 17(4), 914. Revista situada en el primer cuartil (Q1), Factor de Impacto: 2.677 (según los datos del Journal Citation Reports del año 2016).

En los últimos años, las cámaras de profundidad se han mostrado como una herramienta prometedora para el fenotipado de plantas. En este artículo se establecen los errores asociados al modelar algunas características de los árboles a diferentes velocidades del viento (de 0 a 10 m/s) a partir de los datos recogidos por un sensor RGB-D de bajo coste (Microsoft Kinect v2). Los experimentos se realizaron utilizando dos especies arbóreas: álamos y ciruelas. Los resultados obtenidos mostraron diferencias dependiendo de la especie del árbol y la velocidad del viento. Las estimaciones del índice de área foliar y del volumen del árbol fueron generalmente más consistentes a altas velocidades del viento en ciruelos. Los álamos se vieron particularmente afectados por velocidades del viento superiores a 5 m/s. Por el contrario, las medidas de altura fueron más consistentes para los álamos que para los ciruelos. En general, se podría establecer una velocidad límite del viento de 5 m/s (18 km/h) para conseguir buenas estimaciones.

En este artículo se colaboró en la recogida de datos en los experimentos y en su posterior procesado. La recogida de datos y la generación de reconstrucciones 3D de los diferentes árboles se realizó a partir de la experiencia obtenida en el trabajo con algoritmos de reconstrucción 3D descrito en el Capítulo 7. Además, se efectuó la estimación del índice de área foliar aplicando la segmentación descrita en 3.4.1.1.1.

1.3.2. Congresos y conferencias

En este apartado, las publicaciones están ordenadas por orden cronológico, lo que permite ver la evolución del trabajo de investigación desarrollado a lo largo de estos años y presentado en la presente memoria de tesis.

Publicación 4. Ribeiro, A., Bengochea-Guevara, J.M., Cantuña, K. & Andújar, D. (2017). 3DWeed: Un robot para la inspección de cultivos. En *Jornadas Nacionales de Robótica 2017* (pp. 1-6).

En este artículo se presenta una visión general del proyecto de investigación: Integración de información multisensorial y aprendizaje automático para la detección, caracterización y reconocimiento preciso de estructuras naturales en campos de cultivo (3DWeed), financiado por el Ministerio de Economía, Industria y Competitividad dentro de su Programa Estatal. El objetivo principal de este proyecto es proporcionar las herramientas tecnológicas necesarias en el desarrollo de sistemas de Gestión Integrada de Malas hierbas (GIM). El proyecto se estructura en torno a dos escenarios: los sistemas de producción de cereales de secano que prevalecen en el centro de España y los sistemas de viñedo basados en el uso de riego deficitario. Para ambos escenarios se está desarrollando un sistema de inspección compuesto por una plataforma móvil terrestre que integra un sistema multisensorial. Se describen los trabajos realizados en los Capítulos 5 y 7.

Publicación 5. Cantuña, K., Andújar, D., Recasens, J., Valencia, F., Bengochea-Guevara, J.M. & Ribeiro, A. (2017). Generación de mapas de malas hierbas en viñedos con cubierta vegetal, utilizando una cámara SLR. En *XVI Congreso de la Sociedad Española de Malherbología* (pp. 1-7). Trabajo aceptado que se presentará en Pamplona el 27 de Octubre de 2017.

Este artículo describe la generación de mapas de malas hierbas combinando las imágenes proporcionadas por una cámara réflex comercial (Canon EOS 7D), en condiciones reales de campo con iluminación no controlada, y la información de ubicación para cada fotografía suministrada por

un receptor GPS-RTK. El proceso genera una ortofoto (almacenada en formato GeoTIFF) de la zona muestreada a partir de un conjunto de fotos solapadas adquiridas automáticamente con la cámara situada en un vehículo eléctrico (Renault Twizy) que se mueve con una velocidad aproximada de 3 km/h. A continuación, los píxeles de la ortofoto se clasifican automáticamente en mala hierba y fondo empleando un algoritmo de segmentación seleccionado entre las 10 estrategias basadas en índices de color más utilizadas. Se participó en la recogida de datos usando el vehículo descrito en el Capítulo 5, y utilizando el programa desarrollado para el Capítulo 6 que asocia a cada imagen captada, la posición GNSS de la cámara en el momento de la captura.

Publicación 6. Ribeiro, A., Bengochea-Guevara, J.M., Conesa-Muñoz, J.M., Nuñez, N., Cantuña, K. & Andújar, D. (2017). 3D monitoring of woody crops using an unmanned ground vehicle. En *Proceedings of Precision agriculture'17* (pp. 1-10). Wageningen Academic Publishers. Trabajo aceptado que se presentará en Edimburgo (UK) el 18 de julio de 2017.

En este artículo se describe un sistema de inspección de cultivos integrado en un vehículo terrestre. En los muestreos realizados en campo, cuyos resultados se recogen en este trabajo, se integraron dos tipos de cámaras en el vehículo: un sensor RGB-D de bajo coste (Microsoft Kinect v2) y una cámara réflex comercial (Canon EOS 7D). La información adquirida por el sensor RGB-D se integró con los algoritmos desarrollados obteniendo una reconstrucción tridimensional de los cultivos muestreados, lo que permitió construir un mapa de distribución del volumen de la copa de los árboles. El vehículo utilizado es el que se describe en el Capítulo 5, y los métodos implementados para la reconstrucción 3D y la generación del mapa de volúmenes son los explicados en el Capítulo 7.

Publicación 7. Bengochea-Guevara, J. M., Andújar, D., Conesa-Muñoz, J., & Ribeiro, A. (2016). A medium size field inspection vehicle. En *MCG2016: 5th International conference on Machine Control & Guidance* (pp. 1-7).

Este trabajo presenta los primeros pasos realizados en la automatización de un vehículo de mediano tamaño para la inspección de cultivos, el vehículo eléctrico Renault Twizy. Se describen los diferentes sensores de los que consta la plataforma: un sensor RGB-D de bajo coste (Microsoft Kinect v2), una cámara réflex comercial y un receptor GPS-RTK. Se muestran los resultados obtenidos en la reconstrucción tridimensional de los cultivos leñosos en los que se realizaron los primeros experimentos y se describen las posibilidades de esta plataforma, tanto en la generación de mapas 2D como 3D. El vehículo usado es el descrito en el Capítulo 5, y los métodos implementados para la reconstrucción 3D son los mostrados en el Capítulo 7.

Publicación 8. Bengochea-Guevara, J. M., Andújar, D., Conesa-Muñoz, J., & Ribeiro, A. (2016). Plataforma de inspección para la obtención de mapas 2D y 3D de un cultivo. En *XXXVII Jornadas de Automatica* (pp. 1-6).

En este artículo se presenta una plataforma móvil terrestre capaz de inspeccionar dos tipos de escenarios: los cultivos anuales (maíz, cereales, etc) y los cultivos plurianuales (árboles frutales, viñedos, etc). Se describe el vehículo utilizado, Renault Twizy, y los diferentes sensores de los que consta la plataforma: un sensor RGB-D de bajo coste (Microsoft Kinect v2), una cámara réflex comercial y un receptor GPS-RTK. Se describen las posibilidades de esta plataforma, sin presentar aún resultados, tanto en la generación de mapas 3D con la información obtenida a través del sensor RGB-D, como en la generación de mapas 2D a partir de la información captada por la cámara réflex. La descripción del vehículo y su equipamiento es parte del Capítulo 5, mientras que las

posibilidades planteadas para la generación de mapas 3D son las descritas en el Capítulo 7.

Publicación 9. Bengochea-Guevara, J. M., Andújar, D., Conesa-Muñoz, J., & Ribeiro, A. (2016). A crops inspection vehicle based on a battery-powered electric car. En *RoboCity16 Open Conference on Future Trends in Robotics* (pp. 325-332). ISBN: 978-84-608-8452-1.

En este artículo se propone la utilización de un vehículo eléctrico comercial de mediano tamaño para la inspección de cultivos, en concreto el modelo Twizy de Renault. Se describen las ventajas de utilizar este tipo de plataformas, entre otras el tamaño, y el motor eléctrico (cero emisiones). El motor eléctrico evita las vibraciones que aparecen en las plataformas con motores de explosión, lo que es una gran ventaja a la hora de capturar información con los sensores de a bordo. Además, este tipo de plataformas puede moverse a velocidades muy bajas (por debajo de los 3 km/h) sin dificultades y tienen una autonomía de 80 km con una carga de 3 horas y media. El artículo también describe algunos de los sensores integrados en la plataforma: un sensor RGB-D de bajo coste (Microsoft Kinect v2), una cámara réflex comercial (Canon EOS 7D) y un receptor GPS-RTK (Hemisphere R220). Se presentan algunos experimentos iniciales que muestran las posibilidades de este tipo de plataforma para obtener información precisa del cultivo. La descripción del vehículo y de su equipamiento es parte del Capítulo 5.

Publicación 10. Ribeiro, A., Andujar, D., Bengochea-Guevara, J.M., Conesa-Muñoz, J. & Cantuña, K. (2016). Vehículo de inspección de cultivos. Reconstrucción 3D y 2D de un cultivo. En *II Jornadas de Viticultura Sech 2016* (pp. 1-5).

Este trabajo presenta de forma resumida el contenido de las publicaciones 7, 8 y 9.

Publicación 11. Andújar, D., Ribeiro, A., Bengochea-Guevara, J.M., San Martín, C., Fernández-Quintanilla, C., Dorado, J. (2015). Reconstrucción 3D de malas hierbas utilizando cámaras de profundidad. En *XV Congreso de la Sociedad Española de Malherbología: La Malherbología y la transferencia tecnológica*, (pp. 201-207) ISBN/ISSN: 978-84-608-2775-7.

En este estudio se optimiza el ángulo de posicionamiento del sensor RGB-D Microsoft Kinect v1 para la reconstrucción tridimensional de algunas malas hierbas de especial relevancia como son *Xanthium strumarium* L., *Datura stramonium* L. y *Chenopodium álbum* L.. Se concluye que la posición ideal del sensor debe ser elegida de acuerdo a la especie a muestrear y su estado fenológico. Los resultados confirman que existe una correlación entre la biomasa de malas hierbas y el área estimada con el sensor, y que se puede realizar una estimación adecuada de la altura de las plantas a partir de su reconstrucción 3D. Se participó en la reconstrucción tridimensional de las plantas mediante el algoritmo presentado en el apartado 7.1.1.

Publicación 12. Conesa-Munoz, J., Bengochea-Guevara, J. M., Andujar, D., & Ribeiro, A. (2015). Efficient Distribution of a Fleet of Heterogeneous Vehicles in Agriculture: A Practical Approach to Multi-path Planning. En *Autonomous Robot Systems and Competitions (ICARSC), 2015 IEEE International Conference on* (págs. 56-61). ISBN: 978-1-4673-6990-9.

En este artículo se propone un planificador agrícola muy general de rutas para vehículo que considera flotas de vehículos heterogéneas, variabilidad en el cultivo, operaciones de reabastecimiento y diferentes criterios de optimización: distancia, tiempo, consumo o combinaciones de todos ellos, cubriendo, en definitiva, una gran cantidad de situaciones agrícolas reales. Se participó en la definición del problema y en la discusión de los resultados a partir de la

experiencia desarrollada en el trabajo de campo con los vehículos descritos en los Capítulos 3 y 4. Este planificador fue utilizado como planificador de la ruta del vehículo presentado en el Capítulo 3 y se describe en el apartado 3.4.

Publicación 13. Bengochea-Guevara, J. M., Conesa-Muñoz, J., & Ribeiro, A. (2014). Generating Autonomous Behaviour for a Crop Inspection Robot. En *ROBOT2013: First Iberian Robotics Conference*. Advances in Intelligent Systems and Computing, 252 (pp. 481-493). Springer International Publishing. ISBN: 978-3-319-03412-6.

En este trabajo se presentó una arquitectura de generación de comportamientos que da lugar a la generación de las principales conductas que debe tener un vehículo de inspección para navegar autónomamente por el campo. Se mostró la solución desarrollada para conseguir que un vehículo siga una línea de cultivo, conducta fundamental para la inspección del campo. El método de procesamiento de imagen implementado permitía determinar la posición y orientación del vehículo respecto a la línea de cultivo en tiempo real, y mediante dos controladores borrosos, uno para la velocidad de traslación y otro para la angular, se conseguía que el vehículo siguiese la línea de cultivo sin pisarla. El vehículo que se utilizó en este trabajo es el descrito en el Capítulo 3 y la conducta de seguimiento de la línea de cultivo es la versión previa a la presentada en el apartado 3.4.1.

Publicación 14. Bengochea-Guevara, J.M., Burgos-Artizzu, X., & Ribeiro, A. (2014). "Real-time image processing for crop/weed discrimination in maize fields". En *Proceedings of RHEA-2014: 2nd International Conference on Robotics and associated high-technologies and equipment for agriculture and forestry* (pp. 477-488). ISBN: 978-84-697-0248-2.

En este trabajo se presentó un método de procesamiento de imagen que permitía discriminar entre líneas de cultivo y malas hierbas en cultivos con un esquema de siembra de calle ancha, como los cultivos de maíz. Las imágenes eran captadas por una cámara réflex comercial montada en un tractor, y el procedimiento permitía la discriminación en tiempo real bajo condiciones de luz no controlada y a pesar de los movimientos de la cámara. Este método es una primera versión y la base del descrito en el apartado 3.4.1.1.2 para detectar la línea de cultivo.

Publicación 15. Bengochea Guevara, J.M. & Ribeiro, A. (2013). Generación de comportamiento autónomo para un robot de inspección de cultivos. En *XII Workshop Robótica Cognitiva (Robocity 2030)*. Cap. 9. (pp. 125-136). ISBN: 978-84-695-8175-9.

En este trabajo se presentaron de forma teórica las principales conductas que debe tener un vehículo de inspección de cultivos para navegar autónomamente por el campo. Estas conductas fueron tenidas en cuenta para las conductas desarrolladas en el apartado 3.4.

Publicación 16. Conesa-Muñoz, J., Bengochea-Guevara, J. M., & Ribeiro, A. (2013). Path planning to minimise distances and recharging instances for a small fleet of vehicles in an arable field. En *Proceedings of Precision agriculture'13* (pp. 373-380). Wageningen Academic Publishers. ISBN: 978-90-8686-224-5.

En este trabajo se estudió cómo afecta en la planificación agrícola de rutas para que los vehículos cubran un campo, la distribución de pequeñas estaciones de recarga en las cabeceras de un cultivo, necesarias para abastecer pequeñas plataformas móviles con autonomía limitada. El trabajo se centró en determinar, en función del campo, el número óptimo de robots que debería

tener la flota y el número de estaciones necesarias, así como su ubicación, para dar servicio adecuadamente al conjunto de robots. Se participó en la definición del problema y en la discusión de los resultados a partir de la experiencia desarrollada en el trabajo de campo con el vehículo descrito en el Capítulo 3.

Publicación 17. Bengochea-Guevara, J. M., Conesa-Muñoz, J., & Ribeiro, A. (2012). Developing a small autonomous robot for crop inspection. En *Information Technology, Automation and Precision Farming. International Conference of Agricultural Engineering-CIGR-AgEng 2012: Agriculture and Engineering for a Healthier Life* (pp. C-2171).

En este trabajo se presentó el desarrollo y la evaluación de un pequeño vehículo autónomo de inspección de cultivos cuyo objetivo era navegar por el campo guiado por dos líneas de cultivo mediante la información suministrada por una webcam de alta gama situada en la parte frontal del robot y la utilización de un controlador borroso para corregir la orientación del vehículo. El vehículo utilizado es el descrito en el Capítulo 3 y los algoritmos de visión y controladores descritos son una versión preliminar de los explicados en el apartado 3.4.

1.3.3. Actividades de diseminación

A continuación, se presentan distintas actividades de diseminación realizadas durante la elaboración de esta tesis:

- Participación en el programa educativo *4ºESO+Empresa* de la Comunidad de Madrid celebrado durante el curso 2015-16 (5 horas) y 2016-17 (4 horas).
- Participación en la *Semana de la Ciencia de Madrid* organizado por la Fundación madri+d en el año 2016 (3 horas).
- Participación en la *Noche Europea de los Investigadores de Madrid* organizado por la Fundación madri+d en el año 2015 (3 horas).
- Participación en la organización y exposición del stand del Centro de Automática y Robótica (CSIC-UPM) en la feria internacional *Global Robot Expo: International Exhibition of Robotics* en los años 2016 (10 horas) y 2017 (25 horas).
- Participación en la organización y exposición del stand del Centro de Automática y Robótica (CSIC-UPM) en la feria internacional abierta al público *Robocity16: Robots for Citizens* en el año 2016 (12 horas).
- Miembro del comité organizador de congreso internacional "*Second International Conference on Robotics and associated High-technologies and Equipment for Agriculture and forestry*" en el año 2014 (27 horas).

1.4. Estructura de la tesis

Esta memoria se divide en 8 capítulos.

Capítulo 1 (Introducción): Este capítulo describe, de forma general, el problema a investigar, así como la motivación, los objetivos y las aportaciones de la presente investigación.

Capítulo 2 (Estado del Arte): Este capítulo revisa la situación actual de la agricultura y de los diferentes avances realizados hasta el momento para desarrollar vehículos autónomos de inspección de cultivos y para reconstruir el entorno en ambientes agrícolas.

Capítulo 3 (Robot móvil comercial de pequeña envergadura): En este capítulo se presenta el primer vehículo de inspección con el que se trabajó. Se describe el robot elegido y el resto de elementos que conforman la plataforma de inspección. Se muestra la implementación realizada para teleoperar el robot, así como las diferentes conductas desarrolladas imprescindibles para que la plataforma navegase de manera autónoma por el campo. Estas conductas fueron probadas en un campo real de maíz con el objetivo de verificar el funcionamiento del robot.

Capítulo 4 (Cuatrimoto con motor de explosión): En este capítulo se presenta la automatización de una cuatrimoto con motor de explosión, vehículo disponible en la mayoría de explotaciones agrícolas. Se muestra el vehículo elegido y los diferentes elementos necesarios para conseguir su automatización. Este desarrollo sirve como base para teleoperar la cuatrimoto, y para poder implementar conductas autónomas en el futuro. Se realizaron diferentes experimentos teleoperando la cuatrimoto para comprobar el correcto funcionamiento de la automatización realizada.

Capítulo 5 (Vehículo eléctrico): En este capítulo se presenta la automatización y puesta a punto como vehículo de inspección de cultivos de un vehículo eléctrico comercial. Las características de este vehículo frente a los vehículos de motor de explosión, como la cuatrimoto, lo hacen más adecuado como plataforma de inspección de cultivos. Permite el desplazamiento a velocidades muy bajas, adecuadas para el muestreo; no produce vibraciones, lo que favorece la captura de datos por los sensores. La automatización realizada sirve como base para teleoperar el vehículo, y para poder implementar conductas autónomas en el futuro. Al final del capítulo, se muestran los resultados de los diferentes experimentos.

Capítulo 6 (Reconstrucción 2D del entorno): En este capítulo se presenta un procedimiento para generar un mapa de la cubierta vegetal de un campo de cultivo (línea de cultivo y malas hierbas) en campos con un esquema de siembra en líneas separadas, como el maíz, a partir de la información suministrada por una cámara réflex comercial y un receptor GPS-RTK a bordo de un vehículo de inspección. El procedimiento corrige los movimientos no deseados de la cámara, provocados por el desplazamiento del vehículo de inspección en el campo, más acusados en vehículos pequeños, donde el desplazamiento en el campo es menos uniforme debido al terreno. Para validar el método se experimenta en un campo de maíz real con el robot móvil, el vehículo más pequeño de los utilizados.

Capítulo 7 (Reconstrucción 3D del entorno): En este capítulo se presenta el método desarrollado para realizar la reconstrucción 3D de cultivos leñosos en grandes extensiones corrigiendo los problemas de deriva. Asimismo, se presentan los métodos para la estimación de distintos parámetros de interés del cultivo a partir de la reconstrucción generada, como son la altura, la anchura y el volumen. Estas estimaciones se presentan en mapas que permiten conocer la situación del cultivo por zonas, lo que es esencial para la gestión efectiva del cultivo. Para validar los procedimientos propuestos, se realizaron experimentos en distintos campos de viñedos reales en diferentes épocas del año.

Capítulo 8 (Conclusiones y trabajo futuro): En este capítulo se resumen las principales aportaciones de este trabajo, y se estudian las líneas de investigación futura.

2. ESTADO DEL ARTE

2.1. Agricultura de Precisión

Tradicionalmente, las prácticas agrícolas se han orientado hacia una gestión uniforme del cultivo, ignorando la variabilidad espacial y temporal del mismo. Este enfoque tiene dos principales consecuencias negativas: a) la contaminación del aire y del suelo, con la consiguiente contaminación de las aguas subterráneas (Liu & O'connell, 2002), (Spliid & Køppen, 1998) al aplicar tratamientos en lugares donde no es necesario, y b) el aumento de los costes de producción (Gebbers & Adamchuk, 2010).

A finales de los 90, gracias al desarrollo de distintas tecnologías como los Sistemas de Posicionamiento Global por satélite (GPS), sensores de cosecha, sensores de humedad o de fertilidad del suelo, sensores multiespectrales, sistemas de teledetección, los Sistemas de Información Geográfica (SIG o GIS) y los Sistemas de Apoyo a la Toma de Decisiones (DSS, del inglés *Decision Support System*), surgió el concepto de Agricultura de Precisión (AP), que propone la adaptación de la gestión de los cultivos a la variabilidad de éstos. Dentro de la AP tienen especial importancia las técnicas orientadas a la aplicación selectiva de tratamientos, que engloban un conjunto de técnicas de cultivo dirigidas a ajustar el uso de agroquímicos considerando la diversidad tanto del medio físico como biológico (Kropff, Wallinga, & Lotz, 2007). En contraposición a los métodos agrícolas tradicionales, los métodos de precisión proponen ajustar las dosis de tratamientos a las necesidades de cada unidad de terreno, restringiendo su uso a áreas de cultivo infestadas e incluso variando la cantidad de tratamiento aplicado según la densidad de la infestación. Estudios experimentales realizados sobre cultivos de cereal en Alemania (Gerhards, 2007), España (Ruiz, Escribano, & Fernández-Quintanilla, 2006) y la República Checa (Hamouz, 2007) muestran ahorros por encima del 70%, el 74% e incluso el 82% respectivamente, mostrando que con un tratamiento de precisión es posible reducir substancialmente las dosis recomendadas de

muchos productos sin que con ello se reduzcan significativamente ni su eficacia ni los rendimientos en la cosecha, traduciéndose en una reducción de los costes de producción y una gestión agrícola más respetuosa con el medioambiente (Earl, Wheeler, Blackmore, & Godwin, 1996). Aunque a priori este tipo de tratamiento selectivo puede no parecer rentable por el alto precio de la maquinaria necesaria (vehículos adaptados, sensores, aperos más sofisticados, etc.), en EEUU se ha demostrado experimentalmente que sus beneficios netos pueden compensar los costes asociados (Rider, Vogel, Dille, Dhuyvetter, & Kastens, 2006).

La aplicación selectiva de tratamientos requiere estimar la cantidad de tratamiento necesario para cada unidad de cultivo (Senay, Ward, Lyon, Fausey, & Nokes, 1998). En primer lugar, es necesario recoger información en el campo para determinar la ubicación y la densidad estimada de la plaga, etapa que podemos denominar de percepción. Utilizando esta información y el conocimiento que se tiene sobre el comportamiento de la plaga y el cultivo, se selecciona la acción óptima a realizar sobre el cultivo, etapa que se puede considerar como de toma de decisiones. Finalmente, se realiza la aplicación selectiva y precisa de tratamiento siguiendo el protocolo establecido en la etapa anterior; esta última etapa sería la de actuación.

Para hacerse una idea de la dimensión que tiene el problema del tratamiento de las plagas agrícolas conviene proporcionar algunas cifras. La tierra para uso agrícola representa el uso principal del suelo en la Unión Europea (UE) con el 40% de la superficie total terrestre (Eurostat, 2016). En 2012, más del 60% de la superficie agrícola de la Unión Europea se utilizó para cultivos anuales (cereal, maíz, etc.), mientras que el 6% se usó para cultivos plurianuales (olivos, viñas, frutales, etc.). Las plagas reducen significativamente la producción agrícola, siendo responsables de aproximadamente el 40% de reducción global sobre el rendimiento potencial de los cultivos (Oerke, Dehne, Schönbeck, & Weber, 2012) mediante la transmisión de enfermedades (patógenos), alimentándose de los cultivos (invertebrados) o compitiendo con las plantas de cultivo, como en el caso de las malas hierbas. Para hacerse una idea, se estima que la cantidad de cultivo que consumen los insectos sería suficiente para alimentar a más de mil millones de personas (Birch, Begg, & Squire, 2011). Este escenario puede empeorar con el establecimiento de plagas exóticas favorecido por el cambio climático. Así, el clima cada vez más cálido y húmedo del Norte de Europa favorece el desarrollo de enfermedades, mientras que las condiciones más secas y cálidas en el Sur originarán plagas de insectos. A modo de ejemplo, la literatura indica que cada 10 meses una nueva plaga agrícola penetra en el Sur de Europa moviéndose hacia el Norte al cambiar las condiciones (Reddy, 2015). Hoy en día la mayoría de los agricultores y productores en la UE dependen de los pesticidas químicos de amplio espectro. Solo en Europa se gastaron en 2013 alrededor de 360.000 toneladas de fitosanitarios para acabar con las plagas (Eurostat, 2013). No obstante, sus efectos negativos conducen a problemas difíciles de resolver como la aparición de plagas secundarias y de resistencia, además de la contaminación del medio ambiente, lo que ha llevado a la UE a aprobar una legislación que prohíbe un número importante de productos plaguicidas químicos sintéticos (Reglamento CE nº 1107/2009 y Directiva 2009/128/CE del Parlamento Europeo y del Consejo). Este nuevo escenario impulsa acciones encaminadas a lograr un uso sostenible de los pesticidas que reduzca el impacto en la salud humana y el medioambiente, promoviendo el concepto de Gestión Integrada de Plagas (GIP), en el que una etapa fundamental es la monitorización o inspección continua de los cultivos.

A nivel del suelo, la recopilación de datos se puede realizar a pie o utilizando plataformas móviles. Una observación a pie continua de un cultivo es costosa en tiempo y requiere desplazar un gran número de operarios cualificados cuando se trata de cubrir grandes áreas de tratamiento. En campos pequeños los operarios pueden realizar eficazmente esta tarea, pero en grandes extensiones esta opción es inviable. La forma de proceder en estos casos es realizar únicamente observaciones en puntos concretos del campo. Habitualmente los datos se recogen de puntos predefinidos a lo largo

de un área utilizando rejillas de muestreo, y se interpola para estimar las densidades de las áreas intermedias (Rew & Cousens, 2001).

Los datos recogidos de forma continua permiten una descripción cualitativa de la abundancia de la infestación (es decir, presencia o ausencia; cero, baja, media o alta) en lugar de los recuentos cuantitativos de plantas que se generan normalmente mediante el muestreo discreto (Marshall, 1988). Así, el desarrollo de tecnologías que permitan la inspección autónoma y continua de campos de cultivo es una cuestión todavía inmadura de gran interés. Entre los diversos medios de recolección de información bien estructurada con un precio razonable, los vehículos equipados con sensores de a bordo se consideran una de las tecnologías más prometedoras a medio plazo. Sin embargo, el uso de robots móviles autónomos en entornos agrícolas sigue siendo objeto de estudio ya que la navegación en este tipo de ambientes presenta dificultades debido a la variabilidad y naturaleza del terreno y la vegetación, así como a las condiciones ambientales (Slaughter, Giles, & Downey, 2008), (Li, Imou, Wakabayashi, & Yokoyama, 2009).

2.2. Vehículos de inspección

El diseño de robots móviles que trabajen en el exterior, como el entorno agrícola, sigue siendo un desafío. La navegación en entornos agrícolas presenta dificultades debido a los cambios en las condiciones atmosféricas y a las variaciones en la naturaleza del terreno y en la vegetación. La autonomía de un vehículo se consigue mediante la detección del entorno y el empleo de algoritmos de control apropiados para la tarea especificada. Los entornos agrícolas están formados por plantas, árboles, tierra, etc. Su diversidad complica la navegación de un vehículo que tiene que desplazarse por grandes superficies de varias hectáreas de terreno irregular. Además, condiciones adversas como el polvo, la niebla o las variaciones en la iluminación natural, pueden afectar a la calidad de los datos adquiridos por los sensores embarcados en los vehículos. Es más, el color de la planta puede cambiar durante las diferentes etapas de su crecimiento y la calidad del suelo puede variar de un lugar a otro. Frente a estas características que complican el desarrollo de sistemas de inspección efectivos existen otras que ayudan en la sistematización de los procedimientos, como son que la mayoría de los cultivos, ya sean herbáceos o leñosos, se plantan en línea recta manteniendo aproximadamente una distancia fija entre plantas en la línea y la misma distancia, o ancho de calle, entre líneas. Además, los puntos de referencia que ya existen en el campo (como, por ejemplo, postes) pueden utilizarse como puntos de referencia estacionarios para los algoritmos de localización y navegación. Para conseguir una estrategia de navegación autónoma que cubra totalmente un cultivo, trabajos recientes han demostrado que, planificando previamente las trayectorias a seguir, se pueden obtener tratamientos óptimos en términos de aplicación de fitosanitarios, consumo de combustible, distancia recorrida o incluso tiempo de trabajo (Conesa-Muñoz, Bengochea-Guevara, Andujar, & Ribeiro, 2016), (Conesa-Muñoz, Pajares, & Ribeiro, 2016).

La investigación en sistemas de navegación para aplicaciones agrícolas se ha centrado en métodos de guiado que emplean información global o local. Los sistemas de guiado que utilizan información global intentan dirigir el vehículo a lo largo de una ruta previamente definida basándose en un mapa del terreno y en la posición del vehículo respecto a una referencia absoluta. En este caso, se suelen emplear sistemas globales de navegación por satélite (GNSS), como el GPS. Los sistemas de guiado que utilizan información local para intentar dirigir un vehículo se basan en la detección de referencias locales, tales como patrones de siembra y el espacio entre líneas de cultivos.

La precisión de las posiciones absolutas que se derivan de un GNSS puede mejorarse mediante el empleo de la tecnología RTK (del inglés Real Time Kinematic), sistema GPS diferencial

que emplea una única estación de referencia para proporcionar correcciones en tiempo real y precisión alrededor del centímetro basándose en mediciones de la fase de la onda portadora de la señal. El uso de un receptor GPS-RTK como único sensor de posicionamiento para el guiado de vehículos agrícolas se ha examinado en varios estudios (Stoll & Kutzbach, 2000), (Blackmore, Griepentrog, Nielsen, Nørremark, & Resting-Jeppesen, 2004). Es más, varios autores evalúan el uso de receptores GPS de bajo coste para el guiado de vehículos agrícolas (Rovira-Más, Chatterjee, & Sáiz-Rubio, 2015), (Gomez-Gil, Alonso-Garcia, Gómez-Gil, & Stombaugh, 2011), (Alonso-Garcia, Gomez-Gil, & Arribas, 2011).

Grandes compañías como John Deere o Case New Holland ya incorporan esta tecnología en sus vehículos (John Deere, 2017), (Case New Holland, 2017), de modo que estos pueden moverse autónomamente dentro del cultivo aunque los cambios de dirección en cabecera siguen siendo manuales.

Independientemente del tipo de GNSS utilizado, esta tecnología de navegación tiene algunas limitaciones cuando el GNSS con una única antena sirve como único sensor de posición para la navegación autónoma. Por esta razón, el RTK-GNSS se combina frecuentemente con otros sensores, como las Unidades de Medida Inercias (IMU, del inglés *Inertial Measurement Unit*) (Eaton, Katupitiya, Siew, & Howarth, 2010), (Michio Kise, Noguchi, Ishii, & Terao, 2002) o Giróscopos de Fibra Óptica (FOG, del inglés *Fibre Optic Gyroscope*) (Nagasaka, Umeda, Kanetai, Taniwaki, & Sasaki, 2004), (Noguchi, Kise, Ishii, & Terao, 2002), (Bak & Jakobsen, 2004), o mediante el uso de dos antenas GNSS (Emmi, Gonzalez-de-Soto, Pajares, & Gonzalez-de-Santos, 2014), que permiten conocer, entre otras cosas, la orientación del vehículo en movimiento con mayor precisión o cuándo éste está parado. Es importante tener en cuenta que cuando un GNSS, incluso un RTK-GNSS, se emplea como único sensor para navegar a través de un cultivo sin pisar las plantas, un comportamiento esencial en cultivos como el maíz, o colisionar con los árboles, en el caso de cultivos leñosos, resulta indispensable conocer perfectamente la disposición de las líneas de cultivo. Para ello los cultivos deben ser sembrados con un sistema guiado por RTK-GNSS o mapeados usando técnicas de mapeo georeferenciado. Este enfoque es costoso y puede no ser factible, lo que reduce el alcance de los sistemas de navegación que se basan en GNSS.

Los sistemas de visión son cada vez más comunes en aplicaciones agrícolas tales como localización (Burgos-Artizzu, Ribeiro, Tellaache, Pajares, & Fernández-Quintanilla, 2010), construcción de mapas (Sainz-Costa, Ribeiro, Burgos-Artizzu, Guijarro, & Pajares, 2011), navegación autónoma (Bengochea-Guevara, Conesa-Muñoz, Andújar, & Ribeiro, 2016), seguimiento de rutas (García-Santillán, Montalvo, Guerrero, & Pajares, 2017), inspección (Burgos-Artizzu, Ribeiro, Guijarro, & Pajares, 2011), monitoreo (Tellaache, Burgos-Artizzu, Pajares, & Ribeiro, 2008) y evitación de obstáculos (Ross et al., 2014) debido a su rentabilidad y capacidad para proporcionar grandes cantidades de información. Al tratarse de escenarios al aire libre, uno de los factores más importantes a tener en cuenta es la influencia de las condiciones de iluminación ambiental sobre los sensores de visión. En los últimos años se está investigando el uso de estos sistemas para el guiado autónomo, utilizando, la mayoría de ellos, las líneas de cultivo como guía. El proceso de detección de líneas de cultivo va acompañado de algunas dificultades, como la aparición de discontinuidades en la línea producidas por errores en la siembra, las formas y tamaños irregulares de las plantas a lo largo de la línea y la presencia de malas hierbas, que pueden distorsionar el proceso de detección de la línea. Se han propuesto diferentes estrategias para detectar las líneas de cultivo cuando se usa una cámara RGB como sensor de visión para el guiado. En (Gottschalk, Burgos-Artizzu, Ribeiro, & Pajares, 2010) y (Sainz-Costa et al., 2011) se aplica una etapa de segmentación a una imagen en color RGB para obtener, primero, una imagen en escala de grises, y, tras umbralizarla, una imagen binaria en la que los píxeles blancos corresponden con la cubierta vegetal que aparece en la imagen. A continuación, la imagen binaria se divide en franjas horizontales para abordar la perspectiva de la

cámara. Para cada franja, revisan todas las columnas de píxeles. Las columnas con más píxeles blancos que negros se etiquetan como posibles líneas de cultivo, y todos los píxeles de la columna se ponen en blanco; en caso contrario, se ponen a negro. Para determinar los puntos que definen las líneas de cultivo, se selecciona el centro geométrico del bloque con el mayor número de columnas blancas consecutivas en cada franja. Entonces, el método estima la línea definida por estos puntos, basándose en los valores medios de sus coordenadas. Otros enfoques (Søgaard & Olsen, 2003) transforman una imagen en color RGB a una imagen en escala de grises utilizando un índice que pondera más la componente verde (Woebbecke, Meyer, Von Bargaen, & Mortensen, 1995) y la dividen en franjas horizontales, donde los valores máximos de gris indican la presencia de una posible línea de cultivo. Cada máximo define un segmento de la línea, y los centros de gravedad de los segmentos se unen mediante un método similar al utilizado en la transformada de Hough (Hough, 1962) o aplicando una regresión lineal. En (Hague, Tillett, & Wheeler, 2006), la imagen RGB original se transforma en una imagen en escala de grises utilizando un índice que pondera más la componente verde (Marchant & Onyango, 2000) y se divide en franjas horizontales. Construyen un filtro paso banda basado en el hallazgo de que la intensidad de los píxeles a través de estas franjas presenta una variación periódica debido a que las líneas de cultivo son paralelas. A veces, la detección de las líneas es difícil ya que el cultivo y las malas hierbas están unidos en una misma área.

La transformada de Hough se ha empleado para el guiado de vehículos agrícolas (Åstrand & Baerveldt, 2005), (Rovira-Más, Zhang, Reid, & Will, 2005), (Marchant, 1996), (Hague, Marchant, & Tillett, 1997), (Leemans & Destain, 2006). Dependiendo de la densidad del cultivo, la transformada de Hough puede detectar muchas líneas, por lo que posteriormente se fusionan las líneas con parámetros similares (Tellaache, BurgosArtizzu, Pajares, Ribeiro, & Fernández-Quintanilla, 2008), (Tellaache, Burgos-Artizzu, et al., 2008), (Tellaache, Pajares, Burgos-Artizzu, & Ribeiro, 2011). Cuando se presentan malas hierbas y están distribuidas irregularmente, pueden causar fallos en la detección de las líneas. En (Vioix, Douzals, Truchetet, Assémat, & Guillemín, 2002), (Bossu, Gée, Guillemín, & Truchetet, 2006), (Bossu, Gée, Jones, & Truchetet, 2009), se utiliza la transformada de Fourier para extraer las líneas de cultivo, ya que la imagen muestra algunos componentes en el dominio de la frecuencia; sin embargo, esto no sucede para todos los tipos de cultivos. En (Romeo et al., 2012), los autores analizan imágenes capturadas en perspectiva por un sistema de visión instalado a bordo de un vehículo y consideran que la cámara fue sometida a vibraciones y movimientos no deseados producidos como resultado del movimiento del vehículo en terreno irregular. En (Bezdek, Ehrlich, & Full, 1984) se propone un proceso de agrupación difusa (*fuzzy clustering*) para obtener un umbral con el que separar los píxeles correspondientes a cubierta vegetal (cultivo y malas hierbas) de los que corresponden a los elementos restantes del campo (suelo y piedras). De forma similar a otros enfoques (Sainz-Costa et al., 2011), para detectar la línea de cultivo se aplica un método que se basa en la proyección en perspectiva de la imagen, que busca la máxima acumulación de píxeles verdes segmentados a lo largo de alineaciones rectas.

También se ha estudiado la navegación autónoma basada en visión estereoscópica. Para ello, se puede usar la diferencia de altura entre las líneas de cultivo y las calles entre ellas, surcos, marcadores artificiales, etc. En (Kise, Zhang, & Rovira Más, 2005) se presenta un sistema de visión estereoscópica que utiliza la estructura 3D de la línea de cultivo para el guiado. Los autores constatan la alta carga computacional del método y la aparición de píxeles en blanco en algunas localizaciones, en particular las más alejadas, que se resuelven reduciendo la resolución y filtrando, respectivamente. En (Rovira-Más, Han, Wei, & Reid, 2007) se utilizan las líneas de cultivo de un campo de maíz como referencia para el guiado autónomo. Los problemas aparecen en la generación de puntos 3D cuando las hojas largas de maíz bloquean la cámara y cuando las condiciones de luz cambian, concluyendo que posición de la cámara es esencial para el buen funcionamiento de la

aproximación propuesta. Además, también refieren dificultades relacionadas con el procesamiento computacional, que resuelven reduciendo la cantidad de puntos generados. En (Hanawa, Yamashita, Matsuo, & Hamada, 2012) se usan surcos para el guiado autónomo de un tractor. Los autores señalan la aparición de problemas cuando la luz del sol es muy fuerte y, en consecuencia, la sombra proyectada por el tractor afecta a la generación de imágenes de profundidad. En (Blas & Blanke, 2011) se presenta un sistema de guiado autónomo que utilizaba la huella dejada por un tractor como la referencia principal. El sistema de imágenes 3D muestra problemas cuando la huella seguida presenta regiones planas en las que no existen diferencias en altura. En (Wang, Zhang, Rovira-Más, & Tian, 2011) se presenta el guiado de un vehículo en un campo de rastrojos con visión estereoscópica, calculando el desplazamiento lateral del vehículo. Los resultados son buenos en trayectorias rectas, no así en trayectorias curvas. Existen también algunos sistemas comerciales de guiado en agricultura basados en visión estereoscópica. CLAAS comercializa una cámara de visión estereoscópica denominada CAM PILOT (CLAAS, 2013) que permite seguir líneas de cultivos. Naio Technologies ha desarrollado y comercializa el robot Oz (Naio Technologies, 2016), para eliminar malas hierbas que utiliza visión estereoscópica para la navegación autónoma entre las líneas de cultivo. Inicialmente, se basaron en un LIDAR (del inglés *Laser Imaging Detection and Ranging*) para la navegación dentro de las líneas de cultivo, pero luego cambiaron a un sistema de visión estereoscópica, con el que obtienen un posicionamiento más preciso y detectan plantas más pequeñas.

La navegación con sensores láser también ha sido fuente de numerosas investigaciones debido a su alta resolución y gran campo de visión. El sensor láser es uno de los dispositivos más utilizados en aplicaciones al aire libre. Determina la distancia relativa de los objetos en el área circundante al dispositivo midiendo el tiempo de vuelo de los pulsos láser. Una ventaja importante de estos sensores frente a los sistemas visuales es la capacidad de proporcionar datos robustos de distancia para la detección y localización de objetos. Esto permite que el robot funcione de forma más fiable con diferentes condiciones atmosféricas y de iluminación ambiental. En (Satow, Matsuda, Ming, Hironaka, & Tan, 2004) se utiliza un láser para detectar la altura y posición de las líneas de cultivo, que sirve como sistema de guiado de un tractor. (Weiss & Biber, 2011) utilizan un LIDAR para la detección y segmentación de plantas y suelo con el propósito de que pueda ser utilizado para la navegación y el mapeo. En el trabajo desarrollado en (Ahamed et al., 2011) se usan las medidas proporcionadas por un láser para la navegación autónoma utilizando marcas artificiales, y para monitorizar el crecimiento del cultivo.

También se han investigado el uso de los láseres para la detección de filas de árboles en cultivos leñosos. Así los datos del láser se pueden usar para detectar las diferentes partes de un árbol: tronco y copa. En (Hansen et al., 2011) y (Libby & Kantor, 2011) se utiliza el láser para detectar la copa de las filas de árboles. Además en (Libby & Kantor, 2011) se utilizan cintas reflectantes para detectar los extremos de las filas, lo que reduce el tiempo de procesamiento y mejora la detección de las filas. En (Hamner, Singh, Bergerman, & others, 2010) se presenta un método para detectar el tronco y la copa de los árboles y con ello reconocer filas de árboles. Se utiliza la transformada de Hough para extraer puntos y líneas características con el fin de que un vehículo agrícola pueda navegar entre las filas.

En otros trabajos se utiliza el láser para determinar la distancia del dispositivo a los árboles y la dirección de éstos, lo que permite conocer los errores laterales y de rumbo entre el vehículo y las filas de árboles (Christiansen, Jensen, Ellekilde, & Jørgensen, 2011), (Libby & Kantor, 2011), (Hamner et al., 2010), (Andersen, Ravn, & Andersen, 2010), (Barawid, Mizushima, Ishii, & Noguchi, 2007), (Tsubota, Noguchi, Noboru & Mizushima, 2004).

Los láseres también se han combinado con cámaras digitales para conseguir un guiado más robusto (Subramanian et al., 2009), además de con un encoder para proporcionar retroalimentación

sobre el ángulo de dirección. En estos casos, el sistema de guiado orienta al tractor en trayectorias rectas y curvas. Igualmente se ha utilizado una combinación de láser y cámara para desarrollar un sistema basado en SLAM (del inglés *Simultaneous Localization And Mapping*) (Cheein, Steiner, Paina, & Carelli, 2011), (Debain et al., 2010).

En cuanto al tipo de vehículo, la mayoría de los estudios de guiado autónomo de vehículos agrícolas se han centrado en tractores o vehículos pesados. Dentro de la Agricultura de Precisión, el uso de vehículos pequeños o medianos para inspeccionar un cultivo completo es una opción adecuada frente a máquinas grandes ya que se minimiza la compactación del suelo. La inspección basada en vehículos autónomos pequeños o medianos puede ser muy útil para la detección temprana de plagas mediante la recopilación de información georreferenciada, necesaria para construir mapas de riesgo precisos. Además, debido a que tienen un impacto mínimo sobre los cultivos y sobre el suelo, se puede realizar más de un muestreo a lo largo del año, lo que ayuda a un mayor seguimiento del estado del cultivo a lo largo de la campaña, favoreciendo que el tratamiento sobre el campo sea más efectivo y económicamente más rentable.

2.3. Reconstrucción del entorno

Los avances en los sistemas de percepción en agricultura (Mulla, 2013) están permitiendo una reconstrucción del entorno agrícola cada vez más cercana a la realidad. La posibilidad de captar y reconstruir con mayor precisión los diferentes elementos presentes en los cultivos permite conocer con mayor exactitud el estado del cultivo, posibilitando una gestión eficaz del mismo que considere su variabilidad. Lo que, finalmente, favorece la implantación de un esquema de Agricultura de Precisión.

Entre los distintos mapas que se pueden obtener de un cultivo tiene especial interés, de cara al tratamiento, el mapa de distribución de malas hierbas que refleja la posición y densidad de los rodales de infestación. El mapa de distribución de malas hierbas resulta una valiosa herramienta para optimizar la utilización de recursos en el control eficaz de las infestaciones. Tradicionalmente la generación de mapas de distribución de malas hierbas se ha realizado manualmente, mediante muestreo discreto por parte de operarios especializados desplazados en el campo. Automatizar este proceso permite un muestreo continuo y la construcción de mapas con una descripción mucho más detallada y precisa de las infestaciones. En los últimos años se han publicado distintos estudios en los que se han utilizado plataformas terrestres equipadas con cámaras RGB y receptores GPS para construir mapas del cultivo (Bak & Jakobsen, 2004), (Downey, Giles, & Slaughter, 2004a), (Downey, Giles, & Slaughter, 2004b). También se han utilizado robots aéreos (UAV, del inglés *Unmanned Aerial Vehicle*) (Barrientos et al., 2011), (Peña, Torres-Sánchez, de Castro, Kelly, & López-Granados, 2013), (Pérez-Ortiz et al., 2015), con los que capturar las fotos georreferenciadas a partir de las cuales se construyen los mapas. Para lograr mapas correctamente georreferenciados, se sitúan marcas en el suelo de tamaño suficiente como para ser detectables en las fotos y se toman las coordenadas GPS con precisión de esas marcas. Los mapas así generados tienen, además de información sobre malas hierbas, información sobre el cultivo que puede utilizarse para realizar evaluaciones exhaustivas del mismo. Respecto a los mapas de distribución de infestaciones, éstos son útiles a la hora de construir mapas específicos de aplicación que puedan ser la base del funcionamiento de aperos inteligentes, como por ejemplo barras de pulverización preparadas para la aplicación localizada de agroquímicos (Weisz, Fleischer, & Smilowitz, 1996), abonos (Dobermann et al., 2002) o herbicidas (Gerhards, Sökefeld, Schulze-Lohne, Mortensen, & Kühbauch, 1997), (Conesa-Muñoz, Gonzalez-de-Soto, Gonzalez-de-Santos, & Ribeiro, 2015), (Gonzalez-de-Santos et al., 2016), (Pérez-Ruiz et al., 2015).

Durante años los sistemas de visión en dos dimensiones (2D) han sido los sistemas de visión más utilizados en la automatización agrícola buscando la inspección de los cultivos sin daño para los mismos (evaluación no destructiva). Sin embargo, en la actualidad, la visión por computador está en un punto de inflexión, moviéndose hacia un enfoque tridimensional (3D), impulsado por la mejora de la tecnología y los precios más bajos de los dispositivos en el mercado (Eddershaw, 2014). En la última década, el número de investigaciones relacionadas con los sistemas de visión 3D aplicados a la agricultura ha crecido rápidamente. Algunas de las razones que contribuyen a esta tendencia incluyen el continuo aumento de la potencia de procesamiento de los ordenadores, la disminución del coste y el tamaño de la electrónica.

Un deseo común de todos los agricultores es conocer el rendimiento de sus cultivos. La predicción precisa del rendimiento ayuda a los productores a mejorar la calidad del cultivo y reducir los costes operacionales al tomar mejores decisiones sobre la gestión del cultivo. Habitualmente, la estimación del rendimiento se realiza sobre la base del conocimiento que se tiene del cultivo, datos históricos, las condiciones meteorológicas y los muestreos manuales realizados por los operarios. Como se ha explicado anteriormente, el muestreo manual es un proceso que consume mucho tiempo, requiere mucha mano de obra y es inexacto, ya que el número de muestras suele ser demasiado pequeño para captar la magnitud de variación del rendimiento en cada bloque del cultivo. Así, es de suma importancia encontrar una alternativa automatizada y eficiente que pueda capturar con precisión la variación espacial y temporal de un cultivo. Con la información obtenida de una reconstrucción 3D del cultivo se pueden estimar parámetros importantes como el estado de crecimiento, la altura, la forma, la biomasa, la necesidad de nutrientes, el estado de salud, etc. Si los datos se georreferencian, se pueden construir mapas y llegar a aplicar, en caso de ser necesario, un tratamiento individualizado por planta.

Existen diferentes sistemas de visión 3D que se han aplicado con éxito en agricultura (Vázquez-Arellano, Griepentrog, Reiser, & Paraforos, 2016). En (Li, Zhang, & Huang, 2014) se revisa el estado del arte de distintas técnicas de visión 3D en el fenotipado de plantas, en concreto en obtención de los rasgos físicos de la planta. Los autores concluyen que el refinamiento y desarrollo de estas técnicas acelerarán el proceso de fenotipado. La mayoría de plataformas para el fenotipado se basan en visión 3D (Busemeyer et al., 2013), (Polder, Lensink, & Veldhuisen, 2013), (Alenyà Ribas, Dellen, Foix Salmerón, & Torras, 2012), (Ladybird, 2014). Cuando trabajan fuera de invernaderos, en exteriores, suelen utilizar elementos para proporcionar sombra y mantener constantes las condiciones de luz. En (Rosell & Sanz, 2012) se revisan varios métodos de caracterización geométrica de cultivos leñosos y en (Wulder et al., 2012) de árboles forestales. (Moreda, Ortiz-Cañavate, García-Ramos, & Ruiz-Altisent, 2009) por su parte revisa distintas técnicas de visión para determinar el tamaño de la fruta y su clasificación. En estas revisiones los autores concluyen que las técnicas 2D serán progresivamente sustituidas por técnicas 3D, y ven el escaneo 3D multiespectral (combinación de datos multiespectrales con reconstrucción de superficies 3D) como una técnica muy prometedora. (Bac, van Henten, Hemming, & Edan, 2014) revisan el uso de la tecnología 3D en robots cosechadores para cultivos de alto valor (manzanas, tomates, etc.), donde ya existen versiones comerciales para la recolección de fresas (Agrobot, 2014), pero la relación precio/rendimiento todavía tiene que mejorar para que este tipo de equipos se implanten en explotaciones reales.

Estimar el rendimiento de un cultivo previamente a la cosecha es esencial para ajustar la gestión del cultivo, aunque una estimación precisa requiere adquirir un gran número de información de campo. Se trata, por tanto, de una actividad laboriosa, intensiva y que requiere una gran cantidad de tiempo, a la vez que se ajusta bien a la automatización. En (Herrero-Huerta, González-Aguilera, Rodríguez-Gonzálvez, & Hernández-López, 2015) se propone un proceso automático para la estimación del rendimiento de un viñedo a partir de imágenes adquiridas con

una cámara réflex. Los racimos de uvas más cercanos se reconstruyen mediante técnicas de Estructura a partir del Movimiento (SfM, del inglés *Structure from Motion*), indicando que sus principales limitaciones son la dependencia del tiempo atmosférico y la necesidad de utilizar luz artificial. En (Moonrinta, Chaivivatrakul, Dailey, & Ekpanyapong, 2010) también se propone un método para plantaciones de piñas y se considera la SfM una técnica prometedora, pero se reconoce que se necesita más trabajo para incrementar la precisión de la reconstrucción. En (Wang, Nuske, Bergerman, & Singh, 2013) se propone el uso de un sistema de visión estereoscópico autónomo para estimar la producción de un cultivo de manzanos, que funciona por la noche y con iluminación controlada. El sistema presenta problemas debidos a las oclusiones, los reflejos y la heterogeneidad del color. Asimismo, aparece un sesgo en la localización de las manzanas, que requiere la colocación de marcas artificiales cada 3 árboles para recalibrar el sistema de visión.

En (Billiot, Cointault, Journaux, Simon, & Gouton, 2013) se presenta un sistema basado en visión estéreo para medir el espacio entre plantas en cultivos de maíz en una fase temprana. En los experimentos llevados a cabo, el sistema era capaz de detectar alrededor del 96% de las plantas, aunque la precisión disminuye cuando se trata de detectar el centro (62% y 74%), con un tiempo de procesamiento entre 5 y 20 s. En (Zhao, Sun, Cai, Liu, & Lammers, 2012) se utiliza un sensor láser de distancia para obtener la forma 3D de hojas de calabacines (*Cucurbita pepo*) con el fin de detectar el estrés hídrico de la planta, perfilando sus trazas morfológicas (marchitamiento). Los autores consideran que se ha realizado muy poca investigación usando técnicas 3D a pesar de que potencialmente proporciona información más fiable acerca del marchitamiento en respuesta al estrés hídrico. En (Piron, Heijden, & Destain, 2011) se propone el uso de un sensor 3D basado en luz estructurada para distinguir entre cultivo y mala hierba en una etapa temprana basándose en la altura. La aproximación propuesta presenta muchos problemas debido, fundamentalmente, a las grandes variaciones en el rango dinámico de la escena, el alcance del sensor, los reflejos, la delgadez de las plantas y las oclusiones. Por último, en (Lino & Fabbro, 2004) también se utiliza un sensor 3D basado en luz estructurada para la reconstrucción 3D de peras.

En (Šeatović, Kutterer, Anken, & Holpp, 2009) usan un sensor 3D basado en triangulación para la detección en tiempo real de malas hierbas de hoja ancha (*Rumex obtusifolius*). La tasa de detección es alta, pero decrece cuando aparecen tréboles u otras plantas de hoja ancha. Determinan que una estrategia 3D ofrece una segmentación y una clasificación de las hojas mucho más robusta comparada con la obtenida mediante una estrategia 2D. En (Wolff, 2012) desarrollan un sistema para el fenotipado de plantas que consiste en dos cámaras embarcadas en una plataforma. Era capaz de escanear alrededor de 2200 plantas por día de trabajo, pero requiere de dos operarios para mover la plataforma. En (Jiang, Zhu, Cheng, Luo, & Tao, 2009) se compara un sistema tradicional de detección 2D con un sistema de visión 3D para clasificar la calidad de las manzanas. El resultado es una disminución de un 30% en la tasa de error con la estrategia 3D.

En (Garrido et al., 2015) realizan reconstrucciones 3D de plantas de maíz solapando nubes de puntos procedentes de un LIDAR embarcado en un robot. En (Weiss & Biber, 2011) usan un LIDAR con baja resolución (29x59 píxeles) para evaluar diferentes clasificadores de plantas en interiores, logrando una precisión en la clasificación del 99% con uno de los clasificadores entrenados (regresión logística simple) usando plantas de 6 especies diferentes. Realizaron el mismo proceso en exteriores bajando la tasa hasta el 60%. En (Saeys, Lenaerts, Craessaerts, & De Baerdemaeker, 2009) se evalúan dos tipos de LIDARs, de onda continua y de pulso modulado, embarcados en una cosechadora para estimar la densidad del trigo y el volumen del cultivo. Estimaron satisfactoriamente la densidad del cultivo en experimentos realizados con distintas densidades, velocidades y vibraciones. Los impactos del LIDAR fueron usados para hacer una reconstrucción 3D del campo en postprocesado, obteniendo mejores resultados usando el LIDAR de onda continua, ya que su velocidad de escaneo es mayor. En (Nakarmi & Tang, 2012) se presenta un

sistema para medir el espacio entre plantas usando una cámara basada en la tecnología de tiempo-de-vuelo (TOF, del inglés *Time-Of-Flight*) protegida de la luz directa del sol y del viento. Los autores hablan de la superioridad de las cámaras TOF comparadas con las cámaras estereoscópicas convencionales. En (Adhikari & Karkee, 2011) se desarrolla un sistema de imagen 3D para la poda automática con el fin de identificar las ramas no deseadas y localizar los puntos de poda en un cultivo de manzanos. El 90% de los puntos de poda fueron localizados correctamente usando una cámara TOF. En (Gongal, Amatya, & Karkee, 2014) se presenta la fusión de una cámara 2D con una cámara TOF para estimar el rendimiento de las manzanas en un cultivo de frutales. En los experimentos realizados el 88% de las manzanas se detectó, enfatizando el significativo incremento en la visibilidad cuando se capturaban imágenes por ambos lados de los árboles que cuando se capturan por un solo lado. El mayor desafío es la visibilidad limitada de las manzanas, ya que algunas estaban completamente ocultas por las hojas y las ramas. En (Vazquez Arellamo, Reiser, Garrido Izard, & Griepentrog, 2016) se hace hincapié en la flexibilidad y posibilidades de una cámara TOF en aplicaciones agrícolas para diferentes entornos agrícolas y condiciones, siendo capaces de reconstruir y georreferenciar plantas de maíz en un invernadero y en entornos a campo abierto bajo diferentes condiciones de luz. Deepfield Robotics también utiliza una cámara TOF para el fenotipado de plantas en su robot de campo Bonirob (Deepfield Robotics, 2016), pero para adquirir imágenes estables, utilizan una cámara compacta encapsulada junto con una fuente de luz artificial y un dispositivo para darle sombra.

Actualmente, el sensor RGB-D Kinect v2 de Microsoft, basado en tecnología TOF, es un dispositivo muy interesante entre los sistemas de visión 3D gracias a su bajo coste y a su buen rendimiento. El sensor Kinect v2 se ha utilizado para la caracterización de plantas en agricultura. En (Paulus, Behmann, Mahlein, Plümer, & Kuhlmann, 2014) comparan dos sistemas 3D de bajo coste, entre los que estaba el sensor Kinect v2, con un escáner láser de alta precisión caro y concluyeron que los sistemas de bajo coste podían reemplazar al escáner en varios escenarios de fenotipado de plantas. En (Chéné et al., 2012) se presenta un algoritmo para segmentar imágenes de profundidad de plantas obtenidas por la primera versión del sensor Kinect en un plano cenital. Se muestra el potencial de este sensor para la estimación del volumen, la curvatura y la morfología de la hoja, o su uso para la detección de patógenos. En (Andújar, Dorado, Fernández-Quintanilla, & Ribeiro, 2016) se propone el uso del sensor Kinect v2 para determinar el volumen de las malas hierbas en cultivos de maíz y definir su época de tratamiento. Los resultados sugieren que este sensor puede ser un dispositivo de alta precisión para estimar el volumen de las malas hierbas y determinar el estado del cultivo. En (Wang & Li, 2014) se usa un sensor Kinect v2 para estimar el volumen de cebollas, mostrando que el volumen calculado estaba directamente relacionado con el estimado con las medidas procedentes del sensor.

3. ROBOT MÓVIL COMERCIAL DE PEQUEÑA ENVERGADURA

Para conseguir una plataforma autónoma de inspección de cultivos es necesario desarrollar una serie de conductas que permitan al vehículo desenvolverse autónomamente por el campo. Estas conductas básicas se desarrollaron y probaron en un robot móvil comercial con el fin de verificar su correcto funcionamiento antes de implementarlas en otros vehículos.

En este capítulo se presenta el robot elegido y sus características, además del resto de elementos que conforman la plataforma de inspección. Se muestra el sistema implementado para teleoperar el robot, así como las diferentes conductas desarrolladas para conseguir el comportamiento autónomo del robot en el campo. Por último, se discuten los resultados de los experimentos realizados con esta plataforma.

3.1. Descripción del robot

El robot utilizado es un modelo comercial, en concreto el robot mBase-MR7 fabricado por MoviRobotics (Figura 3.1). Tiene cuatro ruedas con locomoción diferencial, sin volante y puede rotar sobre su eje vertical. En la Tabla 3.1, suministrada por el fabricante, se muestran algunas de las características más relevantes del robot.

Figura 3.1. Robot mBase-MR7 de Movirobotics

Tabla 3.1. Características del robot mBase-MR7

Medidas	60 cm (longitud) x 55 cm (anchura) x 45 cm (altura)
Ruedas laterales	Diámetro: 30 cm
Velocidad máxima de traslación	30 cm/s
Velocidad máxima de rotación	90 grados/s
Motores	Cuatro motores 12V / 12Nm max / Reductora 81:1
Resolución encoders	500 CPR
Alimentación	Dos baterías de Ni-MH 12V@32Ah
Peso	28 Kg (plataforma + baterías)
Capacidad de carga	40 Kg
Sensores	5 infrarrojos
	Encoders

3.1.1. Arquitectura interna

Los módulos en los que se divide la arquitectura interna de la plataforma son, según la información del fabricante, los que se indican en la Figura 3.2.

Figura 3.2 Arquitectura interna del robot mBase-MR7

En la configuración utilizada, se tiene una tarjeta PC104 que actúa como núcleo central del sistema, en la que se ejecutan todos los procesos de alto nivel del sistema. Esta tarjeta se comunica con la tarjeta de control IOM, que sirve como interfaz para los sensores infrarrojos (IR), así como para controlar los motores enviando consignas a las tarjetas controladoras (MCU). En los siguientes apartados se detallan los diferentes módulos.

3.1.1.1. Placa base

La tarjeta PC104 incluida inicialmente en el robot, la PM-LX-800-R11 de IEI Technology Corp, fue sustituida por la tarjeta LV-7FX-i7-4GB de Commell (procesador Intel® Core™ i7, 4GB DDR3 de memoria RAM) porque ofrece un mejor rendimiento para los procesos que se ejecutan en el sistema. Además, se conectó un disco duro de estado sólido (SSD) de 64 GB a la nueva tarjeta con el fin de hacer el sistema más robusto a las vibraciones producidas durante el movimiento por las irregularidades del terreno. En el disco duro se instaló el sistema operativo Lubuntu (Lubuntu, 2017), sobre el que se ejecutan los procesos necesarios para llevar a cabo el proyecto. Lubuntu es una distribución oficial de Ubuntu (Ubuntu, 2017), sistema operativo basado en GNU/Linux, indicado para equipos donde se quiere potenciar el rendimiento a costa de simplificar el entorno gráfico. Además, se conectó un adaptador de red inalámbrica a la tarjeta, situando su antena en el exterior, en el panel trasero del robot. El adaptador permite crear una red inalámbrica cuando se enciende el robot con la que acceder remotamente a los sistemas del mismo. La teleoperación del robot se realiza con un dispositivo conectado a esta red, como se explicará en el apartado 3.3. La Figura 3.3 muestra el esquema de conexiones de la tarjeta LV-7FX-i7-4GB.

Figura 3.3. Conexiones de la tarjeta LV-7FX-i7-4GB

3.1.1.2. Tarjeta de control IOM

La tarjeta de control de bajo nivel de la plataforma (IOM) es el módulo de control de los drivers de motor (MCU). También los sensores infrarrojos van conectados a esta tarjeta, tal como se

muestra en la Figura 3.4.

Figura 3.4. Conexiones de la tarjeta IOM

3.1.1.3. MCU

MCU es la tarjeta de control encargada de la comunicación con los dos motores de la plataforma. El módulo integra controladores proporcionales-integrales-derivativos (PID) independientes por rueda y configurables por el usuario fijando un conjunto de parámetros. La plataforma incluye dos tarjetas en el modelo de cuatro ruedas utilizado (Figura 3.5). En la Figura 3.6 se detallan las conexiones de cada tarjeta MCU.

Figura 3.5. Conexión de los motores a las tarjetas MCU

Figura 3.6. Conexiones de cada tarjeta MCU

3.1.1.4. Sensores infrarrojos

La plataforma dispone de tres sensores infrarrojos analógicos y dos digitales utilizados para la detección de obstáculos próximos al robot. Los infrarrojos analógicos (Figura 3.7) están colocados a la misma altura en la cara frontal del robot a modo de parachoques. Las lecturas devueltas por estos sensores son en voltios, de modo que entre 0 y 1,83 V se considera que no hay nada delante del sensor. La distancia máxima de detección es de 25 cm.

Figura 3.7. Sensores infrarrojos frontales

En la parte trasera del robot se encuentra un infrarrojo digital, a modo de parachoques trasero. El otro infrarrojo digital se encuentra en la parte inferior del robot. En estos casos la distancia máxima de detección es de 40 cm.

3.1.2. Mejoras sobre la plataforma inicial

Sobre la plataforma original se realizaron una serie de modificaciones en el cableado y la alimentación del sistema para mejorar la fiabilidad y aislamiento del mismo. El esquema de alimentación empleado se muestra en la Figura 3.8.

Figura 3.8. Esquema de alimentación de la plataforma

Además, se añadieron varios interruptores en el exterior a los ya existentes para la conexión y desconexión de los diferentes componentes principales del sistema (placa base, tarjeta IOM) y facilitar el trabajo con la plataforma. También se incrementaron los conectores exteriores al chasis: conector para antena WiFi, conector VGA, conector Ethernet y 3 conectores USB. Los nuevos conectores permiten conectar monitor, teclado, ratón, cable Ethernet, etc., para poder trabajar con el robot sin necesidad de acceder al interior del mismo. En la Figura 3.9 se muestra la distribución de conectores e interruptores en el panel superior del robot.

Figura 3.9. Distribución de conectores e interruptores en el panel superior del robot

3.1.3. Protocolo de comunicación

En este apartado se detalla el protocolo de mensajes que utiliza la placa de control IOM.

3.1.3.1. Protocolo general de paquete

Todos los paquetes recibidos y enviados por el robot tienen la estructura mostrada en la

Figura 3.10.

SYNC0	SYNC1	contador	comando	[datos]	checksum
-------	-------	----------	---------	---------	----------

Figura 3.10. Estructura de paquete del protocolo de comunicación del robot

Los bytes SYNC0, SYNC1 sirven como cabecera de los paquetes y son utilizados por el robot para sincronizar la comunicación.

El valor de contador refleja el total del número de bytes de los elementos del paquete que vienen a continuación sin contar el valor de la suma de verificación (*checksum*).

El byte de comando indica bien el comando que se quiere ejecutar, en caso de ser paquetes enviados al robot, o bien a qué información corresponden los bytes de datos, en caso de ser paquetes enviados por el robot.

Los bytes de datos contienen el valor de la acción que se quiere ejecutar, en caso de ser paquetes enviados al robot, o el valor de la medida devuelta por el robot, cuando el mensaje lo envía el robot.

En el caso de los mensajes recibidos por el robot, el primer byte de los datos siempre es la cadena de caracteres ARG o NARG. Se utiliza ARG cuando el dato a enviar es positivo o cuando se manda más de un dato dentro del mismo mensaje, y NARG cuando se envía un dato negativo.

El valor del *checksum* corresponde al byte de menor peso de la suma de todos los bytes del mensaje, desde el contador hasta el último byte de datos.

3.1.3.2. Mensajes más importantes recibidos por el robot

En la Tabla 3.2 se muestran algunas de las órdenes más significativas que puede recibir el robot.

Tabla 3.2. Mensajes más importantes recibidos por el robot

Nombre	CMD	ARG	Nº bytes datos	Descripción
open_controller	0x01	-	0	Reiniciar odometría y apagar motores
close_controller	0x02	-	0	Apagar motores
enable_motors	0x04	ARG	2	Habilitar/deshabilitar motores
reset_origo	0x07	-	0	Reiniciar odometría al origen (0, 0, 0)
trans_vel	0x0B	ARG/NARG	3	Establecer velocidad de traslación (mm/s)
rot_vel	0x15	ARG/NARG	3	Establecer velocidad de rotación (°/s)
stop	0x1D	-	0	Parar traslación y rotación
set_analog	0x47	ARG	2	Habilitar/deshabilitar envío de paquetes de información de sensores
set_trans_acel	0x5A	ARG	3	Establecer velocidad de aceleración (mm/s ²)
set_odometria	0x5F	ARG	7	Establece el valor de la odometría actual

3.1.3.3. Mensajes más importantes enviados por el robot

La Tabla 3.3 muestra algunos de los mensajes que envía el robot para informar de su estado.

Tabla 3.3. Mensajes más importantes enviados por el robot

Nombre	CMD	Nº bytes datos	Descripción
motor	0x80	4	Odometría X (mm)
		4	Odometría Y (mm)
		2	Odometría θ (0-360°)
		2	Velocidad del lado izquierdo de la plataforma (mm/s)
		2	Velocidad del lado derecho de la plataforma (mm/s)
		2	Voltaje de la batería
ain	0x9A	2	Infrarrojo analógico frontal izquierdo
		2	Infrarrojo analógico frontal centro
		2	Infrarrojo analógico frontal derecho
		1	Infrarrojo digital trasero
		1	Infrarrojo digital inferior

A partir de los valores recibidos de la velocidad del lado izquierdo y derecho de la plataforma se pueden obtener las velocidades de traslación y rotación aplicando (3.1) y (3.2) respectivamente.

$$V_{tras} = \frac{V_{izq} + V_{dcha}}{2} \quad (3.1)$$

$$V_{rot} = \frac{V_{izq} - V_{dcha}}{\text{Distancia entre ejes del robot}} \quad (3.2)$$

3.2. Arquitectura del sistema

Para convertir el robot en una plataforma de inspección de cultivos se le añaden distintos elementos. En la Figura 3.11 se ilustra la arquitectura del sistema desarrollado con todos sus componentes.

En los siguientes apartados se describen los diferentes elementos que componen la arquitectura del sistema desarrollado y su función dentro del sistema.

Figura 3.11. Arquitectura del sistema desarrollado

3.2.1. Ordenador de a bordo

Sobre el robot se colocó un ordenador, que a partir de ahora llamaremos ordenador de a bordo, en concreto un ordenador portátil modelo Toughbook CF-19 de la marca Panasonic, equipado con un procesador Intel Core i5-2520@2.5GHz y 2 GB de memoria RAM. Este modelo está diseñado para trabajar en entornos exteriores exigentes, a prueba de polvo, vibraciones, con una pantalla visible a la luz del día, etc.

El propósito de este ordenador es procesar toda la información procedente de la cámara y el receptor RTK-GPS y, en función de ésta, decidir la manera de actuar mandándole los comandos necesarios al robot.

El ordenador dispone de conexión a Internet mediante un módem USB que permite el acceso a una red de telefonía móvil 4G.

3.2.2. Cámara réflex

A bordo del vehículo se colocó una cámara réflex digital de objetivo único, el modelo EOS 7D de la marca Canon.

La cámara se conecta al ordenador de a bordo mediante una conexión USB, proporcionando aproximadamente cinco imágenes RGB por segundo con una resolución de 1056×704 píxeles. La cámara se sitúa en un mástil a 80 cm de altura con un ángulo de cabeceo (*pitch*) de 18° (Figura 3.12). Se estudiaron otras localizaciones para la cámara, tales como colocarla boca abajo, enfocando directamente al suelo; en ese caso solo se cubriría una pequeña porción de terreno y, en consecuencia, la detección continua (*tracking*) de la línea de cultivo era más vulnerable a cambios locales como errores de siembra, áreas de malas hierbas, etc. Además, el terreno cubierto era el área más próxima al frente del robot, así que cuando el robot necesitaba reaccionar a lo que se presentaba en la imagen, parte de ella había quedado atrás. Otra opción analizada fue situarla delante del robot, en una posición avanzada con un mástil de acero. Sin embargo, esto ocasionaba más vibraciones en la

cámara durante el desplazamiento del robot, deteriorando significativamente el funcionamiento del sistema.

Figura 3.12. Localización de la cámara junto con todos los elementos del sistema y ejemplo de imagen captada por la cámara

3.2.3. Receptor GPS-RTK

El equipamiento del vehículo se completa con un receptor GPS con corrección RTK modelo R220 de la marca Hemisphere. Es capaz de proporcionar la posición con una precisión de $1,5 \text{ cm} + 1 \text{ ppm}$ (partes por millón) en el plano horizontal y de $3 \text{ cm} + 1 \text{ ppm}$ (partes por millón) en el plano vertical a una frecuencia máxima de 20 Hz.

La tecnología RTK es una técnica de posicionamiento basada en una estación de referencia (receptor GNSS) situada en una posición conocida. Esta estación mide la fase de la onda portadora de la señal recibida de los satélites y la retransmite en tiempo real a otros receptores GNSS. Éstos comparan sus propias medidas de fase con las de la estación de referencia, lo que les permite calcular sus posiciones relativas respecto a la estación de referencia con precisión centimétrica. Al mismo tiempo obtienen sus posiciones absolutas conocida la posición absoluta de la estación de referencia. Para distribuir a través de Internet el flujo de datos GNSS con las mediciones de fase proporcionadas por la estación de referencia, se usa el protocolo NTRIP (Networked Transport of RTCM vía Internet Protocol). El ordenador de a bordo del robot recibe estas correcciones gracias a su conexión a Internet y se las suministra al receptor RTK mediante una conexión USB para lograr la precisión requerida. Las correcciones provienen de una estación situada en el Centro de Automática y Robótica (La Poveda, Arganda del Rey) cuando los experimentos se realizan cerca de esta localización, y en caso de no ser así, las correcciones se reciben de una de las estaciones permanentes de la red que tiene el Instituto Geográfico Nacional por toda España (IGN, 2017).

El protocolo NMEA (NMEA, 2017) es un protocolo estándar que utilizan la mayoría de receptores GPS. Así el receptor envía en una cadena de caracteres (trama) la información de la ubicación geográfica de la antena junto con otros datos de interés. Existen distintos tipos de tramas,

en el caso del presente trabajo el receptor se ha configurado para suministrar tramas \$GPGGA al ordenador de a bordo a través de una conexión USB.

3.3. Teleoperación

En este apartado se describen los pasos necesarios para conseguir teleoperar remotamente el robot desde un ordenador portátil o tableta (ver Figura 3.12). También se detalla la interfaz de usuario (GUI del inglés *Graphical User Interface*) desarrollada.

Como se describió en el apartado 3.1.1.1, el robot crea una red WiFi a la que se conecta la tableta del usuario sobre la que se ejecuta la GUI. Mediante la interfaz desarrollada el operario puede teleoperar el robot enviando órdenes y recibiendo información del estado del robot a partir de la comunicación con una aplicación desarrollada que se ejecuta en la tarjeta PC104 del robot.

3.3.1. Interfaz GUI

El desarrollo de la interfaz gráfica GUI se basa en las librerías Qt (Qt, 2017).

En la Figura 3.13 y Figura 3.14 se pueden ver algunas vistas de la interfaz diseñada. La parte derecha del panel tiene dos pestañas: *Controls* y *More Info*. En la Figura 3.13 se muestra la ventana activa cuando se selecciona la pestaña *Controls*. Ésta es también la ventana que aparece por defecto al ejecutar la aplicación. En la Figura 3.14 se aprecia la ventana activa cuando está seleccionada la pestaña *More Info*.

Figura 3.13. Interfaz vista por el operador (Opción *Controls*)

Figura 3.14. Interfaz vista por el operario (Opción *More Info*)

En la parte izquierda de las ventanas aparece una zona en la que se muestran los mensajes (órdenes) enviados al robot con la finalidad de facilitar el proceso de depuración.

3.3.1.1. Opción *Controls*

En este apartado se explican cada uno de los componentes de la opción *Controls* de la interfaz (Figura 3.13). El botón *Connect* sirve para conectar la aplicación, utilizando la red WiFi creada por el robot, a la aplicación servidor lanzada en el mismo. Con el botón *Disconnect* se desconecta la interfaz del servidor del robot.

El botón de *STOP* es un botón de emergencia para detener instantáneamente la marcha del robot. Es imprescindible cuando surge algún imprevisto que puede provocar un accidente dañando la estructura del robot o de algún elemento de su entorno.

En la parte del panel destinada a las aceleraciones, se muestran las aceleraciones de traslación (mm/s^2) y rotación ($^\circ/\text{s}^2$) con las que está configurado el robot. Pueden visualizarse tanto en formato numérico como en forma de barra de progreso. La aceleración de traslación puede incrementarse o decrementarse con los botones *Up* y *Down* respectivamente. Por defecto el robot tiene una aceleración de traslación de 200 mm/s^2 . Asimismo, en el modelo de robot utilizado, la aceleración de rotación es de $100 \text{ }^\circ/\text{s}^2$ y no puede variarse, por lo que aparecen deshabilitadas las teclas a tal efecto.

En la parte del panel dedicada a las velocidades, se pueden ver las velocidades de traslación (mm/s) y rotación ($^\circ/\text{s}$) con las que está actuando el robot. Pueden visualizarse tanto en formato numérico, como por medio de unos diales que cambian de color en función de la proximidad a los límites máximos de funcionamiento, así como en un eje de coordenadas donde podremos ver reflejada la dirección que sigue el robot y la magnitud de los valores de las velocidades de traslación y rotación utilizadas. La velocidad de traslación puede variarse, incrementándose o decrementándose, mediante los botones *Up* y *Down*, respectivamente. Valores positivos significan que el robot se moverá hacia delante, mientras que los negativos indican al robot que se mueva

hacia atrás. En consecuencia, el valor por defecto al arrancar la interfaz es cero para que el robot no se desplace. De igual forma, los botones derecha e izquierda, sirven para incrementar y decrementar la velocidad de rotación, respectivamente; donde valores negativos hacen que el robot gire a la izquierda, y positivos que gire a la derecha. El valor por defecto al arrancar la interfaz es cero para que el robot no gire.

Por último, la barra deslizante *Automatic Braking* permite al robot efectuar un frenado gradual hasta quedar completamente parado cuando esta opción está activada. El tiempo de ejecución del proceso de frenado hasta la parada total lo establece la longitud de la parte seleccionada en la barra deslizante.

3.3.1.2. Opción *More Info*

En esta ventana se muestra la información enviada por el robot (Figura 3.14). En la parte superior aparecen, de forma numérica, los datos enviados por el robot relativos a las velocidades de su lado izquierdo, de su lado derecho, su velocidad de traslación (todas ellas expresadas en mm/s) y su velocidad de rotación (en °/s).

En la parte central se muestran los valores numéricos devueltos por la odometría del robot. Reflejan los mm que se ha desplazado el robot en el plano XY desde la posición inicial, además de los grados que se ha desviado de su orientación inicial. Estos datos proceden de las medidas realizadas por los encoders que posee el robot en sus ruedas. Estos valores son estimaciones de la posición relativa del robot respecto a su localización inicial que van acumulando errores a medida que el robot se mueve.

Aproximadamente en la parte central de la ventana aparecen cinco leds que reflejan el estado de los cinco sensores infrarrojos del robot. Como se ha explicado en apartados anteriores, el robot dispone de tres sensores infrarrojos en su parte frontal (parte izquierda, centro y derecha), uno en la parte trasera y otro en la parte inferior trasera. Cada uno de los leds representa un sensor infrarrojo, así los tres de arriba corresponden a los frontales, el del medio al trasero inferior, y el de abajo al trasero. Cuando algún infrarrojo detecta algún obstáculo delante, el led correspondiente en la ventana se ilumina en rojo.

Finalmente, en la parte inferior de la ventana se refleja, con un display numérico, el valor en voltios del voltaje de salida de la batería del robot. Además, aparece el porcentaje de batería que le queda al robot, representado mediante una barra de progreso. De esta forma se puede saber cuándo la batería del robot está a punto de agotarse y proceder a su sustitución.

3.4. Comportamiento Autónomo/Navegación autónoma

En este apartado se describen las diferentes conductas desarrolladas para conseguir que el robot pueda inspeccionar un campo de cultivo de forma autónoma.

Para inspeccionar una línea de cultivo en un cultivo con un esquema de siembra de calle ancha (como el maíz), el robot debe posicionarse al principio de la línea, es decir, en el punto aproximado establecido por el plan generado con la trayectoria que debe seguir, con la línea entre sus dos ruedas delanteras. A continuación, el robot debe avanzar, siguiendo la línea de cultivo usando su cámara de a bordo, hasta que llega al final de la línea. Una vez que ha inspeccionado una línea, el robot debe ejecutar las maniobras necesarias para posicionarse en la cabecera de la siguiente línea a inspeccionar dictaminada por el plan que sigue. El proceso se repite hasta que todas las líneas del campo han sido inspeccionadas o cuando el plan ha sido completamente ejecutado. En definitiva, para lograr la inspección con cobertura total del campo, se requiere de un conjunto de

conductas individuales: (1) seguimiento de una línea de cultivo, (2) detección del final de una línea de cultivo y (3) transición a la cabecera de la siguiente línea a inspeccionar (tengase en cuenta que el plan proporciona solo un punto aproximado). Los enfoques propuestos para generar estas conductas en el robot se discuten en los siguientes apartados.

El plan a seguir por el robot para inspeccionar un campo de cultivo lo genera un planificador de trayectorias. La planificación de trayectorias en entornos agrícolas es una tarea compleja. Generalmente, puede formularse como un Problema de Enrutamiento de Vehículos con Capacidad (Bochtis & Sørensen, 2009). Básicamente, el problema consiste en determinar la mejor ruta de inspección que proporcione una cobertura completa del campo considerando características tales como la forma del campo, la dirección de las líneas de cultivo, el tipo de cultivo y algunas características de los vehículos, tales como los radios de giro. Los vehículos deben recorrer completamente cada línea exactamente una vez; por lo tanto, el planificador determina el orden en el que se deben recorrer las líneas de tal manera que se minimice algún criterio de optimización. Dado un contorno de campo, el planificador puede deducir la disposición de las líneas y la distancia entre líneas requerida por las plantas, debido a que asume que la siembra se llevó a cabo por una herramienta mecánica que mantuvo esa distancia de una manera razonablemente precisa. Además, no se requiere una alta precisión, ya que la plataforma propuesta y el método propuesto utilizan exclusivamente los puntos de trayectoria como referencias de guía para entrar y salir de las líneas de cultivo.

El planificador empleado se describe en (Conesa-Muñoz, Bengochea-Guevara, Andujar, & Ribeiro, 2016). Utiliza un algoritmo de recocido simulado para abordar un caso simplificado del problema general de planificación de trayectoria con un solo vehículo y teniendo en cuenta como criterio de optimización la distancia recorrida. La Figura 3.15 muestra la ruta que genera el planificador para un campo de cultivo en el que se realizaron experimentos. El tamaño del campo era de aproximadamente 7 m × 60 m, lo que representa un total de diez líneas de cultivo en un esquema de siembra de maíz con 0,7 m de distancia entre líneas. En este caso, la trayectoria óptima era explorar secuencialmente el campo, comenzando en un borde y siempre pasando a una línea adyacente, ya que el vehículo tiene un radio de giro que permite el movimiento entre líneas adyacentes suponiendo cabeceras que permitan la transición del vehículo.

Figura 3.15. Trayectoria calculada por el planificador para que el robot mBase-MR7 recorra todas las líneas del campo de cultivo de maíz utilizado en los experimentos.

3.4.1. Conducta de seguimiento de línea de cultivo

Se diseñó e implementó un método de procesamiento de imágenes capaz de extraer la disposición de las líneas de cultivo en tiempo real a partir de las imágenes adquiridas con la cámara colocada en la parte frontal del robot para permitirle navegar autónomamente siguiendo la línea de cultivo situada entre sus ruedas. El objetivo del procesamiento de imagen es obtener la posición relativa del vehículo con respecto a la línea de cultivo que está siguiendo (Figura 3.16), es decir, el ángulo de orientación del robot respecto a la línea de cultivo (α), y el desplazamiento (d) entre el centro del robot y el punto más cercano a la línea que define la línea de cultivo.

Figura 3.16. Posición y orientación del robot respecto a la línea central del cultivo

Los valores del desplazamiento del vehículo (d) y del ángulo (α) se suministran a dos controladores borrosos, uno para la velocidad de rotación y otro para la velocidad de traslación, que determinan los valores de corrección de la orientación y la velocidad para generar en el robot una conducta de seguimiento de línea de cultivo.

3.4.1.1. Procesamiento de imagen

En el proceso de reconocimiento de líneas de cultivo, el principal problema es la identificación de características que sean estables en diferentes condiciones ambientales. El proceso de detección de líneas se acompaña de algunas dificultades, como líneas incompletas, plantas ausentes, y formas y tamaños irregulares de las plantas dentro de la misma línea. Además, la presencia de malas hierbas a lo largo de las líneas puede distorsionar el reconocimiento de las líneas añadiendo ruido a la estructura. La mayoría de trabajos en este ámbito se han centrado en grandes vehículos agrícolas, en los que el desplazamiento es más uniforme que en los vehículos pequeños. En este caso, el desafío consiste en detectar de forma robusta una línea de cultivo en presencia de malas hierbas, a pesar de las vibraciones y variaciones en la cámara causadas por el movimiento del vehículo en el campo. La mayoría de métodos para la detección de vegetación generalmente considera que todos los píxeles asociados con la vegetación tienen un fuerte componente verde (Meyer & Neto, 2008), (Woebbecke et al., 1995), (Andreasen, Rudemo, & Sevestre, 1997), (Perez, Lopez, Benlloch, & Christensen, 2000), (Aitkenhead, Dalgetty, Mullins, McDonald, & Strachan, 2003), (Yang, Prasher, Landry, & Ramaswamy, 2003), (Ribeiro, Fernández-Quintanilla, Barroso, García-Alegre, & Stafford, 2005), (Van Evert et al., 2006). Para aprovechar esta característica, es frecuente la utilización de cámaras digitales en el espectro visible y el uso del modelo de color RGB

cuando se trabaja a nivel del suelo (Sainz-Costa et al., 2011), (Søgaard & Olsen, 2003), (Hague et al., 2006), (Leemans & Destain, 2006), (Tellaache, BurgosArtizzu, et al., 2008), (Bossu et al., 2009), (Romeo et al., 2012), (Meyer & Neto, 2008), (Aitkenhead et al., 2003), (Yang et al., 2003), (Ribeiro et al., 2005), (Van Evert et al., 2006). En la estrategia propuesta para la detección de líneas se desarrolla una técnica en tiempo real que funciona correctamente con imágenes RGB adquiridas en condiciones ambientales variables y con iluminación no controlada.

En la Figura 3.17 (a) se muestra una imagen típica adquirida por la cámara del robot. En las esquinas superiores de la imagen, las líneas de cultivo son difíciles de distinguir debido a la perspectiva de la imagen. Para evitar estos efectos, la imagen se dividió por la mitad, descartándose la mitad superior (Figura 3.17 (b)). Por lo tanto, el procesamiento de imagen presentado a continuación solo utiliza la mitad inferior de cada imagen. La Figura 3.18 muestra un diagrama de flujo de la fase de procesamiento de imagen.

Figura 3.17. (a) Imagen característica captada por la cámara del robot (b) Región de interés de la imagen recuadrada en rojo

Figura 3.18. Diagrama de flujo del procesamiento de imagen

3.4.1.1.1. Segmentación

El objetivo de la primera etapa del procesamiento es aislar la cubierta vegetal del fondo, es decir, convertir la imagen RGB de entrada en una imagen en blanco y negro en la que los píxeles blancos representan la cubierta vegetal (cultivo y malas hierbas) y los píxeles negros representan los elementos restantes en la imagen (tierra, piedras, paja, etc.).

La segmentación explota la fuerte componente verde de los píxeles que representan la vegetación. En primer lugar, la imagen RGB en color se transforma en una imagen en escala de grises mediante una combinación lineal de los planos rojo, verde y azul, como se muestra en la ecuación (3.3).

$$\forall i \in \text{filas_imagen} \wedge \forall j \in \text{columnas_imagen}$$

$$\text{Imagen_gris}(i,j) = r \cdot \text{rojo}(i,j) + g \cdot \text{verde}(i,j) + b \cdot \text{azul}(i,j) \quad (3.3)$$

donde i varía de 0 a 352 (recuerde que el área de trabajo de la imagen es la mitad inferior), j de 0 a 1056, los valores $\text{rojo}(i,j)$, $\text{verde}(i,j)$, $\text{azul}(i,j)$ son, respectivamente, las intensidades de rojo, verde y azul no normalizadas (0-255) en el píxel (i, j) , y r, g, b son el conjunto de coeficientes reales que determinan cómo se construye la imagen en escala de grises. Estos valores son cruciales en la segmentación de la vegetación respecto a la no vegetación, y su selección se discute en detalle en (Woebbecke et al., 1995) y (Ribeiro et al., 2005). En la estrategia propuesta, estos valores se establecieron a un conjunto de valores constantes ($r = -0,884$, $g = 1,262$ y $b = -0,311$) que mostraron previamente buenos resultados para imágenes similares (Burgos-Artiz et al., 2010) en comparación con otros índices bien conocidos, tales como el exceso de verde, ExG, ($r = -1$, $g = 2$, $b = -1$) (Woebbecke et al., 1995).

En el siguiente paso, se utiliza un umbral para convertir la imagen en escala de grises en una imagen binaria (blanco y negro) en la que, como ya se dijo, los píxeles blancos representan la cubierta vegetal y los píxeles negros el resto. El umbral depende de las condiciones de iluminación; para que la estrategia funcione bien tanto en días soleados como nublados, el umbral no es constante, sino que se calcula para cada imagen de entrada como el valor medio de las intensidades de gris en la imagen. Los resultados de la etapa de segmentación se ilustran en la Figura 3.19.

Figura 3.19. (a) Imagen original con una marcada presencia de malas hierbas (b) Imagen en escala de grises (c) Imagen segmentada

3.4.1.1.2. Detección de la línea central del cultivo

El objetivo de la siguiente etapa, que procesa las imágenes binarias obtenidas en la etapa anterior, consiste en discriminar los píxeles blancos pertenecientes a la línea central del cultivo de los que pertenecen a malas hierbas u otras líneas de cultivo. Para lograr este objetivo, el método desarrollado basado en (Bengochea-Guevara, Burgos Artizzu, & Ribeiro, 2014) realiza primero una operación morfológica de apertura (erosión seguida de dilatación) de la imagen binaria para eliminar píxeles blancos aislados (erosión) y resaltar áreas con una alta densidad de píxeles blancos (dilatación). Uno de los objetivos de esta operación es eliminar los pequeños grupos de píxeles negros que aparecen dentro de los cultivos. El elemento estructural utilizado para la dilatación y la erosión es un cuadrado de 3×3 . A continuación se extraen los bordes de la imagen resultante utilizando el operador Sobel (Sobel, 1978), marcando todos los píxeles en las transiciones (de blanco a negro y viceversa). En la Figura 3.20 se muestra el resultado de esta operación.

Figura 3.20. Imagen obtenida tras aplicar el operador Sobel a una imagen captada por el robot

La imagen se divide entonces en tres franjas horizontales para hacer frente a la perspectiva de la imagen. Cada franja se procesa independientemente usando el método expuesto a continuación. En primer lugar, se busca el potencial centro vertical de la línea central del cultivo, siendo éste la columna de la franja con el mayor número de píxeles blancos dentro de una ventana de búsqueda. Para identificar esta columna, se construye un vector con tantas componentes como

columnas tiene la ventana, donde cada componente almacena el número de píxeles blancos (vegetación) de la columna asociada, tal como se expresa en la ecuación (3.4).

$$\forall i \in \text{filas_franja} \wedge \forall j \in \text{columnas_franja}$$

$$v(j) = \sum_{i=1}^{\text{filas}} \text{imagen_binaria}(i,j) \quad (3.4)$$

La perspectiva de las imágenes se tiene también en cuenta al definir esta ventana, de tal forma que el tamaño de la ventana varía dependiendo de la proximidad de la cámara a la franja analizada. La ventana de búsqueda está centrada en el centro de la imagen en la primera imagen, pero debido al solapamiento entre las imágenes siguientes (el robot avanza 6 cm entre imágenes yendo a su máxima velocidad), el potencial centro de la línea en la imagen se busca alrededor de la posición central identificada en la imagen anterior.

Después de identificar el potencial centro de la línea, el algoritmo comienza a identificar los bordes que delimitan la línea de cultivo, buscando a la derecha y a la izquierda desde el centro encontrado. Para confirmar que se ha alcanzado un borde de la línea, el método utiliza tres etiquetas para los píxeles: blanco, negro y borde. Cuando el píxel encontrado es blanco, se marca como perteneciente a la línea de cultivo, y el algoritmo continúa con el siguiente píxel. Cuando se localiza un píxel de borde, la exploración ha alcanzado un borde de la línea o un grupo de píxeles negros dentro del cultivo. Para distinguir entre estos dos casos, se utiliza la distancia al siguiente píxel de borde. La distancia a la siguiente línea de cultivo o a una mala hierba entre líneas de cultivo es mayor en el primer caso que en el último, es decir, dentro de la línea de cultivo. De hecho, se establecen dos umbrales de distancia, $D_1 \leq D_2$, de tal manera que, si la distancia calculada es mayor que el umbral D_2 , la exploración ha alcanzado un borde de la línea de cultivo, mientras que, si la distancia es menor que D_1 , se ha alcanzado un grupo de píxeles negros dentro del cultivo. Si la distancia está entre D_1 y D_2 , el método utiliza el vector generado previamente para localizar el centro de la línea y procede como sigue. Se calcula el porcentaje de píxeles blancos en cada columna para el rango de componentes del vector entre la posición actual del píxel y la posición del borde. Si este porcentaje es superior a un umbral denominado *min_proporción*, el algoritmo determina que ha alcanzado un grupo de píxeles negros dentro del cultivo porque la columna a la que pertenece este grupo de píxeles negros tiene un gran número de píxeles blancos, lo que indica que forma parte de una línea de cultivo. Si es inferior a este umbral, el algoritmo determina que ha alcanzado el borde de la línea de cultivo, ya que el número de píxeles negros en las columnas que lo separan de la siguiente línea de cultivo o mala hierba es grande.

Este procedimiento se expone formalmente en la Tabla 3.4, donde p es el píxel que se está explorando actualmente, n es el siguiente píxel (no negro) en el orden de procesamiento a una distancia d . D_1 , D_2 y *min_proporción* son los tres parámetros del método.

Tabla 3.4. Método de detección de línea de cultivo

Tipo del pixel actual	Distancia d (en píxeles) hasta el próximo pixel no negro		
	$d \leq D_1$	$D_1 < d \leq D_2$	$d > D_2$
Blanco	Marca todos los píxeles desde p a n y salta a n ($p \leftarrow n$)	Marca todos los píxeles desde p a n y salta a n ($p \leftarrow n$)	Fin
Borde	Marca todos los píxeles desde p a n y salta a n ($p \leftarrow n$)	SI $\sum_i$ píxeles blancos ($i, p \dots n$) $> min_proporción$ ENTONCES Marca todos los píxeles desde p a n y salta a n ($p \leftarrow n$) SI NO Fin	Fin
Negro	Salta hasta n ($p \leftarrow n$)	Salta a n ($p \leftarrow n$)	Fin

Debido a los efectos de la perspectiva en la imagen, el ancho de las líneas de cultivo varía dependiendo de la proximidad a la cámara. Este fenómeno se considera en el método propuesto. El parámetro D_1 varía entre 5 y 10, comenzando en 5 cuando se analiza la franja más alejada de la cámara y llegando a 10 cuando se analiza la franja más cercana. Del mismo modo, el parámetro D_2 varía entre 10 y 20. El valor del umbral $min_proporción$ es 0,6. Usando este proceso, se puede detectar la línea central de cultivo a partir de la imagen binaria en presencia o ausencia de malas hierbas (Figura 3.21).

Figura 3.21. (a) Imagen segmentada (b) Línea central del cultivo detectada aplicando el método de detección propuesto a la Figura 3.19 (a)

3.4.1.1.3. Extracción de la línea recta que define la línea central del cultivo

Después de detectar la línea central del cultivo, el propósito de esta etapa es extraer la línea recta que define la línea central de cultivo de la imagen resultante de la última etapa. Para hacer frente a la perspectiva de la cámara, la imagen se divide en tres franjas horizontales, al igual que en la etapa anterior, que se procesan para obtener tres puntos que definan la línea central de cultivo. La etapa anterior suponía que el potencial centro vertical de la línea central del cultivo era la columna con el mayor número de píxeles blancos. Sin embargo, esto puede no ser el caso cuando están presentes grupos de píxeles negros dentro del cultivo. En la etapa anterior, tal ocurrencia no afecta al algoritmo, es decir, no importa si el algoritmo comienza en el centro exacto de la línea de cultivo siempre y cuando se encuentre dentro de la línea. Sin embargo, para la extracción de la línea recta que define la línea de cultivo se requiere que el centro de la línea de cultivo se localice de la forma más precisa posible. Por lo tanto, se define una ventana de búsqueda de la misma manera que en la

etapa anterior, y se obtiene un vector con tantos componentes como el tamaño de ventana, donde cada componente almacena el número de píxeles blancos de la columna asociada. A continuación, se calcula el valor máximo del vector y todas las columnas de la imagen cuya componente vectorial es superior al 80% de este valor máximo se convierten en blanco, mientras que el resto se convierte en negro (Figura 3.22 (a)). Para determinar los puntos que definen la línea central del cultivo, en cada franja, se elige el centro geométrico del bloque con el mayor número de columnas blancas. El algoritmo estima entonces la línea recta que define los tres centros identificados (uno por cada franja) usando el método de mínimos cuadrados (Gauss, 1809) (Figura 3.22 (b)). Si se localizan menos de dos centros (debido a errores en la siembra), el algoritmo emplea la línea recta que se obtuvo en la imagen anterior. Después de obtener la línea recta que define la línea de cultivo, se calculan el ángulo (α) entre la dirección de movimiento del robot y la línea central del cultivo, y el desplazamiento (d) entre el centro del vehículo y el centro de la línea de cultivo (Figura 3.16).

Figura 3.22. (a) Línea central del cultivo obtenida en la etapa anterior (b) Columnas blancas y negras definidas por el algoritmo (c) Línea recta que define la línea central del cultivo

3.4.1.2. Control de navegación

Existen varios enfoques para abordar el control de un vehículo. Los métodos convencionales de control producen resultados razonables a expensas de una alta carga computacional y un diseño costoso debido a que la obtención del modelo matemático del vehículo se convierte en extremadamente laboriosa (Sheikholeslam & Desoer, 1992), (Rossetter & Gerdes, 2002), ya que los robots móviles con ruedas están caracterizados por dinámicas no lineales y están afectados por un importante número de perturbaciones, como derivas, rozamientos o variaciones en la cantidad de carga. Como alternativa, se puede aproximar el comportamiento humano para controlar la velocidad y dirección del vehículo usando técnicas de inteligencia artificial, como las redes neuronales (Pomerleau, 1989). Sin embargo, la técnica que proporciona una mejor aproximación al razonamiento humano y proporciona una estructura de control más intuitiva es la lógica borrosa (Zadeh, 1965), (Sugeno, 1999). Varios autores han propuesto soluciones basadas en la lógica borrosa para la navegación autónoma (Fraichard & Garnier, 2001), (Naranjo, Sotelo, Gonzalez, Garcia, & Sotelo, 2007), (Pradhan, Parhi, & Panda, 2009), (Kodagoda, Wijesoma, & Teoh, 2002), (Antonelli, Chiaverini, & Fusco, 2007), que demuestran su robustez. En (Fraichard & Garnier, 2001), se emplea el control borroso en un automóvil real para realizar el seguimiento de trayectorias y la evitación de obstáculos en entornos exteriores reales parcialmente conocidos. En (Naranjo et al., 2007), se implementan controladores borrosos en un coche real para realizar experimentos en carreteras reales dentro de un circuito privado. Sus resultados muestran que los controladores borrosos imitan

perfectamente el comportamiento humano en la conducción y el seguimiento de rutas, así como maniobras más complejas en las que están implicados varios vehículos, como el adelantamiento o el control adaptativo de la velocidad de crucero. En (Pradhan et al., 2009), se discute el empleo de diferentes controladores borrosos para la navegación de múltiples robots móviles en presencia de obstáculos estáticos y móviles. Sus experimentos demuestran que los robots son capaces de evitar los obstáculos y salvar los caminos sin salida, así como alcanzar los objetivos eficientemente. En (Kodagoda et al., 2002), los autores desarrollan e implementan controladores borrosos para el control de dirección y velocidad de un vehículo guiado autónomo. Sus resultados indican que los controladores propuestos son insensibles a la incertidumbre paramétrica y a las fluctuaciones de carga y superan a los controladores PID convencionales, particularmente en la precisión de seguimiento, error de estado estacionario, control de la vibración y robustez. En (Antonelli et al., 2007), se aborda el seguimiento de una trayectoria desconocida, basado en un conjunto de reglas borrosas, que emula el comportamiento de un conductor humano. Aplica un conocimiento aproximado sobre la curvatura de la trayectoria delante del vehículo y la distancia entre el vehículo y el siguiente giro para alcanzar el valor máximo posible de la velocidad de traslación para conducir con seguridad siguiendo la trayectoria.

3.4.1.2.1. Introducción a la lógica borrosa

En el año 1965, la aparición de un trabajo de Lofti Zadeh sobre Conjuntos Borrosos (Zadeh, 1965), revolucionó la matemática al proponer una nueva lógica denominada *fuzzy* (borrosa). Según la misma, una puerta no tiene porqué estar necesariamente abierta (1) o cerrada (0), sino que puede estar abierta a medias (0,5), bastante abierta (0,8), casi cerrada (0,1), etc. La principal ventaja de utilizar términos lingüísticos como a medias, bastante, casi, poco, mucho, algo, etc., está en que permite plantear el problema en los mismos términos en los que lo haría un experto. De hecho, el propio Zadeh justifica el éxito de sus trabajos con la frase: “El mundo es *fuzzy*”. En otras palabras, no tiene sentido buscar la solución a un problema no perfectamente definido, por medio de un planteamiento matemático muy exacto, cuando es el ser humano el primero que razona empleando inexactitud. Así la lógica borrosa surge como un intento de formalización del razonamiento con incertidumbre. En particular, y al contrario que otras formas de razonamiento, intenta abordar problemas definidos en términos lingüísticos, y por tanto imprecisos, donde los datos están expresados en términos cualitativos.

El primer punto que debe afrontarse al enfocar el tema es el de la representación matemática de las expresiones lingüísticas. Podemos formalizar que un varón es alto cuando mide 1,90, y que hace frío cuando la temperatura es de 10°C. Evidentemente, una estatura de 1,75 ya no correspondería a un varón alto, sino a uno de estatura normal. “1,90 es alto” es cierto al 100%, “1,75 es alto” es cierto al 0%, pero “1,75 es normal” es cierto al 100%. Pues bien, la aplicación de la lógica borrosa consiste en asignar a estaturas comprendidas entre 1,75 y 1,90, valores borrosos entre 0 y 1. Si la interpolación se hace de forma lineal, entonces “1,80 es alto” es algo cierto (0,33 *fuzzy*). La lógica borrosa tendrá, por una parte, el mismo aspecto sintáctico que la lógica de predicados y, por otra, su semántica se basa en el concepto de borrosidad que se formaliza en la teoría de conjuntos borrosos.

3.4.1.2.2. Conjuntos borrosos

En los conjuntos clásicos algo está incluido completamente en él o no lo está en absoluto. Esta situación puede describirse asignando un 1 a todos los elementos incluidos en el conjunto y un 0 a los no incluidos. A la función que asigna estos valores se le llama función de pertenencia. Los conjuntos borrosos permiten describir el grado de pertenencia o inclusión de un objeto (o el valor de una variable) al concepto dado por la etiqueta que le da nombre, asignando un número real entre 1

y 0.

Sea U un conjunto de objetos que se denomina universo del discurso. Un conjunto borroso F en U queda caracterizado por una función de pertenencia μ_F que toma valores en el intervalo $[0,1]$, es decir, $\mu_F: U \rightarrow [0,1]$; donde $\mu_F(u)$ representa el grado en el que $u \in U$ pertenece al conjunto borroso F .

3.4.1.2.3. Funciones de pertenencia de conjuntos borrosos

La función de pertenencia de un conjunto borroso consiste en un conjunto de pares ordenados $F = \{(u, \mu_F(u)) \mid u \in U\}$ si la variable es discreta, o una función continua si no lo es. El valor de $\mu_F(u)$ indica el grado con que el valor u de la variable U está incluida en el concepto representado por la etiqueta F . Para la definición de estas funciones se utilizan ciertas familias de forma estándar, las más frecuentes y que se usarán a lo largo de esta tesis, son las funciones de tipo trapezoidal, *singleton* y triangular.

3.4.1.2.4. Función de pertenencia trapezoidal

La función trapezoidal (Figura 3.23) se define por cuatro puntos a, b, c, d . Esta función es 0 para valores menores de a y mayores de d , vale 1 entre b y c , y toma valores en el intervalo $(0,1)$ entre a y b , y entre c y d .

Figura 3.23. Función trapezoidal

Se utiliza en sistemas borrosos sencillos, pues permite definir un conjunto borroso con pocos datos, y calcular su valor de pertenencia con pocos cálculos. Es adecuada para modelar propiedades que comprenden un rango de valores. La definición de la función se muestra en (3.5).

$$Trap(u; a, b, c, d) = \begin{cases} 0 & u < a \\ \frac{u - a}{b - a} & a \leq u < b \\ 1 & b \leq u \leq c \\ \frac{d - u}{d - c} & c < u \leq d \\ 0 & u > d \end{cases} \quad (3.5)$$

3.4.1.2.5. Función de pertenencia singleton

La función tipo *singleton* tiene valor 1 solo para un punto a y 0 para el resto (Figura 3.24).

Figura 3.24. Función *singleton*

Se utiliza habitualmente en sistemas borrosos simples para definir los conjuntos borrosos de las particiones de las variables de salida, pues permite simplificar los cálculos y requiere menos memoria para almacenar la base de reglas. La definición de esta función se indica en (3.6).

$$Sing(u; a) = \begin{cases} 1 & u = a \\ 0 & u \neq a \end{cases} \quad (3.6)$$

3.4.1.2.6. Función de pertenencia triangular

La función triangular (Figura 3.25) es adecuada para modelar propiedades con un valor de inclusión distinto de 0 para un rango de valores estrecho en torno a un punto b .

Figura 3.25. Función triangular

En (3.7) se muestra la definición de esta función.

$$Triang(u; a, b, c, d) = \begin{cases} 0 & u < a \\ \frac{u-a}{b-a} & a \leq u < b \\ \frac{c-u}{c-b} & b \leq u \leq c \\ 0 & u > c \end{cases} \quad (3.7)$$

3.4.1.2.7. Reglas borrosas

Las reglas borrosas combinan uno o más conjuntos borrosos de entrada, llamados antecedentes o premisas, y les asocian un conjunto borroso de salida, llamado consecuente o consecuencia. Una regla típica, de tipo SI-ENTONCES para un sistema de control sería “SI error es positivo-pequeño y derivada de error es negativo-pequeño ENTONCES acción es positiva-pequeña”.

Las reglas borrosas permiten expresar el conocimiento que se dispone sobre la relación entre antecedentes y consecuentes. Para expresar este conocimiento de forma completa normalmente se precisa de varias reglas, que se agrupan formando una base de reglas, es decir el conjunto de reglas que expresan las relaciones conocidas entre antecedentes y consecuentes. Por tanto, la base de reglas borrosas es una colección de reglas con el formato mostrado en (3.8).

$$\text{SI } x_1 \text{ es } F_1 \text{ y } \dots \text{ y } x_n \text{ es } F_n \text{ ENTONCES } y \text{ es } G \quad (3.8)$$

donde F_i y G son conjuntos borrosos en $U_i \subset \mathfrak{R}$ y $V \subset \mathfrak{R}$, respectivamente, y $\bar{x} = (x_1, \dots, x_n)^T \in U_i \times \dots \times U_n$, e $y \in V$ son variables lingüísticas. Este formato de reglas se conoce como borroso puro o de tipo Mamdani (Mamdani, 1974), que estabiliza un sistema en torno a su punto de trabajo.

Otro formato frecuente para las reglas es el llamado tipo Takagi-Sugeno (Sugeno, 1999); en este caso la función de salida es una combinación lineal de las variables de entrada (3.9).

$$\text{SI } x_1 \text{ es } F_1 \text{ y } \dots \text{ y } x_n \text{ es } F_n \text{ ENTONCES } y=f(x) \quad (3.9)$$

3.4.1.2.8. Borrosificador

El *borrosificador* establece una relación entre los puntos de entrada no borrosos al sistema, $\bar{x} = (x_1, \dots, x_n)^T$, y sus correspondientes conjuntos borrosos A en U . Calcula el grado de pertenencia de las variables de entrada a cada una de las etiquetas lingüísticas mediante las funciones de pertenencia. Éste será un número comprendido entre 0 y 1, ambos incluidos, para cada etiqueta.

3.4.1.2.9. Desborrosificador

El *desborrosificador* es la función que transforma un conjunto borroso en V , normalmente salida de un dispositivo de inferencia borrosa, en un valor no borroso.

El método de desborrosificación normalmente empleado para sistemas de tipo Mamdani es

el centro de gravedad. Si el sistema es de tipo Sugeno, el valor de la salida no borrosa se obtiene como media ponderada de las salidas de cada regla.

3.4.1.2.10. Controladores borrosos

La estructura interna de un controlador borroso se muestra en la Figura 3.26. Un primer elemento llamado borrosificador realiza la conversión de valores discretos a términos borrosos. Su salida es utilizada por el mecanismo de inferencia borrosa para aplicarla a cada una de las reglas de la base de conocimiento. Finalmente, el desborrosificador transformará estos conjuntos borrosos en un valor no borroso.

Figura 3.26. Estructura de un controlador borroso

3.4.1.2.11. Control propuesto

Como se explicó anteriormente, gracias al método de detección de líneas de cultivo que se ha implementado en el robot, se obtiene el ángulo de orientación y el desplazamiento del centro del vehículo respecto a la línea de cultivo. Esta información es la que se utiliza para controlar el vehículo. El objetivo es recorrer la línea de cultivo lo más rápido posible evitando pisar las plantas de cultivo.

El control de navegación propuesto que permite al robot seguir líneas de cultivo (en estado temprano, cuando las plantas todavía no han crecido mucho) consiste en dos controladores borrosos (Figura 3.27), uno para controlar la velocidad de rotación y otro para controlar la velocidad de traslación. Ambos controladores tienen la finalidad de emular el comportamiento de un conductor experimentado. En el caso de un conductor, si el vehículo se desplaza hacia un lado de la línea que quiere seguir, el conductor gira el volante hacia el lado contrario, rectificando el volante según el vehículo se aproxima a la línea a seguir. De igual forma ocurre si el vehículo se desvía cierto ángulo de la orientación que debe seguir, el conductor gira el volante en el sentido contrario, rectificando el volante según se aproxima a la orientación adecuada. Basándose en estas premisas, se diseñaron los controladores borrosos, de forma que el robot navegue con la línea de cultivo entre sus ruedas, corrigiendo su trayectoria si ésta se desvía de la línea que está siguiendo.

Figura 3.27. Esquema visual del control desarrollado

3.4.1.2.12. Controlador borroso de la velocidad de rotación

Las entradas del controlador que actúan sobre la velocidad de rotación del robot son: 1) el desplazamiento del centro del vehículo respecto al punto de medio de la línea de cultivo (d en la Figura 3.16) y 2) el ángulo de orientación del robot (α en la Figura 3.16). El controlador proporciona como salida la velocidad de rotación del vehículo.

A la hora de modelar un sistema mediante lógica borrosa, hay varias configuraciones posibles, tanto para la estructura de las reglas como para la forma en la que se opera o la forma en la que se transforma la salida de nuevo a un valor no borroso.

En este caso se ha escogido el método de implicación de Takagi-Sugeno, donde los antecedentes son proposiciones borrosas y los consecuentes son funciones de pertenencia de tipo singleton. Se ha elegido este método porque el uso de *singletons* como consecuentes en las reglas difusas es adecuado para aplicaciones de control, donde el tiempo de respuesta es crucial (Sugeno, 1999); como ocurre en este trabajo, donde se requieren los menores tiempos de procesamiento posibles para que la reacción del robot sea adecuada a la velocidad en la que se mueve.

Las funciones matemáticas seleccionadas para las operaciones de AND, OR y desborrosificación han sido respectivamente las funciones: MIN, MAX y Media ponderada, por sus buenos resultados.

A continuación, se describen los conjuntos borrosos y las reglas borrosas definidas para el controlador de velocidad de rotación implementado.

Las entradas del controlador toman un valor continuo dentro de un rango específico

(diferente para cada entrada). Dicho valor se debe transformar en un conjunto borroso para su posterior uso como antecedente en las reglas de inferencia del controlador.

En el caso de la entrada correspondiente al desplazamiento del robot respecto al punto medio de la línea de cultivo (d), el rango de variación es de -25 a 25 cm. La caracterización del desplazamiento se ha realizado en 5 conjuntos borrosos (Negativo Grande (NG), Negativo Pequeño (NP), Cero (Z), Positivo Pequeño (PP), Positivo Grande (PG)) (Figura 3.28 (a)). Para elegir el valor de los rangos de cada conjunto se ha tenido en cuenta la distancia entre las ruedas del robot (41 cm) de forma que se ajustaron para que el robot no pisase la línea de cultivo en su recorrido.

La entrada correspondiente al ángulo de orientación (α) también se caracteriza con 5 conjuntos borrosos (Negativo Grande (NG), Negativo Pequeño (NP), Cero (Z), Positivo Pequeño (PP), Positivo Grande (PG)) (Figura 3.28 (b)). Para seleccionar el rango de variación y el valor de los rangos de cada conjunto se determinó que el robot pisaba la línea de cultivo si giraba un ángulo de 30° o -30° .

Como se ha comentado, las funciones de pertenencia de la salida del controlador son de tipo *singleton* (Figura 3.29). El rango de velocidades de rotación permitidas por el robot es de $-90^\circ/\text{s}$ a $90^\circ/\text{s}$, y los conjuntos borrosos se seleccionaron para cubrir el rango de velocidades necesario para controlar el robot de forma suave (Negativa Grande (NG), Negativa Pequeña (NP), Cero (Z), Positivo Pequeña (PP), Positiva Grande (PG)).

Una vez convertidas las entradas a conjuntos borrosos, se aplican las reglas de inferencia para hallar las salidas. Se han diseñado 25 reglas, teniendo en cuenta todas las posibles combinaciones, y en cada una se ha pretendido reflejar lo que haría un conductor experto en caso de estar en la situación concreta. Un ejemplo de regla se ilustra en (3.10).

SI (Desplazamiento es NG) y (Ángulo es PP) ENTONCES (Velocidad Rotación es PP) (3.10)

Las reglas se resumen en la Tabla 3.5.

(a)

(b)

Figura 3.28. Controlador de la velocidad de rotación. Conjuntos borrosos de las variables de entrada: (a) Desplazamiento d y (b) Ángulo de orientación α

Figura 3.29. Controlador de la velocidad de rotación. Conjuntos borrosos para la variable de salida

Tabla 3.5. Reglas de control borroso para la velocidad de rotación

<div style="display: inline-block; transform: rotate(-45deg);"> Desplazamiento d </div>					
	NG	NP	Z	PP	PG
Ángulo α					
NG	PG	PG	PG	PP	Z
NP	PG	PP	PP	Z	NP
Z	PG	PP	Z	NP	NG
PP	PP	Z	NP	NP	NG
PG	Z	NP	NG	NG	NG

3.4.1.2.13. Controlador borroso de la velocidad de traslación

Las variables de entrada en el controlador de la velocidad de traslación del robot son las mismas que las del controlador anterior, es decir, desplazamiento y ángulo (d y α), y la salida es la velocidad de traslación del robot.

Al igual que anteriormente, y por los mismos motivos, se ha elegido para este controlador el método de implicación de Takagi-Sugeno. Se eligen de nuevo las funciones: MIN, MAX y Media ponderada para las operaciones de AND, OR y desborrosificación, respectivamente.

En cuanto a los conjuntos borrosos de ambas entradas se han elegido 5 (Negativo Grande (NG), Negativo Pequeño (NP), Cero (Z), Positivo Pequeño (PP), Positivo Grande (PG)) (Figura 3.30). Para elegir el valor de los rangos de estos conjuntos se ha tenido en cuenta que el vehículo solo debía desplazarse a su máxima velocidad (30 cm/s) cuando estuviera correctamente posicionado; en caso contrario se mueve más despacio para evitar pisar el cultivo.

(a)

(b)

Figura 3.30. Controlador de la velocidad de traslación. Conjuntos borrosos de las variables de entrada: (a) Desplazamiento d y (b) Ángulo de orientación α

La salida del controlador, la velocidad de traslación aplicada al vehículo, se caracteriza por tres conjuntos borrosos (Mínima (MIN), Media (MED), Máxima (MAX)), cuyos valores se seleccionaron para cubrir el rango de velocidades permitidas del robot (Figura 3.31).

Figura 3.31. Controlador de la velocidad de traslación. Conjuntos borrosos para la variable de salida

Se han diseñado 25 reglas con todas las posibles combinaciones, de manera que el vehículo solo circule a la máxima velocidad cuando esté correctamente posicionado y orientado, y en caso de no ser así, dependiendo de la magnitud del desplazamiento y/u orientación, desplazarse a velocidades menores. Las reglas establecidas se muestran en la Tabla 3.6.

Tabla 3.6. Reglas de control borroso para la velocidad de traslación

Desplazamiento d Ángulo α	NG	NP	Z	PP	PG
NG	MIN	MIN	MIN	MIN	MIN
NP	MIN	MIN	MED	MED	MED
Z	MIN	MED	MAX	MED	MIN
PP	MED	MED	MED	MIN	MIN
PG	MIN	MIN	MIN	MIN	MIN

3.4.2. Conducta de detección del final de la línea de cultivo

Para completar el seguimiento de la línea de cultivo inspeccionada, el robot debe detectar el final de la línea de cultivo (Figura 3.32). Para ello se utiliza el número de píxeles pertenecientes a vegetación en la imagen. Cuando el robot comienza a seguir una línea de cultivo, el número de píxeles pertenecientes a vegetación en la primera imagen del recorrido se almacena como valor de referencia. A medida que el robot avanza, detecta el número de píxeles asociados a vegetación en cada imagen. Cuando este número es inferior al 80% (umbral determinado mediante el método de prueba y error) del valor de referencia, el robot asume que ha llegado al final de la línea de cultivo y

comprueba con el GPS-RTK de a bordo que la posición es coherente, con un margen de error, con el punto de salida establecido en el plan. Si el punto está próximo al punto de salida establecido en el plan, el robot se detiene para iniciar la maniobra de cambio de línea; de lo contrario, continúa siguiendo la línea de cultivo usando la dirección de la línea central que se obtuvo en la imagen anterior. Esta es la forma de lidiar con los errores de siembra que provocan la pérdida de píxeles asociados a vegetación.

Figura 3.32. (a) Imagen captada por el robot al final de la línea de cultivo y (b) su correspondiente imagen segmentada. El número de píxeles asociados a vegetación (píxeles blancos) es inferior al 80% del número de píxeles blancos en la imagen de referencia (Figura 3.19) y la localización del robot es muy cercana al punto de salida definido por el plan para esa línea de cultivo que se está inspeccionando. De esta forma, el robot determina que ha alcanzado el final de la línea de cultivo

3.4.3. Conducta de cambio de línea

Después de detectar el final de una línea de cultivo, se lleva a cabo la conducta de cambio de línea. En esta conducta, el robot realiza las maniobras necesarias para posicionarse en la cabecera de la siguiente línea a inspeccionar. Para realizarlas se ha considerado como si el robot no pudiera rotar sobre su eje vertical, al igual que la mayoría de vehículos utilizados en los campos agrícolas (tractores, vehículos todo terreno, etc.). La razón es que a menudo, en los experimentos realizados, las ruedas del robot se atascaban en la tierra al girar sobre sí mismas. Este conjunto de maniobras consiste en una combinación de movimientos en línea recta y en arco con la ayuda del GPS de a bordo. En concreto se trata de la siguiente secuencia de cinco movimientos (Figura 3.33): (1) movimiento de avance en línea recta para situarse fuera del cultivo, en otras palabras en la cabecera del cultivo, para evitar aplastar el cultivo en maniobras posteriores; (2) movimiento en arco hacia el lado correspondiente de la siguiente línea de cultivo a inspeccionar para posicionarse perpendicularmente a las líneas de cultivo; (3) movimiento hacia delante en línea recta; (4) movimiento en arco marcha atrás alejándose de la línea de cultivo para posicionarse en paralelo a la dirección de las líneas de cultivo; y (5) movimiento hacia delante en línea recta para situarse en la cabecera de la siguiente línea de cultivo a inspeccionar de acuerdo con el plan.

Figura 3.33. Maniobras definidas para la conducta de cambio de línea

3.5. Resultados

Para evaluar el rendimiento y la robustez de la aproximación propuesta en la detección de la línea central del cultivo, se utilizó un conjunto de 500 imágenes adquiridas por el robot cuando trabajaba de forma teleoperada en diferentes campos de maíz y distintos días en Arganda del Rey (Madrid, España). Por tanto, las imágenes fueron capturadas en diferentes condiciones de iluminación, etapas de crecimiento del cultivo, densidades de malas hierbas y orientaciones de la cámara. La Figura 3.34 ilustra varios ejemplos de las imágenes empleadas.

(a)

(b)

(c)

Figura 3.34. (a)-(c) Ejemplos de imágenes adquiridas por la cámara del robot en diferentes campos y distintos días. (a) Campo de maíz crecido con presencia de malas hierbas (b) Campo de maíz en un estado inicial con sistema de irrigación visible (c) Final de un campo de maíz con presencia de malas hierbas

La aproximación propuesta se comparó en términos de eficacia y tiempo de procesamiento con un método de detección basado en la transformada de Hough (Hough, 1962), estrategia que se integró con éxito en estudios anteriores (Tellaeché et al., 2011). De forma resumida, la transformada de Hough aplicada a la detección de rectas trata de encontrar los parámetros ρ y θ de la ecuación normal de la recta buscada ($\rho = x \cdot \cos\theta + y \cdot \sin\theta$). Para emplearla es necesario discretizar el espacio de parámetros en una serie de celdas denominadas celdas de acumulación (Figura 3.35). Esta discretización se realiza sobre los intervalos $(\rho_{\min}, \rho_{\max})$ y $(\theta_{\min}, \theta_{\max})$, entre cuyos rangos de valores se espera que se encuentren los parámetros ρ y θ buscados.

Figura 3.35. Celdas de acumulación en el espacio ρ - θ

El siguiente paso es evaluar la ecuación de la recta para cada punto (x, y) de la imagen binaria, de tal forma que para cada par (ρ_i, θ_i) que cumpla esta ecuación, se incrementa en uno el valor de su celda. Cuando se acaba de recorrer todos los puntos, la celda que ha obtenido un mayor número de votos indica los parámetros de la recta buscada.

Ambos métodos analizaron la mitad inferior de cada imagen, es decir, 1056×352 píxeles. El tiempo de procesamiento es un aspecto muy importante en casos como éste, en el que se requiere la detección en tiempo real. La eficacia se midió en base al criterio de un experto, en el que la línea detectada se consideró correcta cuando coincidió con la dirección real de la línea de cultivo. La Tabla 3.7 muestra los resultados de procesar las 500 imágenes con ambas estrategias. El rendimiento de la estrategia propuesta supera el de la estrategia basada en la transformada de Hough en un 10%. El tiempo de procesamiento requerido por la estrategia propuesta es aproximadamente cuatro veces menor que el requerido para la estrategia basada en la transformada de Hough, lo que indica que la estrategia propuesta podría procesar 14 imágenes por segundo. En contraposición, la estrategia basada en la transformada de Hough solo puede procesar tres imágenes por segundo, que es menor que los cinco fotogramas por segundo que proporciona la cámara Canon EOS 7D (como se comentó en el apartado 3.2.2).

Tabla 3.7. Detección de la línea central del cultivo. Rendimiento de la estrategia propuesta y de la estrategia basada en la transformada de Hough

Estrategia	Eficacia (%)	Tiempo medio de procesamiento (s)
Estrategia propuesta	96,4	0,069
Estrategia basada en la transformada de Hough	88,4	0,258

Para probar las diferentes conductas desarrolladas para el robot, se estableció un entorno de prueba. Se pintaron líneas verdes en un suelo plano al aire libre para simular líneas de cultivos. Las líneas eran de 30 m de longitud y espaciadas a 70 cm de distancia, como se ilustra en la Figura 3.36 (a).

(a)

(b)

Figura 3.36. (a) Primer entorno de test (b) Imagen del campo de cultivo empleado en los experimentos

En este entorno de prueba, se realizaron varios experimentos para verificar el correcto funcionamiento de las tres conductas autónomas del robot descritas anteriormente: 1) seguimiento de la línea de cultivo, 2) detección del final de la línea y 3) cambio de línea. Durante los experimentos, el robot siguió las líneas sin cabeceos, detectó el final de las líneas, y cambió de línea, continuando la inspección, sin intervención humana. La Figura 3.37 muestra la evolución de las velocidades de traslación y de rotación del robot durante la inspección de una línea y la posición del robot con respecto a la línea (desplazamiento y ángulo) obtenida por el algoritmo de procesamiento de imagen. La Tabla 3.8 muestra la media, desviación típica, mínimo y máximo de la velocidad de traslación, velocidad de rotación, desplazamiento y ángulo. El robot ajustó su velocidad de traslación dependiendo del error en su posición; la velocidad fue mayor cuando el error en su posición fue 0 y disminuyó a medida que aumentó el error, confirmando el correcto funcionamiento del controlador borroso de la velocidad de traslación. Las variaciones en la velocidad de rotación fueron mínimas porque el error en la posición fue muy pequeño (desplazamiento y ángulo). Las ligeras correcciones a la izquierda en la velocidad de rotación (valores negativos) se debieron a la deriva del robot en su funcionamiento (cuando se teleoperaba el robot también presentaba este comportamiento), que tendía a virar hacia la derecha al avanzar. El diseño del controlador permitió que estas correcciones se hicieran suavemente e imperceptiblemente durante la navegación del robot y consiguió que se desplazara en línea recta, lo que resulta imposible cuando el robot es teleoperado.

Tabla 3.8. Resultados obtenidos en el entorno de test

Entorno de test	Media	Desviación típica	Mínimo	Máximo
Velocidad de traslación (cm/s)	28,66	0,68	26,20	30,00
Velocidad de rotación (°/s)	-0,57	0,53	-2,00	0,00
Desplazamiento (cm)	0,55	0,47	-0,78	1,88
Ángulo (°)	0,52	0,38	-0,56	1,51

Después de confirmar el buen funcionamiento del robot en el entorno de prueba, se realizaron varios experimentos en un campo real. Se trataba de un campo de cereal con un espaciado entre líneas de 70 cm, que se asemeja a un esquema de siembra de un cultivo de maíz. Las líneas no eran perfectamente rectas y se caracterizaban por una fuerte presencia de malas hierbas, como se ilustra en la Figura 3.36 (b). El robot se probó en diferentes líneas de cultivo que cubrían todo el campo. En este entorno, el robot siguió de nuevo las filas de cultivo sin pisar las plantas (Figura 3.38), detectó el final de la línea y realizó las maniobras necesarias para cambiar de línea (Figura 3.39) y continuar la inspección sin intervención humana.

Figura 3.37. Primer entorno de test: (a) Evolución de la velocidad de traslación del robot (b) Evolución de la velocidad de rotación del robot (c) Evolución del desplazamiento relativo a la línea (d) Evolución del ángulo de orientación del robot relativo a la línea

Figura 3.38. Conducta de seguimiento de línea de cultivo. Las imágenes (a)-(d) muestran una secuencia de diferentes imágenes del vídeo disponible en (GPA Group Channel, 2017c).

Figura 3.39. Secuencia de maniobras realizadas para el cambio de línea: (a) Correspondiente a la maniobra 1 en Figura 3.33, es decir, movimiento en línea recta hacia delante; (b) Maniobra 2, movimiento en arco; (c) Maniobra 3, movimiento en línea recta hacia delante; (d) Maniobra 4, movimiento en arco marcha atrás y (e) Maniobra 5, movimiento en línea recta hacia delante. El vídeo de la secuencia se puede ver en (GPA Group Channel, 2017c)

El rendimiento del método de seguimiento de la línea de cultivo fue peor en el entorno real en comparación con el entorno simulado. La Figura 3.40 muestra la evolución de las velocidades de traslación y de rotación del robot durante la inspección de una línea y la posición del robot con respecto a la línea (desplazamiento y ángulo) obtenida por el algoritmo de procesamiento de imagen. La Tabla 3.9 presenta los valores (media, desviación típica, mínimo y máximo) obtenidos para la velocidad de traslación, la velocidad de rotación, el desplazamiento y el ángulo. La diferencia en el rendimiento con respecto al entorno simulado es evidente. Los resultados fueron una consecuencia de la posición estimada del robot con respecto a la línea de cultivo (desplazamiento y ángulo). El algoritmo de procesamiento de imágenes extrajo correctamente la línea recta que definía la línea de cultivo. En contraste con el primer entorno de prueba, las líneas no eran perfectamente rectas, lo que afectó al funcionamiento del robot. Sin embargo, la diferencia en el rendimiento entre los dos entornos se debió principalmente a las diferencias entre el suelo plano del entorno de prueba y el terreno irregular del campo. Las irregularidades y rugosidades del campo, que impedían el movimiento del robot, y las características del vehículo, que no proporcionaba ningún amortiguamiento, provocaban vibraciones y oscilaciones en los ángulos de guiñada (*yaw*), cabeceo (*pitch*) y alabeo (*roll*) de la cámara durante la navegación del robot, particularmente en las zonas del terreno más irregulares, por ejemplo, con rodadas de tractores. Estos efectos incrementaron la variación en la posición estimada del robot al moverse en el campo, lo que disminuyó el buen funcionamiento del robot, ralentizando el seguimiento de las líneas e induciendo cabeceos en tramos en los que las ruedas del robot tenían una mala tracción.

Tabla 3.9. Resultados obtenidos en un campo real

Campo real	Media	Desviación típica	Mínimo	Máximo
Velocidad de traslación (cm/s)	18,87	6,16	10,04	29,94
Velocidad de rotación (°/s)	-0,14	6,40	-9,60	9,60
Desplazamiento (cm)	0,05	7,33	-14,00	16,00
Ángulo (°)	0,53	3,32	-9,00	11,00

Figura 3.40. Experimentos en un campo real: (a) Evolución de la velocidad de traslación del robot; (b) Evolución de la velocidad de rotación del robot; (c) Evolución del desplazamiento relativo a la línea y (d) Evolución del ángulo de orientación del robot relativo a la línea

Las variaciones observadas son uno de los desafíos cuando se utilizan pequeños vehículos de inspección del campo en lugar de tractores o máquinas grandes; para estos últimos, el desplazamiento es más uniforme, con menos vibraciones y variaciones en la cámara. Como se observó en los experimentos, aunque el robot pudo navegar a lo largo de las líneas sin aplastarlas, para mejorar el funcionamiento en navegación de la plataforma, se debería adoptar un vehículo mejor preparado para moverse en un campo de cultivo. Téngase en cuenta que el sistema de navegación propuesto puede adaptarse fácilmente al control de otros tipos de vehículos, ya que está basado en el comportamiento del conductor en lugar de en el modelo del vehículo.

4. CUATRIMOTO CON MOTOR DE EXPLOSIÓN

Una vez implementadas y probadas diferentes conductas para conseguir la autonomía del robot móvil en el cultivo, el siguiente paso fue trabajar sobre un vehículo más apropiado para terrenos irregulares. Así, se pensó en un vehículo disponible en la mayoría de explotaciones agrícolas, una cuatrimoto (ATV, del inglés *All Terrain Vehicle*) con motor de explosión.

Por lo tanto, se realizó la automatización de un vehículo de este tipo, que sirve para poder teleoperar el ATV, así como base para implementar las diferentes conductas autónomas presentadas anteriormente (y abierto a otras nuevas). El desarrollo realizado permite un uso dual del vehículo, pudiendo usarse tanto de forma tripulada como no tripulada.

En este capítulo se presenta el vehículo elegido y los diferentes elementos necesarios para conseguir la automatización del ATV. Tras ello se muestra el desarrollo realizado para poder teleoperar el vehículo, así como el resultado de los experimentos realizados.

4.1. Descripción del vehículo

El ATV utilizado es el Grizzly 700 de Yamaha (Figura 4.1), el ATV más grande de este fabricante. Mide 2,07 m de largo, 1,23 m de ancho, 1,25 m de altura, y pesa 274 kg. Cuenta con un potente motor de gran cilindrada, 708 cc, con un diseño de doble árbol de levas en culata (DOHC, del inglés *Double Overhead Camshaft*) y 4 válvulas. Dispone de neumáticos de 26 pulgadas lo que le aporta una gran tracción. La combinación de su motor y sus neumáticos lo hacen perfecto para moverse por todo tipo de terrenos, incluyendo campos de cultivo.

Figura 4.1. ATV Yamaha Grizzly 700

4.2. Arquitectura del sistema

En la literatura existe algún trabajo realizado para la automatización de un ATV. En (Cortner, Conrad, & BouSaba, 2012) se proponen tres sistemas de actuación: un sistema de actuación sobre la dirección, un sistema de actuación sobre el acelerador y un sistema de actuación sobre el freno. Para controlar la dirección utilizan el motor de dirección asistida, motor de corriente continua que mediante un mecanismo produce un par en el eje de dirección en el sentido en el que el conductor está realizando el giro. Los otros dos sistemas de actuación se encargan de controlar la velocidad del vehículo. La actuación sobre el acelerador la resuelven con un servomotor cuyo eje está unido al eje del acelerador. De esta manera el giro que realiza el servomotor se transmite al acelerador. El control del freno se lleva a cabo con la instalación de un mecanismo de aluminio grande que actúa sobre el freno de pie.

En la arquitectura del sistema que se ha desarrollado también se realiza la actuación sobre el acelerador del ATV, la dirección y el freno del vehículo para conseguir la automatización de la cuatrimoto. En la Figura 4.2 se presenta la arquitectura del sistema implementado.

Figura 4.2. Arquitectura del sistema

4.2.1. Ordenador de a bordo

El ordenador de a bordo utilizado es el mismo que se empleó en la plataforma detallada en el Capítulo 3, en concreto el modelo Toughbook CF-19 de Panasonic (apartado 3.2.1). El hecho de que este portátil esté preparado para su uso en exteriores, soportando polvo y vibraciones, lo hace adecuado para trabajar en el entorno agrícola encima del ATV. El ordenador es el centro de mando a alto nivel del ATV. En él se ejecuta la aplicación encargada de enviar las órdenes al microcontrolador para indicar a qué velocidad debe ir el ATV y qué dirección debe tomar. Dispone de conexión a Internet, por la que recibe la corrección RTK que a su vez redirige al receptor GPS de a bordo (descrito en el siguiente apartado) y, a su vez, lee las tramas enviadas por el receptor GPS. En modo de teleoperación, este ordenador recibe las órdenes que manda el operario a través de la interfaz de usuario que se ejecuta en su tableta.

4.2.2. Receptor GPS-RTK

Asimismo se equipó la cuatrimoto con un receptor GPS-RTK, el modelo R220 de Hemisphere, ya detallado en el apartado 3.2.3. En este caso el GPS proporciona tramas NMEA de tipo \$GPRMC, que indica la velocidad además de la posición. La velocidad suministrada por el GPS sirve como referencia para controlar la velocidad del vehículo, como se explicará posteriormente.

4.2.3. Unidad de medición inercial

Para poder controlar la dirección del ATV, se necesita información sobre ella, por lo que se instaló una IMU en el ATV. El modelo utilizado es el MPU 6050 de la marca InvenSense. Incorpora un acelerómetro y un giróscopo capaces de medir los ángulos girados en los tres ejes del espacio, en otras palabras, los ángulos de guiñada (*yaw*), cabeceo (*pitch*) y alabeo (*roll*), aunque en este caso solo se va a utilizar la información relacionada con el giro del eje de dirección del ATV. Para ello se instaló la IMU en el ATV de forma que la lectura del ángulo girado por el eje coincide con el ángulo de guiñada (*yaw*) medido por la IMU, tal como se muestra en la Figura 4.3. La IMU transmite sus

mediciones al microcontrolador utilizando el protocolo del circuito interintegrado (I²C, del inglés *Inter-Integrated Circuit*) (I2C, 2017).

Figura 4.3. Localización de la IMU en el ATV

4.2.4. Microcontrolador

El microcontrolador recibe las instrucciones del ordenador de a bordo mediante una conexión USB. En función de éstas y de las lecturas de los sensores de a bordo (receptor GPS-RTK, IMU), realiza la toma de decisiones y genera las señales necesarias destinadas a los sistemas de actuación para que el ATV siga el comportamiento establecido.

El microcontrolador utilizado es el ATmega328, un microcontrolador de la familia AVR de 8 bits del fabricante Atmel, integrado en una placa Arduino UNO (Arduino UNO, 2017). Como características destacadas resaltar que trabaja a una frecuencia de reloj de 16 MHz y posee 32 KB de memoria FLASH, 2 KB de SRAM y 1 KB de EEPROM. Permite la generación de señales moduladas por ancho de pulso (PWM, del inglés *Pulse-Width Modulation*) y la comunicación serie y a través de un bus I²C.

4.2.5. Alimentación

Los equipos del sistema se alimentan de diferentes formas. El ordenador de a bordo se alimenta con su propia batería interna. La placa Arduino UNO recibe la alimentación a través de la conexión USB con el ordenador. La IMU se alimenta a través de la placa Arduino UNO, a 5V. El resto de equipos se alimentan mediante dos baterías de 12 V. El receptor GPS-RTK se alimenta directamente desde una batería de 12 V y 4 Ah mientras que las tarjetas electrónicas que controlan las señales que llegan a los actuadores se alimentan desde una batería de 12 V y 18 Ah.

4.2.6. Sistemas de actuación

Los sistemas de actuación que traducen las señales procedentes del microcontrolador en actuaciones concretas se dividen en tarjetas de control y en los propios actuadores. Los circuitos que controlan la dirección, el acelerador y el freno se separaron en distintas tarjetas para lograr un sistema más robusto frente a errores. En otras palabras, las señales generadas por el microcontrolador están destinadas a los diferentes actuadores, pero necesitan ser adaptadas a las características concretas de cada uno de ellos. Esta adaptación se lleva a cabo en las diferentes tarjetas: la tarjeta de control del acelerador, la tarjeta de control del freno y la tarjeta de control de la dirección.

4.2.6.1. Sistema de actuación sobre el acelerador

El sistema de aceleración fue modificado mediante la instalación de un servomotor de giro limitado (180°) controlado por una señal PWM que indica el ángulo que tiene que girar el servomotor. Para su alimentación se utilizó un regulador de tensión que transforma la tensión de la batería (12 V) a la tensión nominal del servomotor (5 V). En la Figura 4.4 se muestra un esquema del sistema de actuación sobre el acelerador, mientras que en la Figura 4.5 se detalla el esquema eléctrico.

Figura 4.4. Esquema del sistema de actuación sobre el acelerador

Figura 4.5. Esquema eléctrico del sistema de actuación del acelerador

La actuación del servomotor sobre el giro del acelerador no es directa, es decir, el eje del acelerador no es solidario al del servomotor. Para ello se incorpora un mecanismo (Figura 4.6) que permite que el servomotor trabaje alejado de los límites, reduciendo el esfuerzo que tiene que hacer para efectuar los giros del acelerador. El mecanismo enrolla el cable en el carrete y este cable tira del vástago acoplado al eje del acelerador que produce un par en el eje del acelerador que hace que éste gire proporcionalmente al giro del servomotor.

Figura 4.6. Mecanismo de giro del acelerador

4.2.6.2. Sistema de actuación sobre el freno

Los vehículos destinados a la agricultura circulan a bajas velocidades por lo que la falta de aceleración detiene el vehículo en un corto intervalo de tiempo. Aún así, es necesario que la cuatrimoto disponga de un sistema de frenado que permita efectuar un frenado rápido en el caso de que aparezca un obstáculo imprevisto. Para implementar este sistema de frenado se instaló un actuador lineal que simula la fuerza que hace un conductor sobre el freno. En la Figura 4.7 se puede ver el esquema del sistema de actuación sobre el freno, y en la Figura 4.8, el esquema eléctrico.

Figura 4.7. Esquema del sistema de actuación sobre el freno

Figura 4.8. Esquema eléctrico del sistema de actuación sobre el freno

Cuando el microcontrolador decide frenar el vehículo, envía una señal a la tarjeta del freno que activa el circuito de alimentación del actuador, alimentado a 12V directamente de una de las baterías a bordo del vehículo. Para proteger al microcontrolador se incluye un optoacoplador con el propósito de aislar eléctricamente la placa Arduino UNO del resto del circuito.

El actuador (solenoides lineal) produce el movimiento lineal de una pletina que permite transformar este movimiento en el propio del freno hidráulico que viene incorporado en el ATV, en torno a su eje (Figura 4.9).

Figura 4.9. Mecanismo de actuación sobre el freno

4.2.6.3. Sistema de actuación sobre la dirección

De igual forma que en (Cortner et al., 2012), la modificación del giro del vehículo se realizó mediante la actuación directa sobre el motor de dirección asistida, que tiene conexión directa al eje de dirección (Figura 4.10).

Figura 4.10. Motor de dirección asistida

El motor de dirección asistida del vehículo tiene un sensor que mide el par ejercido sobre el eje de dirección. Esta información la envía a una unidad de control integrada en el ATV que genera las señales necesarias para controlar el motor de dirección asistida. Como en el sistema de actuación desarrollado se actúa directamente sobre el motor, no es necesario modificar el comportamiento de la unidad de control integrada del vehículo.

Para la actuación sobre dicho motor es necesario conocer sus condiciones de trabajo nominales para evitar sobrepasar los límites de funcionamiento. Con este propósito se realizaron diferentes experimentos en los que se midió la tensión de entrada del motor y su intensidad. En las pruebas se bloqueaban las ruedas delanteras impidiendo que se moviesen y se giraba el eje de dirección para que el sensor de par, que envía la información a la unidad de control, detectase que el motor tenía que iniciarse y con ello ejercer un par muy grande para contrarrestar el bloqueo de la rueda. De estos experimentos se extrajeron las siguientes condiciones de trabajo mostradas en la Tabla 4.1.

Tabla 4.1. Condiciones de trabajo del motor de dirección asistida

	Mínimo	Máximo
Intensidad (A)	-30	30
Tensión (V)	-12	12

El esquema del sistema de actuación sobre la dirección desarrollado, se ilustra en Figura 4.11. En la Figura 4.12 se muestra este esquema con los bloques detallados de la tarjeta de control y, en la Figura 4.13, su esquema eléctrico.

Figura 4.11. Esquema del sistema de actuación sobre la dirección

Figura 4.12. Esquema del sistema de actuación sobre la dirección con el detalle de los bloques que componen la tarjeta

Figura 4.13. Esquema eléctrico del sistema de actuación sobre la dirección

En el control de la dirección hay que controlar dos variables: 1) la cantidad de giro o potencia que llega al motor y 2) el sentido del giro a realizar, que se regulan con una señal PWM generada por el microcontrolador. La regulación de tensión y potencia se consigue activando el circuito cuando la señal que llega al circuito de control es superior a 0, y desactivando el circuito cuando el valor de la señal es nulo. De esta manera, con una señal PWM se activa el circuito durante el tiempo que la señal tenga un valor superior a 0, y se desactiva en caso contrario. De esta forma, si se quiere reducir la potencia que llega al motor, se disminuye el ancho del pulso de la señal PWM, mientras que, si se desea aumentar la potencia, se incrementa el ancho. La activación del circuito se realiza llevando un transistor de potencia a su zona de saturación y la desactivación se logra alcanzando su zona de corte.

Aunque el sentido de giro suele realizarse mediante un puente en H (Cortner et al., 2012), que invierte la alimentación del motor mediante la saturación o corte de transistores, dada la elevada corriente que circula por el motor, se utilizaron dos relés bipolares en una sola dirección de tiro simple bipolar (DPST, del inglés *Double Pole Single Throw*) que alimentan el motor de manera inversa, de forma que solo uno de los relés está activado cada vez. Para la activación de los relés desde el microcontrolador se incluye un circuito de activación con transistores para controlar el sentido del giro y conectar los relés a la señal con la potencia regulada mediante una señal PWM.

4.2.7. Sistema completo

Después de integrar todos los elementos en el vehículo para su automatización, el sistema completo se muestra en la Figura 4.14.

Figura 4.14. ATV con todos los elementos necesarios para su automatización

4.3. Control de la velocidad de traslación y de la dirección del ATV

Para que la automatización del vehículo sea efectiva, el ATV debe de ser capaz de circular de manera no tripulada, con la velocidad y orientación deseada. Para ello, el microcontrolador debe

realizar las actuaciones necesarias en función de las órdenes recibidas del ordenador de a bordo y de la información de los sensores. Con este fin, se diseñan e implementan dos controladores borrosos en el microcontrolador: uno para controlar la velocidad de traslación del ATV, y otro para controlar su dirección.

4.3.1. Control de velocidad de traslación

Se definen dos entradas para este controlador. La primera es el error en la velocidad de traslación (4.1), definida como la diferencia entre la velocidad a la que se desea que vaya el vehículo (velocidad de referencia) y la velocidad real del vehículo medida con el receptor GPS-RTK a bordo del ATV.

$$e_v(t) = v_{Ref}(t) - v_{GPS}(t) \quad (4.1)$$

La segunda entrada del controlador diseñado es la derivada del error en la velocidad de traslación. Como salida del controlador se elige la variación en el ángulo de giro del servomotor que actúa sobre el acelerador. Esta variación permite acelerar o desacelerar el vehículo para ajustar la velocidad a la velocidad deseada.

Al igual que en el caso del vehículo del Capítulo 3, en el controlador desarrollado se ha escogido el método de implicación de Takagi-Sugeno. Asimismo, las funciones matemáticas seleccionadas para las operaciones de AND, OR y desborrosificación han sido respectivamente las funciones: MIN, MAX y Media ponderada.

El error y la derivada del error se han caracterizado con 5 conjuntos borrosos, en concreto Negativo Grande (NG), Negativo Pequeño (NP), Cero (Z), Positivo Pequeño (PP) y Positivo Grande (PG) (Figura 4.15). Los rangos de valores de cada conjunto se han elegido con el propósito de que no haya variaciones bruscas en la velocidad del vehículo.

Al ser el método de implicación de Takagi-Sugeno, las funciones de pertenencia de la salida del controlador son de tipo *singleton* (Figura 4.16). Para seleccionar sus valores se realizaron experimentos para conocer el comportamiento del ATV ante variaciones en el ángulo girado por el servomotor, observándose que variaciones pequeñas del ángulo bastaban para variar la velocidad del vehículo.

Se definieron las 25 reglas mostradas en la Tabla 4.2, para este controlador, teniendo en cuenta todas las posibles combinaciones de las etiquetas borrosas.

Figura 4.15. Controlador de la velocidad de traslación. Conjuntos borrosos de las variables de entrada: (a) Error de velocidad y (b) Derivada del error de velocidad

Figura 4.16. Controlador de la velocidad de traslación. Conjunto borroso para la variable de salida: variación en el ángulo de giro del servomotor que actúa sobre el acelerador

Tabla 4.2. Reglas de control borroso para la velocidad de traslación

Error Derivada del error	Error				
	NG	NP	Z	PP	PG
NG	NG	NG	NP	NP	Z
NP	NG	NP	NP	Z	PP
Z	NP	NP	Z	PP	PP
PP	NP	Z	PP	PP	PG
PG	Z	PP	PP	PG	PG

4.3.2. Control de dirección

Se definen dos entradas para el controlador de dirección del vehículo. La primera entrada es el error de orientación (4.2), definido como la diferencia entre la orientación que se desea que tenga el ATV (orientación referencia) y la orientación real del vehículo estimada por la IMU de a bordo. La segunda entrada del controlador es la derivada del error de orientación.

$$e_{\theta}(t) = \theta_{Ref}(t) - \theta_{IMU}(t) \quad (4.2)$$

Como salida del controlador se elige el ancho de pulso de la señal PWM que regula la potencia que recibe el motor eléctrico de dirección asistida de la cuatrimoto. Cuanto mayor (en módulo) es el ancho del pulso, mayor es el giro efectuado por el vehículo. El sentido del giro lo marca el signo del ancho del pulso.

Como en el caso anterior, para este controlador se ha escogido el método de implicación de

Takagi-Sugeno, y las funciones matemáticas seleccionadas para las operaciones de AND, OR y desborrosificación, han sido respectivamente MIN, MAX y Media ponderada.

Se han definido 5 conjuntos borrosos para caracterizar las dos entradas del controlador: error y derivada del error, en concreto en concreto Negativo Grande (NG), Negativo Pequeño (NP), Cero (Z), Positivo Pequeño (PP) y Positivo Grande (PG) (Figura 4.17). Los rangos de valores de cada conjunto se han elegido teniendo en cuenta la precisión de la IMU de bajo coste utilizada.

(a)

(b)

Figura 4.17. Controlador de la dirección. Conjuntos borrosos de las variables de entrada: (a) Error de orientación y (b) Derivada del error de orientación

Para seleccionar los valores de las funciones de pertenencia de la variable de salida, se realizaron experimentos para conocer la variación de la orientación del ATV ante señales PWM con diferentes anchos de pulso. Tras las pruebas realizadas se definieron las funciones de pertenencia

tipo *singleton* de la salida del controlador que se muestran en la Figura 4.18.

Figura 4.18. Controlador de la dirección. Conjunto borrero para la variable de salida: ancho de pulso de la señal PWM

En la Tabla 4.3 se resumen las 25 reglas diseñadas para este controlador con todas las posibles combinaciones de los conjuntos borrosos definidos.

Tabla 4.3. Reglas de control borroso para la velocidad de traslación

Error Derivada del error	Error				
	NG	NP	Z	PP	PG
NG	NG	NG	NP	NP	Z
NP	NG	NP	NP	Z	PP
Z	NP	NP	Z	PP	PP
PP	NP	Z	PP	PP	PG
PG	Z	PP	PP	PG	PG

4.4. Teleoperación

Para conseguir teleoperar el ATV desde un ordenador portátil o tableta y probar así el funcionamiento de la automatización del ATV, se realizaron las siguientes acciones.

Se configuró el ordenador a bordo del ATV para que crease una red WiFi a la que se pudiese

conectar la tableta del operador. Se desarrolló una aplicación servidor en el ordenador de a bordo que permite conectarse al operario mediante su dispositivo remoto (tras conectarse a la red WiFi), y recibir y procesar los comandos que le manda el usuario. Para que el operario puede teleoperar el ATV se desarrolló una interfaz gráfica de usuario que permite al usuario enviar comandos al ATV de forma sencilla (Figura 4.19). La interfaz, al igual que la implementada para el robot, fue desarrollada con las librerías Qt (Qt, 2017).

Figura 4.19. Interfaz para teleoperar el ATV

El botón Connect sirve para conectar la aplicación a la aplicación servidor lanzada en el ordenador a bordo del ATV a través de la red WiFi creada por éste. Con el botón Disconnect se desconecta del servidor del ATV.

El botón de STOP es un botón de emergencia para detener instantáneamente el ATV.

Las flechas que apuntan hacia arriba y hacia abajo sirven para aumentar o disminuir la velocidad de traslación del ATV. Mientras que las flechas que señalan a derecha e izquierda sirven para variar la dirección del ATV. En la parte superior de la ventana se muestra la velocidad de traslación deseada en km/h y la dirección deseada en grados del ATV.

4.5. Resultados

Para probar el sistema de teleoperación desarrollado, así como la automatización del vehículo se realizaron varios experimentos.

Las pruebas se llevaron a cabo sobre un campo de tierra que simulaba las condiciones reales de trabajo del vehículo. En primer lugar, se realizaron varios experimentos para probar el control de velocidad desarrollado. Así, se evaluó la respuesta del ATV ante distintas velocidades de traslación

de referencia establecidas por el operario a través de su interfaz. En la Figura 4.20 se puede observar el resultado de uno de los experimentos, donde la velocidad de referencia definida era de 8 km/h. Se puede ver como el ATV va progresivamente aumentando la velocidad, teniendo un pequeño sobreimpulso hasta los 9 km/h, estabilizándose luego en los 8 km/h, y presentando unas ligeras variaciones en la velocidad alrededor de ese valor por lo accidentado e irregular del terreno.

Figura 4.20. Seguimiento de velocidad de referencia

Después se llevaron a cabo varios experimentos para comprobar el funcionamiento del control de dirección. Para ello, se midió la respuesta del ATV ante diferentes orientaciones indicadas por el operario a través de su interfaz. En la Figura 4.21 se puede ver la evolución de una de esas pruebas. Se orientó el ATV con un ángulo cercano a 0° y se introdujo en la interfaz un ángulo de referencia de -160° . Al principio, el ATV en reposo no puede ejercer un par suficiente para orientar el eje hacia el ángulo de referencia. Una vez el vehículo se encuentra en movimiento, se orienta hasta llegar al ángulo de referencia, manteniendo la orientación corrigiendo las variaciones introducidas por el terreno muy irregular que simulan una situación compleja de navegación en campo.

Figura 4.21. Seguimiento de ángulo de referencia

Para probar el sistema de actuación sobre el freno, se realizaron varios experimentos en

donde el ATV se desplazaba a 8 km/h sobre el campo de prueba, y el operario pulsaba el botón de STOP de la interfaz. Esta acción provocaba que se desactivase la actuación sobre el acelerador y que se activara el sistema de freno, deteniendo el vehículo de forma segura.

Después de verificar el buen funcionamiento de la automatización del ATV (se puede ver un vídeos de algunos experimentos en (GPA Group Channel, 2017a)), el siguiente paso era conseguir la navegación autónoma del vehículo, implementando las conductas desarrolladas en el robot comercial explicadas en el Capítulo 3. Sin embargo, el desarrollo quedó paralizado ya que surgió la posibilidad de trabajar con un nuevo vehículo, más adecuado para las tareas a realizar, como se verá en el próximo Capítulo, donde se explican las ventajas de la nueva plataforma respecto al ATV utilizado.

5. VEHÍCULO ELÉCTRICO

Tras trabajar con el robot comercial, consiguiendo desarrollar distintas conductas autónomas, y automatizar el ATV, surgió la posibilidad de trabajar con un vehículo eléctrico comercial. Las características y ventajas que ofrece, lo hacen más adecuado como plataforma para la inspección de cultivos, como veremos más adelante. Por ejemplo, frente al motor de explosión del ATV que no permite trabajar con el vehículo a velocidades muy bajas, adecuadas para el muestreo, el motor eléctrico de éste no presenta ningún problema si la plataforma se mueve en el campo a velocidades por debajo de los 3 km/h. En el apartado 5.1.1 se detallan más ventajas de este vehículo eléctrico respecto a la cuatrimoto presentada en el Capítulo 4.

En este capítulo se presentan las características del vehículo elegido y del equipamiento instalado a bordo de la plataforma. A continuación, se detalla la arquitectura del sistema y se explican las actuaciones realizadas para conseguir la automatización del vehículo. Finalmente se muestran las acciones llevadas a cabo para teleoperar la plataforma y los resultados de los experimentos iniciales realizados.

5.1. Descripción del sistema

5.1.1. Vehículo eléctrico

El vehículo eléctrico comercial elegido como plataforma móvil base del sistema de inspección es un Renault Twizy modelo Urban 80 (Figura 5.1). Se trata de un coche eléctrico compacto, con cero emisiones en uso. Tiene una longitud de 2,32 m, una anchura de 1,19 m, una altura de 1,46 m y un peso en vacío de 450 kg. El modelo Urban 80 puede alcanzar los 80 km/h. Está alimentado por un motor eléctrico de 13 kW, con una transmisión automática suave de una sola

marcha y un paquete compacto de baterías de iones de litio. Gracias a su motor eléctrico, el vehículo no vibra durante el movimiento en terreno irregular incluso a velocidades bajas como las requeridas para la adquisición de información en campo (alrededor de 3 km/h). Además, tiene autonomía suficiente para recorrer hasta un máximo de 80 km.

Figura 5.1. Renault Twizy. Modelo Urban 80

Para hacerse una idea de lo que supone un recorrido de 80 km en inspección, veamos cuantas hectáreas se cubrirían en el caso de la inspección de un cultivo leñoso inspeccionando con sensores RGB-D como el sistema que se presenta en el siguiente apartado. Si el cultivo leñoso es un viñedo, las calles entre filas de cepas son habitualmente de 2 m de ancho. Si situamos dos sensores RGB-D a ambos lados del vehículo para tomar imágenes de cada una de las filas mientras la plataforma avanza por la calle, con los 80 km cubriríamos un total de 16 ha, si no tenemos en cuenta los movimientos en cabecera para cambiar de línea. Como el tamaño medio de un viñedo en España es de 1,8 ha (MAPAMA, 2015), en el mejor de los casos, con una sola carga la plataforma podría inspeccionar alrededor de 9 viñedos. En el caso de llevar una sola cámara RGB-D se cubrirían 8 ha ya que habría que recorrer dos veces la misma calle y, por tanto, se podrían inspeccionar más de 4 viñedos de 1,8 ha con una sola carga. Aunque esta superficie se vería algo reducida si se considera también el consumo de los equipos conectados a la batería del vehículo, así como los recorridos realizados en las cabeceras. Por otra parte, el área cubierta en inspección por un UAV de pequeñas dimensiones, con una autonomía de 45 minutos, se sitúa en alrededor de 10 ha en vuelos a 50 m de altura y 17 ha cuando la altura del vuelo es de aproximadamente 100 m (Torres-Sánchez, López-Granados, De Castro, & Peña-Barragán, 2013). Ahora bien, distintos trabajos muestran (Torres-Sánchez, López-Granados, Serrano, Arquero, & Peña, 2015), (Torres-Sánchez, López-Granados, Borra-Serrano, & Peña, 2017) que si se quiere realizar un estudio de cubiertas para hacer, por ejemplo, un seguimiento de la evolución de los rodales de malas hierbas, la altura de vuelo más adecuada sería 30 m, lo que supone cubrir un área de alrededor de 4,5 ha en un solo vuelo. En el caso de la plataforma de inspección terrestre con dos cámaras, la inspección de 4,5 ha supondría un recorrido de 22,5 km, que a una velocidad de 3 km/h requeriría 7 horas y media, y a una velocidad de 8 km/h, velocidad de tratamiento, de menos de 3 horas. En definitiva, la puesta a punto de una plataforma como la propuesta en este Capítulo, podría suponer a corto plazo una alternativa o complemento al muestreo aéreo. Una estrategia combinada interesante sería la de utilizar la inspección aérea para localizar zonas potencialmente problemáticas y posteriormente realizar la

inspección terrestre de esas zonas obteniendo información más precisa del cultivo, entre otras cosas, con mayor resolución. Finalmente, el campo promedio de viñedos de 1,8 ha se recorrería, en el mejor de los casos, en 3 horas a una velocidad de 3 km/h con la plataforma de inspección recorriendo una única vez cada calle.

El coche está equipado de serie con una batería de tracción de 58 V y una batería auxiliar de 12 V, conectadas entre sí. Además, se ha integrado un inversor de onda sinusoidal pura de 1300W que se conecta a la batería auxiliar de 12 V y proporciona una corriente alterna de 230 V/50 Hz que permite enchufar algunos de los equipos de a bordo del vehículo (ordenador, sensores, etc.). Se han cubierto los bajos del vehículo con una plancha de fibra para proteger la batería de tracción y se ha integrado un mástil de perfiles de aluminio en la parte delantera para poder situar en distintas posiciones los diferentes sensores.

La plataforma de inspección (ver Figura 5.2) está integrada, además de por el vehículo, por una serie de equipos entre los que se encuentran: un ordenador compuesto por un procesador Intel Core i7-4771@3.5GHz, 16 GB de memoria RAM, y una tarjeta gráfica NVIDIA GeForce GTX 660; un router con conexión 4G que suministra de conexión a Internet al ordenador; la cámara modelo EOS 7D de Canon descrita en el apartado 3.2.2 y que se conecta al ordenador de a bordo con un puerto USB 2.0; y un receptor GPS-RTK conectado al ordenador, el modelo R220 de Hemisphere descrito en el apartado 3.2.3. El sistema lo completa un sensor de tipo RGB-D que se detalla en el siguiente apartado.

Figura 5.2. Plataforma de inspección basada en un vehículo eléctrico comercial

5.1.2. Sensor RGB-D

El sensor RGB-D integrado en esta plataforma es la Kinect v2 (Figura 5.3), sensor desarrollado por Microsoft y compuesto por una cámara RGB de 1920×1080 píxeles de resolución con un campo de visión horizontal de 84° y vertical de 54°, y una cámara de infrarrojos de 512×424 píxeles de resolución con un campo de visión horizontal de 70° y vertical de 60°. Ambas cámaras tienen una frecuencia de adquisición de hasta 30 Hz.

Figura 5.3. Sensor Kinect v2 de Microsoft

La cámara infrarroja es la que permite la construcción de información de profundidad de la escena utilizando un método de tiempo-de-vuelo (TOF). El sistema TOF modula una fuente de luz dentro de la cámara con una onda cuadrada. Utiliza un detector de fase para medir el tiempo que tarda la luz en viajar desde la fuente hasta colisionar con un objeto y volver reflejada al sensor (Figura 5.4 (a)). Calcula la distancia a partir del tiempo estimado y la velocidad de la luz en el aire: 1 cm en 33 picosegundos. En la Figura 5.4 (b) se muestra el interior del sensor Kinect v2, donde se puede ver su fuente de luz (*infrared illuminator*) y la cámara infrarroja (*infrared camera*) que capta la luz reflejada.

Figura 5.4. (a) Medida de la diferencia de tiempo entre la luz emitida y la recibida. Imagen extraída de (Sell & O'Connor, 2014) (b) Interior del sensor Kinect v2. Imagen extraída de (Ifixit, 2017)

El rango de medida de profundidad del sensor es de 0,5-4,5 m, pero en exteriores el alcance máximo es menor. Así, estudios realizados en exteriores muestran que el sensor suministra medidas válidas de profundidad hasta distancias de 1,9 m en exteriores con iluminación de día soleado. La distancia aumenta hasta alcanzar los 2,8 m con la iluminación difusa de un día nublado (Fankhauser et al., 2015).

El sensor se conecta al ordenador de a bordo mediante un conector USB 3.0.

5.2. Automatización del vehículo

Para conseguir la automatización y, en un desarrollo futuro, la navegación autónoma del

vehículo se propone la arquitectura mostrada en la Figura 5.5.

Figura 5.5. Arquitectura del sistema

El ordenador de a bordo es el responsable de dirigir la actuación del vehículo en función de la información que recibe. Puede ser información de un joystick, del receptor GPS-RTK, información visual, etc. El ordenador envía órdenes al microcontrolador que, a bajo nivel, se encarga de enviar las señales necesarias para actuar sobre el volante, el acelerador y el freno, como se verá en los siguientes apartados, y conseguir así pilotar el vehículo. El microcontrolador utilizado es el ATmega2560, un microcontrolador de la familia AVR de 8 bits del fabricante Atmel, integrado en una placa Arduino MEGA 2560. Trabaja a una frecuencia de reloj de 16 MHz y posee 256 KB de memoria FLASH, 8 KB de SRAM y 4 KB de EEPROM. Permite la generación de señales PWM y, entre otras, la comunicación serie. Se conecta al ordenador de a bordo mediante una conexión USB.

En los siguientes apartados se describen los diferentes elementos de hardware y software desarrollados a fin de automatizar el funcionamiento del vehículo. Es importante señalar que en la automatización se han respetado todos los elementos que permiten la conducción manual del vehículo. En definitiva, el objetivo es disponer de un vehículo de funcionamiento dual.

5.2.1.1. Sistema de actuación sobre la dirección

Al contrario de lo que ocurría con el ATV, el vehículo Renault Twizy no tiene motor de dirección asistida, por lo que se debe actuar sobre el eje de dirección. Midiendo con un dinamómetro la fuerza máxima a ejercer en el volante para conseguir girarlo completamente cuando el vehículo se encuentra en un campo de cultivo, se calculó el par máximo que se debe ejercer sobre el eje de dirección, siendo éste de 20 N·m. Con un valor tan elevado, se descartó la actuación directa con un motor sobre el eje de dirección, pues se requeriría un motor de grandes

dimensiones y de un precio muy elevado. Finalmente se optó por acoplar un reductor al motor y utilizar un sistema de correa de distribución para actuar sobre el eje de dirección.

Se utiliza un motor de conmutación electrónica sin escobillas (*brushless*) con sensores de efecto Hall. El motor tiene acoplado a su eje un *encoder*, un reductor planetario y una polea pequeña (20 dientes), tal como ilustra la Figura 5.6. Se monta una polea grande (72 dientes) en la barra de dirección y se conecta a la polea pequeña a través de una correa de distribución (véase Figura 5.7). Cuando el ordenador de a bordo ordena el cambio de la dirección del vehículo, envía un mensaje al microcontrolador indicando la posición del volante que desea. El microcontrolador manda una orden al controlador digital de posición del motor, Maxon Motor EPOS2, que hace que el motor gire y, por tanto, que la polea pequeña transfiera el movimiento de giro a la polea grande, a través de la correa de distribución. Al girar la polea grande, solidaria a la barra de dirección, gira el volante del vehículo a la posición deseada.

Figura 5.6. Motor, junto su reductor y *encoder*, utilizado para actuar sobre la dirección del vehículo

Figura 5.7. Sistema de correa de distribución para actuar sobre la dirección del vehículo

5.2.1.2. Sistema de actuación sobre el acelerador

El pedal del acelerador de este vehículo tiene dos potenciómetros magnéticos de diferentes valores. Al presionar el pedal, las resistencias de ambos potenciómetros varían. El coche posee, además, un controlador interno de serie, el Sevcon Gen4, al que están conectados ambos potenciómetros, y que es el que determina que el vehículo acelere más o menos según la variación en la resistencia de los potenciómetros; es decir, según la presión ejercida en el pedal. El vehículo utiliza dos potenciómetros por razones de seguridad. El controlador conoce la relación que existe entre los valores de los potenciómetros y si ésta no se cumple, se apaga el motor del vehículo, ya que alguno de los potenciómetros tiene un problema.

Para actuar sobre la aceleración del vehículo respetando el sistema de aceleración existente, se ha integrado otro pedal de aceleración, que de aquí en adelante llamaremos pedal falso, igual al montado en el coche (Figura 5.8). Este pedal se sitúa en una estructura en la parte trasera del vehículo para no entorpecer la conducción manual. La señal generada por este pedal falso se conecta al controlador interno del coche cuando el vehículo no se conduce manualmente, por lo que para conseguir que éste acelere, se debe presionar este pedal falso. De esta forma, el controlador interno interpreta que se está pisando o soltando el pedal del acelerador, modificando así la velocidad del vehículo.

Para mover el pedal se utiliza un motor paso a paso comandado por un controlador conectado al microcontrolador. Cuando el ordenador de a bordo ordena variar la aceleración para cambiar la velocidad del vehículo, envía el mensaje correspondiente al microcontrolador, y éste actúa sobre el pedal falso por medio del controlador que controla el motor. Este controlador permite resoluciones más altas que las especificadas en el tamaño del paso del motor, permitiendo pasos intermedios. De esta forma se tiene un control más fino del motor y, por tanto, del pedal falso.

Figura 5.8. Estructura del pedal falso (a) Vista lateral (b) Vista cenital

5.2.1.3. Sistema de actuación sobre el freno

Como se ha explicado, uno de los motivos de la elección de este vehículo es su capacidad para poder moverse a velocidades muy bajas (por debajo de los 3 km/h) y facilitar así la adquisición de datos por parte de los sensores. Circulando a esas velocidades, simplemente la ausencia de activación del acelerador detiene el vehículo en escaso tiempo. Sin embargo, es necesario que la plataforma tenga incorporado un sistema de freno para efectuar un frenado rápido en caso de

emergencia.

El coche no dispone de un sistema de antibloqueo de ruedas (sistema ABS, del alemán *Antiblockiersystem*) por lo que no se puede implementar ninguna señal electrónica de control para actuar sobre éste. Así, es necesario un elemento actuador para presionar el pedal de freno, a diferencia de lo que ocurría en el pedal acelerador. Se implementó una solución mecánica sobre el pedal del freno que no imposibilita la conducción manual del coche. En concreto, se colocó en la parte frontal del vehículo un servomotor de giro limitado (180°) con un carrete sobre su eje (Figura 5.9), unido al pedal del freno por un cable (Figura 5.10).

Figura 5.9. Servomotor, carrete y cable utilizado para actuar sobre el freno del vehículo

Figura 5.10. Pedal de freno unido al cable que sirve para actuar sobre él

El servomotor está conectado al microcontrolador, de forma que cuando el ordenador de a bordo decide realizar una acción de frenado, envía un mensaje al microcontrolador, el cual manda una señal PWM al servomotor para que éste gire el ángulo suficiente para que se enrolle el cable en el carrete, provocando que tire del pedal y el vehículo frene. Como se utiliza como un sistema de emergencia, la actuación sobre el freno solo tiene dos posibles estados: o desactivada, o totalmente

activada; este último implica pisar totalmente el freno.

5.2.2. Software

Para llevar a cabo el control del vehículo, se ha utilizado ROS (del inglés *Robot Operating System*) (ROS, 2017), un meta sistema operativo de código abierto mantenido por la *Open Source Robotics Foundation*. Proporciona los servicios propios de un sistema operativo incluyendo las abstracciones de hardware, control de dispositivos a bajo nivel, implementación de utilidades comunes, paso de mensajes entre procesos y gestión de paquetes. ROS está basado en una arquitectura de grafos donde el procesamiento toma lugar en los nodos, que se comunican entre sí utilizando el modelo publicador/subscriptor a través de temas.

El ordenador de a bordo es el centro de mando a alto nivel del vehículo. Es el encargado de decidir las actuaciones a realizar en función de la información que recibe. En función del tipo de control del vehículo que se vaya a efectuar (guiado por *joystick*, por información del receptor GPS-RTK, por información visual, etc.) se ejecuta un nodo de control u otro. Este nodo se suscribe a los temas correspondientes según la información que necesita para decidir cómo actuar (temas dónde publica el *joystick* si va a guiarse por el *joystick*, tema donde publica el GPS-RTK si va a ser guiado por éste, etc.), y publica en los temas */cmd/Vel*, */cmd/Pos* y */cmd/Brake*, temas a los que se suscribe el nodo que se ejecuta en el microcontrolador (*/serial_node*), encargado de controlar los diferentes actuadores (Figura 5.11). Publicando en */cmd/Vel* se actúa sobre el acelerador, en */cmd/Pos* sobre la dirección, y en */cmd/Brake* sobre el freno. El nodo del microcontrolador recibe a través de */cmd/Vel* el paso en el que se tiene que situar el motor paso a paso que actúa sobre el pedal falso del acelerador. Por medio de */cmd/Pos* se recibe el ángulo en el que se tiene que posicionar el volante. Para que éste se mueva, el nodo del microcontrolador publica en el tema */position_controller/command* al que está suscrito el nodo del controlador del motor que actúa sobre la dirección (*epos hardware*). Por último, a través de */cmd/Brake*, el nodo del microcontrolador recibe un valor verdadero o falso, en función de si se actúa o no sobre el freno.

Figura 5.11. Esquema de nodos y temas para conseguir la automatización del sistema

Con esta forma de proceder el cambio de un tipo de control a otro es inmediata, simplemente sustituyendo el nodo de control lanzado. Trabajando de esta manera, por medio de nodos y temas, es más fácil incorporar nuevas funcionalidades al vehículo (nuevos sensores, nuevas formas de control, etc) y aislar y detectar más fácilmente posibles problemas.

5.3. Teleoperación

Para probar el funcionamiento de la automatización del vehículo, se implementó una interfaz de usuario para teleoperar el coche utilizando un mando (en inglés *joystick*), de forma que las acciones realizadas sobre las palancas y botón del mando se reflejan directamente en la actuación sobre el vehículo. El movimiento de una de las palancas del mando provoca la presión sobre el pedal falso en consonancia con el movimiento recorrido por la palanca, acelerando el vehículo. El movimiento de otra palanca sirve para girar el volante del vehículo. Además, un botón del mando sirve para frenar totalmente el vehículo. Un microcontrolador, al que se conectan las palancas y el botón, lee sus posiciones y estado, publicándolos en los temas */joy/potY* (posición de la palanca para actuar sobre la aceleración), */joy/potX* (posición de la palanca para actuar sobre el volante), y */joy/switchBrake* (estado del botón para actuar sobre el freno: pulsado o sin pulsar).

Para conseguir que la actuación sobre el mando se refleje en el vehículo, se ejecuta un nodo en el ordenador de a bordo (*/joystick_node*) que se suscribe a los temas del mando. A través de éstos, recibe las posiciones de las palancas y el estado del botón, y los publica en los temas */cmd/Vel*, */cmd/Pos* y */cmd/Brake* para, así, actuar sobre el vehículo (Figura 5.12).

Figura 5.12. Esquema de nodos y temas del sistema funcionando de forma teleoperada

5.4. Resultados

Para probar las diferentes actuaciones que se han realizado en el vehículo, se subió el coche sobre unos tacos, de forma que las ruedas no tuviesen contacto con el suelo, y así poder realizar los experimentos con mayor seguridad.

En primer lugar, se llevaron a cabo pruebas publicando por separado en los temas de */cmd/Vel*, */cmd/Pos* y */cmd/Brake*, comprobando que la reacción del vehículo acelerando, girando el volante y frenando era la adecuada. Tras esto, se utilizó el mando para probar los distintos sistemas de actuación de una forma más próxima a la real. Con el vehículo aún sobre los tacos, se probaron por separado y a la vez. En la Figura 5.13 se muestra el resultado de uno de los experimentos, en el que se va aumentando paulatinamente el número de pasos del motor que mueve el pedal falso. La acción sobre el mando se publica en */cmd/Vel* y se observa como el vehículo empieza a acelerar hasta que se disminuye la presión sobre el pedal, momento en el que empieza a decelerar hasta reducir la velocidad a 0. La velocidad del vehículo se midió a partir de los datos suministrados por el bus CAN (acrónimo del inglés *Controller Area Network*) del vehículo.

Figura 5.13. Velocidad del vehículo en respuesta a la actuación sobre el pedal falso

En el sistema de actuación sobre la dirección, el rango del ángulo de posicionamiento del volante varía entre 0° y 1080° porque el volante permite 3 vueltas completas sobre su eje, siendo 0° la posición del volante en la cual las ruedas del vehículo están orientadas para lograr el máximo giro a la derecha, y 1080° es la situación similar de giro a la izquierda. En la Figura 5.14 se puede ver el resultado de uno de los experimentos sobre la actuación en la dirección. En este caso se movió la palanca del mando para cubrir todo el rango de ángulos del volante, publicando el ángulo correspondiente en */cmd/Pos*, lo que provocó que el controlador del motor del sistema de actuación sobre la dirección, moviera con precisión el volante a la posición indicada.

Figura 5.14. Ángulo de posicionamiento del volante en respuesta a la actuación sobre la dirección

Por último, se probó la actuación sobre el freno, comprobándose que, al pulsar en el botón de freno del mando, el pedal de freno bajaba totalmente, como si se pisase a fondo, provocando el frenado instantáneo y completo del vehículo.

Tras estos experimentos, se bajó el vehículo al suelo y se realizaron varios experimentos en

un circuito de prueba para verificar el correcto funcionamiento del vehículo sobre el suelo. En estos experimentos se comandó el vehículo únicamente por medio del mando, actuando sobre la dirección, aceleración y freno, para completar el recorrido sin necesidad de ninguna actuación manual por parte del operario. En la Figura 5.15 se muestra la trayectoria del vehículo durante uno de los experimentos (los datos de posición se recogieron por medio del receptor GPS-RTK del vehículo). En (GPA Group Channel, 2017b) se puede ver un vídeo con la ejecución de estas pruebas.

Figura 5.15. Recorrido del vehículo controlado por el *joystick* en un circuito de prueba

Tras toda esta experimentación, se pudo verificar el correcto funcionamiento de la automatización realizada en el vehículo eléctrico de Renault. Este desarrollo sirve como base para la implementación de conductas que permitan la navegación autónoma del vehículo, tanto guiada por la señal GPS-RTK como por información visual, en este caso localizando y siguiendo algún elemento de interés, como puede ser la línea de cultivo, al igual que la plataforma presentada en el Capítulo 3 de la presente memoria.

6. RECONSTRUCCIÓN 2D DEL ENTORNO

La generación de mapas de los cultivos es una etapa fundamental para llevar a cabo la implantación de un modelo de agricultura de precisión. La obtención de mapas precisos permite localizar con exactitud las malas hierbas dentro del cultivo, lo que resulta esencial en la planificación del tratamiento selectivo del campo, es decir, tratar sólo en las zonas donde hay presencia de malas hierbas en lugar de en todo el cultivo (Conesa-Muñoz et al., 2015). Estos mapas también son importantes para estimar la efectividad de los tratamientos de una campaña a otra.

La generación de mapas precisos mediante muestreos realizados de forma manual resulta inviable en grandes extensiones, por lo que surge la necesidad de automatizar este procedimiento. En los últimos años se han realizado trabajos para construir mapas de cultivo a partir de la información suministrada por una cámara colocada a bordo de un tractor (Sainz-Costa et al., 2011) o sobrevolando el terreno con drones equipados con cámaras (Peña et al., 2013), (Pérez-Ortiz et al., 2015). El inconveniente de utilizar tractores o vehículos pesados para este propósito es el impacto que tienen sobre los cultivos y la compactación del suelo. Mientras que el inconveniente de los drones es la altura a la que tienen que tomar las imágenes para rentabilizar su escasa autonomía, por lo que, a pesar de las cámaras de alta resolución existentes, no obtienen imágenes de tanta resolución como las que en teoría se pueden obtener desde tierra. En este punto también es importante la distinta perspectiva, que permite ver problemas que a cierta altura son más difíciles de detectar. Además, los vehículos aéreos tienen una mayor dependencia de las condiciones atmosféricas, no pudiendo volar cuando éstas son adversas (viento, lluvia). Por ello, se plantea el uso de pequeños/medianos vehículos terrestres con escaso impacto sobre el campo para la generación de mapas de cultivos.

Al montar cámaras encima de los tractores para generar mapas aparecen problemas debidos a las irregularidades del terreno, que provocan vibraciones y oscilaciones en las cámaras. Para generar mapas precisos ha sido necesario implementar métodos para estabilizar la imagen con el

objetivo de eliminar los efectos de los movimientos indeseados de la cámara (Sainz-Costa et al., 2011). En el caso de los vehículos pequeños de inspección, como el presentado en el Capítulo 3, el problema es más acusado, ya que su desplazamiento en el campo es más susceptible a las irregularidades importantes del terreno como por ejemplo las rodaduras de la maquinaria. Las oscilaciones de la cámara se producen sobre todos los ejes, afectando a los ángulos de guiñada, cabeceo y alabeo (*yaw*, *pitch* y *roll*) de la cámara durante la navegación del robot.

El objetivo del método presentado es generar un mapa de la cubierta vegetal de un cultivo sembrado con una distancia entre líneas suficiente como para que éstas sean apreciables en la imagen. El método desarrollado elimina los efectos de los movimientos no deseados de la cámara.

6.1. Generación de mapa 2D georreferenciado

El método propuesto se aplica sobre un conjunto de imágenes secuenciales que presentan cierto grado de solapamiento. Se supone que la adquisición de imágenes es con una cámara colocada en un vehículo capaz de recorrer el campo siguiendo una línea de cultivo. Algo parecido a lo que hacía el robot presentado en el Capítulo 3. Para cada imagen hay una posición geográfica asociada.

El método se compone de los siguientes pasos: 1) extracción de las rectas que definen las tres líneas de cultivo que aparecen en el centro de la imagen, 2) estabilización de la imagen, 3) obtención de imagen cenital, 4) construcción del mapa y 5) georreferenciación. En lo que sigue se explican con detalle cada uno de estos pasos.

6.1.1. Extracción de las rectas que definen las tres líneas de cultivo

En este método se trabaja con la parte central de la imagen para asegurar que aparezcan al menos tres líneas de cultivo en la región de interés. El tipo de imagen que se trata es la que se muestra en el rectángulo rojo de la Figura 6.1.

Figura 6.1. Imagen captada por la cámara. La región de interés o trabajo aparece dentro del rectángulo rojo

El procedimiento comienza con una fase de segmentación, cuyo objetivo es aislar la cubierta vegetal del resto de elementos de la imagen. Aplicando el proceso de segmentación explicado en el apartado 3.4.1.1.1, se consigue una imagen en blanco y negro (Figura 6.2 (b)) a partir de la imagen en escala de grises de la imagen RGB de entrada (Figura 6.2 (a)), en la que los píxeles blancos

representan la cubierta vegetal (cultivo y malas hierbas) y los píxeles negros representan el resto de elementos la imagen (suelo, piedras, paja, etc.).

Figura 6.2. (a) Imagen en escala de grises e (b) imagen binaria de la región de interés de la Figura 6.1

Una vez que se tiene la imagen binaria se realiza una operación de apertura, para a continuación aplicar el operador Sobel con el fin de extraer los bordes de la imagen resultante. El procedimiento es igual al descrito en el apartado 3.4.1.1.2. Tras esto, la imagen se divide en 10 franjas horizontales. Cada franja se procesa independientemente con el fin de obtener el centro de las tres líneas de cultivo. La dificultad radica en delimitar los bordes de las ventanas de búsqueda de los centros sin que una ventana contenga más de una línea. En un contexto en el que el vehículo se desplace de forma suave, es decir, sin movimientos bruscos ni vibraciones en la cámara, este problema tiene una solución más o menos sencilla. En el caso de la inspección en campos de cultivo los vaivenes del robot son constantes, lo que conlleva la necesidad de disponer de una técnica robusta que permita detectar automáticamente los límites de las ventanas de búsqueda de las tres líneas en cada franja.

El método desarrollado construye, en primer lugar, un vector que almacena en cada componente el número de píxeles blancos de cada columna de la imagen. Después, se calcula el valor máximo de este vector y aquellas componentes del vector que superan un determinado porcentaje de ese máximo se ponen a 1, mientras que el resto se ponen a 0. Este porcentaje comienza en 75% y se ajusta, si es necesario, como se explica más adelante.

A continuación, se recorre el vector de forma que cuando una componente presenta un 1, se explora el vector en un entorno de 50 componentes a la derecha de ese punto. Si en ese entorno aparece otro 1 se cambian a 1 todas las componentes del vector entre el punto inicial y el punto en el que se ha encontrado el nuevo 1. El objeto de este recorrido es obtener en el vector tres grandes bloques de unos que van a representar las zonas donde se encuentran las tres líneas de cultivo, y dos grandes bloques de ceros que son los que delimitan las zonas entre líneas.

Si no se detectan tres bloques de unos, se vuelve al primer paso, y se comienza de nuevo la búsqueda reduciendo el porcentaje sobre el valor máximo que las componentes tienen que superar para ponerse a 1. La reducción es de un 5% en cada iteración. Si después de todas las iteraciones el procedimiento no ha sido capaz de obtener los 3 bloques de unos, se establecen como bordes de las ventanas de búsqueda los bordes promedio obtenidos en las ventanas de búsqueda en las cinco imágenes inmediatamente anteriores. La ausencia de los tres bloques se produce en los casos en los que hay un exceso de mala hierba o errores en la siembra.

Los límites de estos tres bloques de unos son los bordes de las ventanas de búsqueda. Se podrían coger directamente los 6 bordes por pares, como los bordes de las ventanas de búsqueda de cada línea, pero para hacer el método más robusto ante la presencia de malas hierbas combinada con la ausencia de alguna línea de cultivo en alguna imagen por un error de siembra o por el excesivo movimiento de la cámara, se procede de la siguiente forma. En primer lugar, se busca el borde más cercano al centro de la imagen para, a continuación, buscar el otro borde de esa misma

ventana de búsqueda, que será el borde más próximo siempre que esté lo suficientemente alejado (para ello se tiene en cuenta el ancho de la ventana central en las cinco imágenes inmediatamente anteriores). Una vez se han detectado los bordes de la ventana de búsqueda de la línea central, se comprueba que los bordes de las ventanas de búsqueda de las líneas laterales están debidamente alejados de aquella (para ello se tiene en cuenta la separación promedio obtenida entre ventanas de búsqueda en las cinco imágenes inmediatamente anteriores), y que se encuentran a la izquierda y derecha de la línea central. Si esto no ocurre, los bordes de las ventanas de búsqueda de las líneas laterales se inicializan a partir de los valores de los bordes de la ventana central y la separación promedio obtenida entre ventanas de búsqueda en las cinco imágenes inmediatamente anteriores.

Una vez obtenidos los límites de las ventanas de búsqueda, se buscan los potenciales centros verticales de las tres líneas de cultivo, siendo éstos las columnas con el mayor número de píxeles blancos dentro de cada ventana de búsqueda. A partir de ahí, el algoritmo localiza los bordes que delimitan cada línea de cultivo, buscando a izquierda y derecha del centro encontrado tal y como se describió en el apartado 3.4.1.1.2, pero en este proceso el parámetro D_1 varía entre 8 y 15 y el parámetro D_2 entre 15 y 30.

Una vez detectadas las tres líneas de cultivos (Figura 6.3), la siguiente etapa consiste en extraer la línea recta que define cada una de las líneas de cultivo.

Figura 6.3. Detección de las tres líneas de cultivo en la imagen resultante de la etapa anterior

Para obtener las rectas que definen el trazado de las tres líneas de cultivo, se utiliza un procedimiento similar al explicado en el apartado 3.4.1.1.3. En este caso, se comienza con el procedimiento para obtener los límites de las tres ventanas de búsqueda de las tres líneas explicado anteriormente. A continuación, se calcula dentro de cada ventana un vector que almacena el número de píxeles blancos de cada columna. Aquellas columnas que tengan un número de píxeles blancos superior al 80% del valor máximo del vector se ponen enteras a blanco, mientras que el resto se ponen a negro. Para determinar los puntos que definen cada línea del cultivo, en cada franja, se elige el centro geométrico del bloque con el mayor número de columnas blancas. Mediante el método de mínimos cuadrados se extrae la recta que define cada línea de cultivo a partir de estos puntos (Figura 6.4).

Figura 6.4. (a) Puntos que determinan las tres líneas de cultivo de la Figura 6.3 y (b) extracción de las rectas que las definen

Para eliminar la influencia de posibles puntos incorrectos debido a la presencia de malas hierbas, después de obtener la ecuación de la recta, se mide la distancia de cada uno de los puntos a la recta obtenida. Se calcula la media y la desviación típica de estas medidas y aquellos puntos cuyas distancias estén alejadas de la media en un valor superior a la desviación típica, se eliminan. A continuación, se recalcula la recta mediante el método de mínimos cuadrados con los puntos que prevalecen.

6.1.2. Estabilización de la imagen

Para compensar, en parte, los efectos de los movimientos de la cámara en la imagen, en primer lugar, se calcula el ángulo de inclinación respecto a la vertical de la recta que define la línea central del cultivo. Con el ángulo estimado, se lleva a cabo una rotación de la imagen para que la dicha recta quede alineada con la vertical. En segundo lugar, se calcula el desplazamiento horizontal entre la recta que define la línea central del cultivo y el centro de la imagen. Tras calcularlo, se traslada horizontalmente la imagen en dicha cantidad para centrar la recta en la imagen.

6.1.3. Obtención de imagen cenital

Cuando se captura una imagen con una cámara, lo que se tiene en la imagen es una proyección 2D del mundo 3D. La formación de imágenes de una cámara convencional se puede modelar con el modelo simple de *pinhole*, que permite utilizar el modelo de proyección de perspectiva. En este modelo, los objetos tridimensionales se proyectan en una superficie bidimensional por medio de líneas rectas que pasan a través de un único punto, el punto focal, formando la imagen proyectada (Pajares & De la Cruz, 2001). Las imágenes formadas bajo este modelo invalidan el cálculo de las mediciones de distancia porque la perspectiva es una transformación no lineal. La Figura 6.5 muestra la geometría de esta proyección en perspectiva. Un punto perteneciente a una línea de cultivo en el plano horizontal se proyecta sobre el plano de imagen siguiendo una línea a través del punto focal. Otros puntos en la misma línea y en una línea de cultivo paralela, se proyectan de la misma forma. Todos estos puntos pertenecen a líneas de cultivo paralelas en el plano del campo, pero esta relación no se conserva en el plano de imagen, es decir las líneas no son paralelas debido a que la proyección de la perspectiva no es lineal.

Figura 6.5. Modelo de proyección de perspectiva

Para eliminar los efectos de la perspectiva y lograr una imagen en que las líneas aparezcan paralelas, se requiere de una transformación proyectiva u homografía (Pajares & De la Cruz, 2001), (Barnard, 1983), (Mallot, Bühlhoff, Little, & Bohrer, 1991), (Bevilacqua, Gherardi, & Carozza, 2008). Mediante el uso de coordenadas homogéneas, esta transformación proyectiva se puede expresar como una transformación lineal entre dos planos (homografía planar), a saber, el plano del campo (horizontal) y el plano de la cámara (imagen). De acuerdo con (Sainz-Costa et al., 2011), un punto (P) con coordenadas homogéneas $\mathbf{u} = (u, v, w)$ en el plano del campo (espacio de tres dimensiones) puede proyectarse en el plano de la imagen (dos dimensiones) usando la ecuación (6.1).

$$\mathbf{u}' = sH\mathbf{u} \quad (6.1)$$

donde s es un factor de escala, $\mathbf{u}'$ son las coordenadas homogéneas del punto en el plano de la imagen, $\mathbf{u}$ son las coordenadas de ese mismo punto en el plano del campo y H es la matriz de homografía de tamaño 3×3 . La determinación de H permite el cálculo de las proyecciones de los puntos de un plano a otro, o incluso la modificación de toda la imagen para obtener una vista panorámica de la escena. La matriz de homografía se puede calcular utilizando correspondencias de puntos. Se definen las correspondencias como conjuntos de n pares de puntos $(\mathbf{u}_i, \mathbf{u}'_i)$, tales que un punto $\mathbf{u}_i$ en el plano del campo se corresponde con el punto $\mathbf{u}'_i$ en el plano de la imagen. Mediante un sistema homogéneo de ecuaciones lineales (6.2) se puede obtener la matriz H y los factores de escala s_i .

$$s_i \mathbf{u}'_i = H\mathbf{u}_i \quad (i = 1, \dots, n) \quad (6.2)$$

El sistema tiene $n(d + 1)$ ecuaciones y $n + (d + 1)^2 - 1$ incógnitas. Por tanto, H se puede determinar utilizando $n = d + 2$ correspondencias de puntos siempre que no más de d de ellos sean colineales. Para imágenes 2D, esto significa que se necesitan cuatro correspondencias de puntos, de las cuales no más de dos sean colineales. Para calcular la matriz de homografía en las imágenes con las que se trabaja, en primer lugar se seleccionan cuatro puntos en estas imágenes: dos puntos de la recta que define la línea de cultivo a la derecha de la línea central (los situados en la primera y última fila de la imagen con la que se está trabajando) y dos puntos de la recta que define la línea de cultivo a la izquierda de la línea central (igualmente, los situados en la primera y última fila de la imagen con la que se está trabajando). Los puntos se muestran en amarillo en la Figura 6.6.

Figura 6.6. En amarillo, los cuatro puntos de la imagen original que se utilizan para realizar la transformación proyectiva

Como puntos correspondientes en la imagen transformada se eligen los vértices de un rectángulo de unas dimensiones concretas. La anchura de este rectángulo corresponde a dos veces el espaciado entre líneas de cultivo (0,7 m en cultivos de maíz), y la altura se determina midiendo un objeto conocido.

Como ejemplo, para los experimentos realizados, se construyó una rejilla cuadriculada en un suelo plano (Figura 6.7) y se situó al robot descrito en el Capítulo 3, utilizado en los experimentos, enfrente de ella con la cámara orientada en la misma posición que en su recorrido por el campo. Se capturó una imagen de la rejilla y se pudo medir que la imagen de trabajo (franja central de la imagen) abarcaba 2 m. Por tanto, la altura del rectángulo se fijó en 2 m. De esta forma, como se desea que cada píxel equivalga a 1 cm², la imagen trasformada tendrá una resolución de 140×200 píxeles.

Figura 6.7. Rejilla cuadriculada construida

Después de calcular la matriz de homografía, se aplica la transformación proyectiva a cada píxel de la imagen, obteniéndose una imagen cenital del campo de cultivo en la que las líneas de cultivo paralelas en el mundo real se muestran paralelas en la imagen. La Figura 6.8 muestra el resultado de aplicar la transformación proyectiva a la imagen de la Figura 6.3.

Figura 6.8. Imagen cenital obtenida después de aplicar la transformación proyectiva a la imagen de la Figura 6.3

6.1.4. Construcción del mapa

Una vez se tiene la imagen cenital, el objetivo es construir un mapa del campo de cultivo a partir de la secuencia de imágenes capturadas por el vehículo en su recorrido. Para ello, se debe

integrar la información contenida en cada imagen segmentada cenital en un mapa completo de toda la longitud del campo. Este mapa consiste en una matriz de unas determinadas dimensiones, en la que cada una de las componentes representa una zona del campo de cultivo real de 1 cm², que de ahora en adelante llamaremos celda. Los valores de cada componente de la matriz se estiman en función del número de veces que la celda correspondiente tiene cubierta vegetal, es decir, cuando se encuentra un pixel blanco en la imagen segmentada y transformada, el elemento de la matriz correspondiente a esa posición de campo (celda) se incrementa en una unidad. Valores más altos corresponden a aquellas celdas donde se encuentra cubierta vegetal en un número mayor de imágenes. Posteriormente se aplica un umbral para conservar solo aquellas celdas de la matriz en las que la vegetación está definitivamente presente. Para eliminar falsa vegetación en el mapa debido a errores de segmentación en algunas imágenes, se selecciona un umbral correspondiente al 25% del valor máximo. Por lo tanto, todas aquellas celdas por debajo de ese valor no se consideran en la matriz definitiva. Para una mejor visualización de la densidad de vegetación, la matriz puede dar lugar a una imagen en escala de grises en la que los valores más altos son más claros (blancos) y los píxeles grises o negros representan valores más bajos.

6.1.5. Georreferenciación

Mientras el vehículo navega siguiendo la línea de cultivo va captando imágenes. Para conocer la correspondencia entre la información de la imagen y las celdas que representan en el mapa se dispone de la localización geográfica asociada a cada imagen. De esta forma, se calcula la distancia que el vehículo se ha desplazado entre imagen e imagen y por tanto las celdas que ha avanzado en el mapa. La construcción del mapa se realiza en coordenadas relativas a la celda origen y avanzando hacia delante por sencillez. Esto nos da un mapa extendido verticalmente con coordenadas relativas a la celda inicial. Para darle a cada celda su posición geográfica real se procede de la siguiente forma. En primer lugar, se mide experimentalmente en el punto inicial del recorrido, la distancia de la cámara (la antena está situada en el mismo plano vertical) al punto físico delante de ella que aparece en la primera fila de píxeles de la imagen con que se trabaja, en otras palabras, la franja central de la imagen, como se comentó anteriormente. En segundo lugar, una vez el vehículo ha finalizado su recorrido siguiendo una línea de cultivo, se trabaja con todas las ubicaciones geográficas asociadas a las imágenes adquiridas a lo largo del recorrido de la plataforma. Para mejorar la reconstrucción del mapa y mitigar los vaivenes de la antena durante el avance del vehículo debido a las irregularidades del terreno, se calcula por el método de mínimos cuadrados la recta que mejor se ajusta a todas las localizaciones recogidas durante el recorrido. Una vez obtenida esta recta, conocida la posición geográfica inicial de la cámara y conocida la distancia de la cámara a la primera fila de píxeles que aparece en el área de trabajo de la imagen (franja central), es inmediato calcular la localización geográfica del pixel central inferior del área de trabajo de la imagen, que es la posición de la celda origen del mapa. Para ello simplemente hay que desplazarse sobre la recta calculada la distancia medida desde la posición geográfica inicial de la cámara.

Como el mapa de celdas se construye en vertical, pero la recta obtenida no tiene por qué serlo, se calcula el ángulo de inclinación de esta recta. De esta forma, se aplica a todo el mapa una rotación del ángulo obtenido respecto a la coordenada inicial. Por último, se aplica una traslación a todas las coordenadas igual a la posición geográfica inicial de la cámara, ya que todas están referenciadas respecto al (0, 0). De esta forma se obtiene el mapa con las coordenadas geográficas reales.

6.2. Resultados

Para probar el método desarrollado se realizaron varios experimentos en un campo real de maíz en Arganda del Rey (Madrid, España). La siembra se realizó con cuidado de que el cultivo quedase con las líneas rectas, paralelas y con calles entre líneas de 70 cm de ancho. En el momento de los experimentos, el maíz estaba en una fase media de crecimiento, más de 8 hojas.

Las pruebas se llevaron a cabo con el robot descrito en el Capítulo 3. La cámara se coloca a 80 cm de altura con un ángulo de inclinación de cabeceo (*pitch*) de 18°. La antena del receptor GPS se coloca en la misma vertical que la cámara, y el receptor recibe continuamente las correcciones RTK desde el ordenador, por lo que se conoce con precisión (error horizontal de 1,5 cm) la posición de la cámara durante el recorrido del vehículo. Se desarrolló un programa que asocia a cada imagen captada por la cámara, la posición geográfica de la cámara en el momento de la captura.

En el experimento cuyos resultados se muestran, se realizó el recorrido de una línea de cultivo de 60 m con presencia de rodales de malas hierbas y posteriormente se generó el mapa georreferenciado de esta línea.

Para poder georreferenciar correctamente el mapa, con el robot parado en su posición inicial y antes de comenzar el recorrido, se midió la distancia de la cámara al punto que aparecía en la primera fila de píxeles de la imagen recogida en ese momento, siendo ésta distancia de 1,70 m.

Como ya se comentó en el Capítulo 3, el robot tenía dificultades para desplazarse en terrenos muy irregulares. En la Figura 6.9 se puede apreciar la presencia de la rodada de un tractor en uno de los lados de la línea que el robot muestreaba y sobre la que construyó el mapa. Esta rodada provocó que el vehículo fuese muy inclinado hacia un lado durante todo el recorrido. La inclinación como cabía esperar también se evidenciaba en las imágenes adquiridas, tal como se puede ver en la Figura 6.9, donde la línea del horizonte aparece claramente inclinada.

Figura 6.9. Imagen captada por la cámara, donde se aprecia la rodada provocada por un tractor en la calle de la derecha. También se observa que la imagen está inclinada

Esta circunstancia añadida a que el robot se desplazaba con más dificultad en determinadas zonas más irregulares, provocó continuas variaciones en los ángulos de guiñada, cabeceo y alabeo entre imagen e imagen. En la Figura 6.10 se muestra una secuencia de imágenes donde se pueden apreciar estas variaciones.

Figura 6.10. Secuencia de imágenes adquiridas por la cámara donde se pueden apreciar las bruscas modificaciones en la imagen debidas a las variaciones en la orientación de la cámara

Para constatar los movimientos de la cámara y las dificultades del robot para desplazarse en línea recta de forma uniforme, en la Figura 6.11 (a) se representa el desplazamiento entre el centro de la imagen y el centro de la línea central de cultivo para cada una de las 525 imágenes adquiridas a lo largo del recorrido, y en la Figura 6.11 (b) el ángulo entre la orientación del robot y dicha línea central. Estos valores se calculan con el algoritmo desarrollado, tal y como se explica en el apartado 6.1.2. Los valores positivos corresponden a desplazamientos o ángulos a la derecha del centro de la imagen, mientras que los negativos tienen que ver con movimientos hacia la izquierda.

Figura 6.11. (a) Desplazamientos y (b) ángulos medidos durante el recorrido del robot

La Tabla 6.1 muestra las medias, desviaciones típicas, valores mínimos y máximos del desplazamiento y el ángulo en toda la secuencia de imágenes.

Tabla 6.1. Medidas obtenidas a partir de las imágenes durante el recorrido del robot

	Media	Desviación típica	Mínimo	Máximo
Desplazamiento (píxeles)	-9,07	40,18	-98,00	93,00
Ángulo (°)	0,54	6,39	-19,91	31,51

Analizando las gráficas de la Figura 6.11 y la Tabla 6.1 se pueden apreciar las constantes variaciones a lo largo del recorrido del robot, así como la magnitud de las mismas. Para estimar mejor la dimensión del error en el desplazamiento, hay que destacar que la distancia entre líneas de cultivo en la parte inferior de la franja central de la imagen (donde se mide el desplazamiento) es aproximadamente de 300 píxeles en estas imágenes. Para que el mapa generado por el algoritmo desarrollado sea correcto debe mitigar estos efectos producidos por los movimientos no uniformes del robot y las variaciones en los ángulos de guiñada, cabeceo y alabeo de la cámara, y conseguir que la línea central que se ha seguido aparezca centrada y recta en el mapa generado. En la Figura 6.12 se muestra el mapa construido por el algoritmo a partir de las 525 imágenes adquiridas, donde se aprecia como esas variaciones se han corregido, permaneciendo la línea recta y centrada en la imagen.

Figura 6.12. Mapa construido de la línea de cultivo recorrida

En la Figura 6.13 se muestra una ampliación de una zona del mapa de la Figura 6.12 en la que se puede observar un rodal de mala hierba. En la imagen de la Figura 6.13 (a) se ve el fotograma original donde también se observa la infestación.

Figura 6.13. (a) Imagen adquirida durante el recorrido del robot en la que aparece un rodal de mala hierba que se ha señalado en rojo (b) Zona del mapa correspondiente a esa imagen, donde se señala en rojo el rodal de mala hierba

Con los resultados obtenidos se puede verificar que el algoritmo desarrollado es capaz de generar correctamente un mapa 2D de líneas de cultivo a partir de las imágenes georreferenciadas capturadas durante el recorrido del vehículo, siempre que las líneas estén rectas y sean paralelas (siembra con sembradora de precisión) y se trate de un cultivo con un cierto espacio entre líneas. Además, se ha comprobado que el método implementado es robusto frente a los movimientos no uniformes de la cámara y el robot. Cabe esperar que el método dé mejores resultados con imágenes tomadas desde vehículos más grandes como el ATV y el vehículo eléctrico presentados en los Capítulos 4 y 5 respectivamente, ya que los desplazamientos en ese caso serán más uniformes.

7. RECONSTRUCCIÓN 3D DEL ENTORNO

La reconstrucción 3D de cultivos leñosos mediante métodos no destructivos es de gran valor para los procesos de toma de decisiones. El uso de sensores para la caracterización de los cultivos conduce a un mejor conocimiento de los procesos involucrados en el desarrollo del árbol durante todo el ciclo de vida. La utilización de la información extraída de las reconstrucciones 3D puede mejorar las decisiones que se toman para la gestión del cultivo y contribuir a crear nuevos protocolos para mejorar la rentabilidad y salud de las plantas de cultivo.

En este capítulo se presenta el método desarrollado para conseguir la reconstrucción 3D de cultivos leñosos, así como la generación de mapas de diferentes parámetros de interés como el volumen, la altura y la anchura del cultivo calculados a partir de la información obtenida de la reconstrucción 3D.

7.1. Reconstrucción 3D

Si bien la reconstrucción 3D es una línea de investigación con numerosos e importantes trabajos en visión por computador, en los últimos años ha aparecido un tipo de cámaras con buenas prestaciones y bajo coste, como los sensores Kinect de Microsoft y los sensores Xtion de Asus, que proporcionan información de profundidad o distancia a los objetos más próximos de la escena y que, con ello, han abierto nuevas posibilidades en la reconstrucción 3D. Varias de las investigaciones recientes se han dirigido a conseguir la reconstrucción 3D de la escena a partir de las imágenes de profundidad suministradas por estos nuevos sensores. Así se han desarrollado diferentes técnicas que emplean distintos tipos de estructuras de datos aceleradas mediante hardware gráfico para combinar imágenes de profundidad consecutivas y con cierto grado de solapamiento. Cada una con sus particulares ventajas e inconvenientes en términos de velocidad,

escala y calidad de la reconstrucción.

Algunos métodos utilizan una estructura de vóxeles (ver concepto de vóxel en el apartado 7.1.1.1) para almacenar la información de los sensores 3D (Hilton, Stoddart, Illingworth, & Windeatt, 1996), (Curless & Levoy, 1996), (Wheeler, Sato, & Ikeuchi, 1998). Un ejemplo bien conocido es el método de (Curless & Levoy, 1996) que genera reconstrucciones 3D de alta calidad (Zhou & Koltun, 2013), y que adoptó *KinectFusion* (Newcombe et al., 2011), (Izadi et al., 2011), método de reconstrucción 3D incluido por Microsoft en su kit de desarrollo de software *Kinect for Windows Software Development Kit 2.0* (Microsoft, 2017). Aunque la reconstrucción obtenida es de gran calidad, el método presenta importantes limitaciones, por ejemplo, el uso de una rejilla regular de vóxeles implica un gran espacio en memoria, pues se representan densamente tanto el espacio vacío como las superficies a reconstruir; la consecuencia es que la reconstrucción de grandes escenarios compromete la calidad del resultado. Así *KinectFusion* restringe la reconstrucción a un volumen de 8 metros cúbicos. Esto justifica la aparición de variantes del método que permiten reconstrucciones de volúmenes más grandes usando estructuras de vóxeles (Steinbrucker, Kerl, & Cremers, 2013), (Whelan et al., 2012), (Nießner, Zollhöfer, Izadi, & Stamminger, 2013). Otras estrategias proponen la utilización de estructuras jerárquicas de datos que subdividen el espacio eficazmente aunque, a pesar de la clara división de los datos, es difícil llevar a cabo eficientemente la reconstrucción en paralelo dada la complejidad computacional añadida que conlleva (Zeng, Zhao, Zheng, & Liu, 2013), (J. Chen, Bautembach, & Izadi, 2013).

Por esta razón y tras estudiar diferentes métodos de reconstrucción 3D ((Chen et al., 2013), (Nießner et al., 2013), (Steinbrucker et al., 2013), (Whelan et al., 2012)), se optó por basar la reconstrucción 3D en el algoritmo descrito en (Nießner et al., 2013) que proporciona buenos resultados en la reconstrucción de grandes áreas a partir de la información directamente suministrada por el sensor Kinect de Microsoft. El algoritmo se ha implementado en C++ y CUDA (Nvidia, 2017) para sacar el máximo rendimiento a la potencia de las Unidades de Procesamiento Gráfico (GPU, del inglés *Graphics Processor Unit*) de las tarjetas gráficas existentes en el mercado.

7.1.1. Algoritmo de reconstrucción 3D

El procedimiento utilizado (Nießner et al., 2013) extiende el método desarrollado por (Curless & Levoy, 1996) para reconstruir con alta calidad superficies de gran tamaño, mediante la fusión incremental de información de profundidad. El método, que aborda eficientemente la escalabilidad de la reconstrucción, el principal inconveniente de la aproximación de (Curless & Levoy, 1996), no requiere ni una rejilla de vóxeles restringida en memoria ni la sobrecarga computacional de una estructura jerárquica de datos. Se basa en una sencilla técnica de *hashing* espacial, eficiente en memoria y velocidad, que comprime el espacio y permite la fusión de los datos referentes a la superficie a reconstruir, que sólo se almacenan en los vóxeles donde se observan mediciones.

7.1.1.1. Representación y almacenamiento de la información

Para representar el mundo físico tridimensional, se divide el espacio en una rejilla uniforme de espacios discretos llamados vóxeles (Figura 7.1). Cuanto menor sea el tamaño del vóxel, mayor resolución tendrá el objeto 3D que se represente, y, por tanto, será más fiel a la realidad.

Figura 7.1. Aspecto de una rejilla de vóxeles

En cada vóxel se almacena el valor de una distancia con signo (SDF, del inglés *Signed Distance Function*), un valor de color RGB y un peso. El valor SDF determina la distancia de ese vóxel a la superficie del objeto más cercano, siendo un valor positivo si se encuentra fuera del objeto, cero si se encuentra en la superficie del objeto y negativo si está dentro del objeto, tal como se muestra en la Figura 7.2.

Figura 7.2. Ejemplo de valores SDF

Para reducir el coste computacional y lidiar con el movimiento del sensor y el ruido de éste, (Curless & Levoy, 1996) introdujeron la noción de SDF truncado (TSDF) que sólo almacena la distancia con signo en una región alrededor de la superficie observada. El tamaño de esta región se puede adaptar teniendo en cuenta el ruido del sensor, que puede ser modelado como un ruido gaussiano con una varianza basada en la profundidad (Chang, Chatterjee, & Kube, 1994), (Nguyen, Izadi, & Lovell, 2012). Como consecuencia, los vóxeles alrededor de la superficie, pero fuera de la región de truncamiento, se marcan explícitamente como espacio libre y no son asignados en memoria. De esta forma, se elimina la necesidad de tener una rejilla de vóxeles regular completa almacenada en memoria, con las ventajas computacionales que eso supone. Para explotar este aspecto, en el procedimiento implementado se recurre al uso de una tabla *hash* para almacenar los vóxeles. Concretamente, para el diseño de esta estructura de datos, se extendió el esquema *hash* presentado en (Teschner, Heidelberger, Müller, Pomerantes, & Gross, 2003) por su eficiencia en términos de velocidad, calidad y escalabilidad.

La tabla *hash* utilizada almacena bloques de vóxeles, compuestos por 8^3 vóxeles vecinos. Cada entrada ocupada de la tabla *hash* contiene un puntero a un bloque de vóxeles almacenado en

memoria. La tabla *hash* no está estructurada, es decir los bloques de vóxeles vecinos no se almacenan espacialmente, sino que pueden estar en diferentes partes de la tabla *hash*. La función *hash* permite una búsqueda eficiente de bloques de vóxeles en la tabla usando las coordenadas (x, y, z) de la escena.

7.1.1.2. Integración de la información nueva

Dada una nueva imagen de profundidad de entrada y conocida la posición de la cámara, se utiliza la técnica de *raycasting* (Roth, 1982) para proyectar un rayo desde el foco de la cámara por cada pixel de la imagen de profundidad de entrada, para determinar los vóxeles en el mundo 3D que se cruzan con cada rayo (Figura 7.3). De esta forma, se determinan los vóxeles de la rejilla relacionados con la información de profundidad.

Figura 7.3. La técnica *raycasting*

La información nueva se integra en la tabla *hash* en forma de nuevos vóxeles, mientras que para la información coincidente con vóxeles antiguos se actualizan los valores TSDF, los pesos y los valores RGB asociados a estos vóxeles. Los valores de distancia se integran usando una media móvil (7.1) como en (Curless & Levoy, 1996), mientras que los pesos se actualizan según la función (7.2).

$$d_i = \frac{w_{i-1}d_{i-1} + \delta_{w_i}m}{w_{i-1} + \delta_{w_i}} \quad (7.1)$$

$$w_i = \min(w_{i-1} + \delta_{w_i}, 255) \quad (7.2)$$

donde d_{i-1} es la distancia anterior almacenada en el vóxel, m es la nueva información de distancia que se desea fusionar con la información antigua, y d_i la distancia resultante que se almacena en el vóxel. Por su parte, en la función (7.2), w_{i-1} es el peso anterior almacenado en el vóxel, y w_i es el nuevo peso que se almacena en el vóxel. El término δ_{w_i} se utiliza para incorporar las características de ruido del sensor. Así, se da más peso a mediciones de profundidad más cercanas para las que se supone menor ruido. Respecto a los valores RGB de los vóxeles, se actualizan de acuerdo con una media móvil exponencial, dando más peso a los valores más recientes.

Cada vez que se integra información nueva, se utiliza la técnica de *raycasting* para extraer la superficie 3D de la escena que aparece ante la cámara. Esta información servirá como referencia para obtener la posición de la cámara cuando llegue la siguiente imagen de entrada, como se

explicará en el siguiente apartado. Tal y como se comentó anteriormente, se proyectan rayos desde el foco de la cámara a través de todos los píxeles del plano imagen situado entre la cámara y la superficie que se desea extraer. A lo largo de cada rayo se evalúan los valores TSDF de los vóxeles por los que pasa el rayo. Un 0 en el valor TSDF o un cambio de signo en el valor TSDF durante el recorrido del rayo por los vóxeles, significa que se ha encontrado un punto de la superficie, aunque puede que no haya un vóxel exactamente sobre la superficie del objeto (valor TSDF igual a 0), ya que depende de la resolución de la rejilla, por eso también se añade la condición de que las transiciones de cambio de signo en los valores TSDF de dos vóxeles consecutivos tienen que indicar la presencia de la superficie del objeto.

7.1.1.3. Seguimiento de la cámara

Una vez que se ha extraído la superficie de la escena mediante la técnica de *raycasting*, esta información se utiliza para estimar la posición y orientación de la cámara (6 grados de libertad) cuando llega una nueva imagen de entrada (Newcombe et al., 2011). Estimar la posición y orientación comparando la información de la nueva imagen de entrada con la superficie de la escena generada hasta ese momento, permite mitigar algunos de los problemas de deriva y conseguir trayectorias de cámara más regulares. Para estimar la posición y orientación de la cámara se utiliza una variante del algoritmo ICP (del inglés *Iterative Closest Point*) (Chen & Medioni, 1992), que consiste en encontrar la matriz de transformación, M , que alinea con el menor error posible la superficie generada mediante *raycasting* a partir de la información de la imagen de entrada (origen) con la superficie de la escena generada hasta ese momento (destino). Para cada punto en la superficie origen se escoge como correspondencia el punto más cercano en la superficie destino (Besl & McKay, 1992). El objetivo es minimizar la suma de las distancias al cuadrado entre cada punto origen y el plano tangente en su correspondiente punto destino.

La transformación M se obtiene de forma iterativa, aplicando en cada iteración una nueva transformación basada en la transformación calculada en la iteración anterior. Si el error es menor que el valor umbral establecido, entonces el algoritmo se detiene y la transformación encontrada es la solución al problema. Por otro lado, si el error es mayor que el valor umbral establecido, el algoritmo continúa y calcula la nueva matriz de transformación a aplicar en la siguiente iteración. Eligiendo una buena transformación inicial se favorece no caer en óptimos locales y se disminuye el número de iteraciones necesarias para encontrar la solución. Como este algoritmo se ha implementado para manejar la información suministrada por un sensor Kinect v2 embarcado en un vehículo que se mueve despacio siguiendo una trayectoria recta, se elige como transformación inicial la transformación solución obtenida para la imagen anterior.

Si $s_i = (s_{ix}, s_{iy}, s_{iz}, 1)^T$ es un punto origen, $d_i = (d_{ix}, d_{iy}, d_{iz}, 1)^T$ es el punto destino correspondiente, y $n_i = (n_{ix}, n_{iy}, n_{iz}, 1)^T$ es el vector unitario normal en d_i (ver Figura 7.4), entonces el objetivo cada vez que se ejecuta el ICP es encontrar la matriz $M_{\text{óptima}}$ (7.3)

$$M_{\text{óptima}} = \arg \min_M \sum_i ((M \cdot s_i - d_i) \cdot n_i)^2 \quad (7.3)$$

Figura 7.4. Error entre dos superficies según (Low, 2004)

Como la estructura de datos utilizada también almacena los datos RGB asociados, se incorpora un factor de ponderación en la métrica del error basado en la consistencia del color entre los valores RGB en los puntos origen y destino (Johnson & Kang, 1999). Si $c_{s_i} = (r_{s_i}, g_{s_i}, b_{s_i}, 1)^T$ representa las componentes de color RGB en el punto s_i , $c_{d_i} = (r_{d_i}, g_{d_i}, b_{d_i}, 1)^T$ representa las componentes de color RGB en el punto d_i , y $\alpha = (\alpha_1, \alpha_2, \alpha_3, 1)^T$ son los coeficientes de ponderación que escalan la importancia del color con respecto a la forma, la ecuación (7.3) se puede reescribir como la ecuación (7.4).

$$M_{\text{óptima}} = \arg \min_M \sum_i [((M \cdot s_i - d_i) \cdot n_i)^2 + \alpha \cdot (c_{s_i} - c_{d_i})^2] \quad (7.4)$$

donde M está compuesta por una matriz de rotación $R(\alpha, \beta, \gamma)$ y una matriz de traslación $T(t_x, t_y, t_z)$, tal como se muestra en (7.5).

$$M = T(t_x, t_y, t_z) \cdot R(\alpha, \beta, \gamma) \quad (7.5)$$

donde la matriz de traslación viene dada por la expresión (7.6).

$$T(t_x, t_y, t_z) = \begin{pmatrix} 1 & 0 & 0 & t_x \\ 0 & 1 & 0 & t_y \\ 0 & 0 & 1 & t_z \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (7.6)$$

y la de rotación por la expresión (7.7).

$$\begin{aligned}
R(\alpha, \beta, \gamma) &= R_z(\gamma) \cdot R_y(\beta) \cdot R_x(\alpha) \\
&= \begin{pmatrix} r_{11} & r_{12} & r_{13} & 0 \\ r_{21} & r_{22} & r_{23} & 0 \\ r_{31} & r_{32} & r_{33} & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (7.7)
\end{aligned}$$

con

$$\begin{aligned}
r_{11} &= \cos \alpha \cos \beta \\
r_{12} &= -\sin \gamma \cos \alpha + \cos \gamma \sin \beta \sin \alpha \\
r_{13} &= \sin \gamma \sin \alpha + \cos \gamma \sin \beta \cos \alpha \\
r_{21} &= \sin \gamma \cos \beta \\
r_{22} &= \cos \gamma \cos \alpha + \sin \gamma \sin \beta \sin \alpha \\
r_{23} &= -\cos \gamma \sin \alpha + \sin \gamma \sin \beta \cos \alpha \\
r_{31} &= -\sin \beta \\
r_{32} &= \cos \beta \sin \alpha \\
r_{33} &= \cos \beta \cos \alpha
\end{aligned}$$

$R_x(\alpha)$, $R_y(\beta)$ y $R_z(\gamma)$ representan rotaciones de α , β y γ en radianes sobre los ejes X, Y y Z, respectivamente.

La ecuación (7.4) es esencialmente un problema de optimización de mínimos cuadrados, y para resolverlo se requiere la determinación de seis parámetros: α , β , γ , t_x , t_y y t_z . Sin embargo, como α , β y γ son argumentos de funciones trigonométricas no lineales, se convierte en un problema de mínimos cuadrados no lineal, por lo que no se pueden aplicar técnicas lineales eficientes para obtener la solución.

La solución se obtiene realizando una aproximación lineal para convertir el problema no lineal en un problema lineal de mínimos cuadrados (Low, 2004). Debido a que la tasa de imágenes por segundo suministrada por el sensor es muy grande (hasta 30 imágenes por segundo), la variación en la rotación de la cámara entre imágenes es pequeña. Cuando un ángulo $\theta \approx 0$, se puede aproximar $\sin \theta \approx \theta$ y $\cos \theta \approx 1$. Por tanto, como $\alpha, \beta, \gamma \approx 0$, se puede reescribir la ecuación (7.7) dando lugar a la ecuación (7.8) y a la nueva expresión (7.9) de la matriz M .

$$\begin{aligned}
R(\alpha, \beta, \gamma) &= \begin{pmatrix} 1 & \alpha\beta - \gamma & \alpha\gamma + \beta & 0 \\ \gamma & \alpha\beta\gamma + 1 & \beta\gamma - \alpha & 0 \\ -\beta & \alpha & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \\
&= \begin{pmatrix} 1 & -\gamma & \beta & 0 \\ \gamma & 1 & -\alpha & 0 \\ -\beta & \alpha & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (7.8)
\end{aligned}$$

$$M = T(t_x, t_y, t_z) \cdot R(\alpha, \beta, \gamma)$$

$$= \begin{pmatrix} 1 & -\gamma & \beta & t_x \\ \gamma & 1 & -\alpha & t_y \\ -\beta & \alpha & 1 & t_z \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (7.9)$$

La ecuación (7.4) para obtener la transformación óptima, se puede poner en la forma (7.10).

$$\min_M \sum_i [((M \cdot s_i - d_i) \cdot n_i)^2 + \alpha \cdot (c_{s_i} - c_{d_i})^2] = \min_x |Ax - b|^2 \quad (7.10)$$

Por lo que, se puede obtener $M_{\text{óptima}}$ resolviendo la ecuación (7.11).

$$x_{\text{óptima}} = \arg \min_x |Ax - b|^2 \quad (7.11)$$

Se trata de un problema lineal estándar de mínimos cuadrados que se puede resolver usando la descomposición en valores singulares (SVD, del inglés *Singular Value Decomposition* propuesta en (Press, Flannery, Teukolsky, Vetterling, & Kramer, 1987).

7.1.2. Generación de representación 3D

Una vez terminado el proceso de captura de información, el siguiente paso es volcar toda la información de la rejilla de vóxeles generada a una malla triangular que represente la superficie 3D de toda la escena para poder visualizarla y almacenar la información de una forma en la que se pueda trabajar con ella más fácilmente. Para ello se utiliza el algoritmo *Marching Cubes* (Lorensen & Cline, 1987), que a partir de los vóxeles y la información TSDF contenida, extrae la superficie representada como una malla triangular (Figura 7.5).

Figura 7.5. Entrada y salida del algoritmo Marching Cubes

A partir de la rejilla de vóxeles obtenida como salida del algoritmo implementado, se forman cubos constituidos por $2 \times 2 \times 2$ vóxeles vecinos. Cada cubo está formado por 8 vóxeles y las 12 aristas que los unen. El algoritmo *Marching Cubes* crea un vértice por cada arista en que exista un cambio de signo en los valores TSDF de los vóxeles que une la arista (esto quiere decir que hay una superficie que la intersecta, se pasa de un vóxel exterior a un vóxel interior). Por tanto, hay 256 (2^8) posibles topologías dentro del cubo. Atendiendo a la simetría existente, las configuraciones iniciales se pueden reducir a 15 configuraciones básicas (Figura 7.6).

Figura 7.6. Configuraciones básicas del algoritmo *Marching Cubes*

La posición exacta del vértice a lo largo de la arista se calcula mediante una interpolación lineal basándose en las posiciones de los vóxeles de esa arista y en sus valores TSDF.

Determinando qué bordes del cubo están intersectados por la superficie, se crean triángulos conectando esos vértices, que dividen el cubo en regiones dentro de la superficie y regiones exteriores a la superficie. Al conectar los triángulos de todos los cubos, se obtiene una malla triangular que representa la superficie (Figura 7.7).

Figura 7.7. (a)-(c) Distintos ejemplos de mallas triangulares generadas en función de las diferentes posiciones de los vértices en las aristas

7.2. Deriva de la reconstrucción 3D

Uno de los problemas que tienen todos los métodos de reconstrucción 3D que basan la estimación de la posición y orientación de la cámara en la información suministrada en las imágenes, es que puede haber ligeras variaciones entre la posición y orientación calculada y la real de la cámara. Esto sucede sobre todo con escenas parecidas, como son los cultivos, donde una y otra vez se repite la misma estructura, apareciendo siempre información similar (copas llenas de hojas parecidas a distancias similares de la cámara). Estas ligeras variaciones en la posición y orientación calculada pueden dar lugar a una deriva que provoca deformaciones en la reconstrucción 3D, siendo más significativa cuanto más grande es la reconstrucción. En la Figura 7.8 se ilustra este problema.

Figura 7.8. Deriva en la reconstrucción 3D de una fila de viñedos

Para resolver este problema se ha diseñado e implementado un algoritmo de ajuste que tiene en cuenta características del tipo de escenario, es decir, los cultivos leñosos.

7.2.1. Filtrado

El primer paso es realizar un filtrado de la reconstrucción 3D para eliminar aquellos vértices de la malla que aparecen aislados. Un vértice se considera atípico (*outlier*) si la distancia media a sus 64 vecinos más cercanos es superior a la desviación típica de la distancia a los vecinos de todos los puntos. En la Figura 7.9 se muestra un fragmento de una reconstrucción de una fila de viñedos antes y después del filtrado.

Figura 7.9. (a) Fragmento de reconstrucción 3D antes del filtrado; (b) El mismo fragmento después del filtrado

7.2.2. Cálculo de la línea modelo

El siguiente paso consiste en encontrar una línea que modele longitudinalmente la reconstrucción 3D de la fila de árboles generada anteriormente. Esta línea modelo debe ajustarse tanto como sea posible al recorrido de la fila de árboles, utilizándose en los siguientes pasos para segmentar la fila en secciones de la misma longitud. Para modelar la línea se utilizan las posiciones de los vértices de la malla triangular que representa la reconstrucción 3D de la fila.

Los vértices contenidos en la malla se dividen en grupos de menor tamaño de igual número de vértices, y se calcula el centroide de los vértices para cada uno de los grupos. Dado que los vértices de la malla están almacenados consecutivamente según su orden de aparición, los centroides o puntos de la línea modelo resultantes son también consecutivos y determinan la fila de cultivo. El número de puntos de la línea modelo es proporcional al número de grupos en los que se divide la malla original; cuantos más grupos más puntos y por ende más precisión para ajustarse a la línea de cultivo. El número de grupos se estima a partir de la longitud total de la fila, conocida la posición geográfica del inicio y del final de la hilera. En general es suficiente con dividir la fila en grupos de aproximadamente 5 m, ya que experimentalmente se ha comprobado que el efecto de la deriva en 5m es prácticamente despreciable. Obsérvese que los grupos de vértices, aunque contienen el mismo número de vértices, no representan la misma longitud de fila porque la densidad de los vértices no tiene por qué ser uniforme (cambiará dependiendo de la frondosidad de los árboles) y, por tanto, los puntos de la línea modelo obtenidos no están separados por la misma distancia, tal como se ilustra en la Figura 7.10.

Figura 7.10. Línea modelo de la fila de viñedos de la Figura 7.8

Para que la línea modelo recorra de extremo a extremo la fila de árboles es necesario obtener los puntos extremos de ésta para incorporarlos a los puntos obtenidos de la línea modelo. Para obtener el punto inicial se proyectan los vértices del primer grupo sobre la prolongación de la recta que une el primer y segundo centroide. Se elige como punto inicial de la línea modelo el punto proyectado más distante al primer centroide, ya que deja todos los demás vértices de la fila de cultivo a su derecha (en una perspectiva frontal). En el caso del punto final de la línea modelo se procede de manera equivalente. Se proyectan todos los vértices del último grupo sobre la prolongación de la recta que une el penúltimo y último centroide, eligiéndose como punto final de la línea modelo aquel punto proyectado más distante al último centroide, pues deja todos los vértices de la fila de cultivo a su izquierda (Figura 7.11).

Figura 7.11. Los círculos amarillos representan los puntos extremos de la fila de árboles (Figura 7.8) añadidos a la línea modelo de la Figura 7.9

7.2.3. División de la fila en secciones de la misma longitud

Una vez que se obtiene una línea modelo precisa del cultivo, se divide en segmentos de la misma longitud. Esta longitud de segmento se fija, por comodidad, de acuerdo con la resolución final requerida para la extracción de parámetros que se explicará en el apartado 7.3, pero adaptándola a la deriva de la fila de cultivo. Sumando las distancias euclídeas entre los puntos de la línea modelo y comparando la suma final con la distancia entre la posición geográfica del inicio y del final de la fila, existirá una ligera diferencia debida a la deriva de la fila, que hace que la longitud de la línea modelo sea superior a la real. Para distribuir el error a lo largo de toda la fila de cultivo, se adapta la longitud deseada del segmento de forma proporcional a la relación entre la longitud de la línea modelo y la longitud real de la fila. Por ejemplo, si la longitud real de la fila medida a partir de las posiciones geográficas es de 50 m y se desea una longitud de segmento de 0,50 m, la fila se dividirá en 100 secciones; pero si la longitud de la línea modelo es de 53 m, la longitud del segmento

se ajustará a 0,53 m para mantener el número de secciones y así distribuir el error. Posteriormente, cuando se corrija la deriva, se deshará el cambio y el segmento volverá a medir los 0,50 m correspondientes.

Una vez definido la longitud de la sección, se divide la línea modelo en segmentos de esa longitud y se divide la reconstrucción 3D en secciones separadas por planos perpendiculares a la línea modelo en cada punto de separación de los segmentos. De esta forma, la reconstrucción 3D queda dividida en secciones, conteniendo cada una de ellas un fragmento de la reconstrucción (Figura 7.12).

Figura 7.12. Parte de la fila de viñedos de la Figura 7.8 dividida en secciones

7.2.4. Corrección de cada sección

En las reconstrucciones 3D generadas el origen de coordenadas se sitúa en la posición inicial del sensor RGB-D. Para facilitar los procedimientos desarrollados, se realiza un cambio de sistema de coordenadas, situándose el origen en la posición inicial del cultivo, centrado en el suelo, y se define el sistema de coordenadas con el eje X en la dirección de la fila de cultivo (sentido del punto inicial al punto final de la hilera de cultivo), el eje Z en la dirección de crecimiento del árbol y el eje Y que representa la profundidad (Figura 7.13). El cambio de sistemas de coordenadas se realiza aplicando una matriz de transformación compuesta por los vectores que determinan el nuevo sistema de coordenadas (nuevos ejes) con respecto al sistema antiguo.

Figura 7.13. En amarillo, sistema de coordenadas definido y utilizado

Puesto que la línea modelo indica la dirección del cultivo, en cada sección se puede calcular el vector que indica la dirección del cultivo en esa sección utilizando los puntos inicial y final del

segmento de línea modelo en el que se encuentra la sección (Figura 7.14).

Figura 7.14. En rojo el vector que conecta los puntos inicial y final del segmento donde se encuentra la sección (eje X de la sección)

Idealmente, la dirección de este vector debería coincidir con la dirección de la línea de cultivo en el mundo real (eje X de referencia representado en la Figura 7.13), sin embargo, esto no ocurre así debido a la deriva que aparece en la reconstrucción 3D. Para solucionar esto y corregir la deriva, se debe corregir cada sección de forma que se rote para alinear el vector que indica la línea modelo en esa sección, es decir, el eje X de la sección (o $X_{sección}$) con el eje X de referencia (o $X_{referencia}$). De esta forma se corregirán los errores provocados por la deriva. Para ello, en primer lugar, en cada sección se sitúa el sistema de referencia deseado en el punto inicial del segmento en la sección (punto origen de $X_{sección}$) simplemente realizando una traslación desde el punto origen de coordenadas de la fila reconstruida a ese punto. A continuación, y tras normalizar $X_{sección}$, hay que encontrar la matriz de rotación, R , que rote el vector unitario $X_{sección}$ para alinearlo con el vector unitario $X_{referencia}$ (Figura 7.15).

Figura 7.15. En rojo el eje X de la sección ($X_{sección}$) y en amarillo el eje X de referencia ($X_{referencia}$) para la alineación

El teorema de la rotación de Euler (Euler, 1775) establece que cualquier rotación o conjunto de rotaciones sucesivas puede expresarse siempre como una rotación alrededor de un eje de rotación principal. Para obtener este eje (v), se calcula el producto vectorial de $X_{sección}$ y $X_{referencia}$ (7.12).

$$v = X_{sección} \times X_{referencia} \quad (7.12)$$

La fórmula de rotación de Rodrigues (Rodrigues, 1840) permite expresar de forma matemática el teorema de rotación de Euler, posibilitando el cálculo de la matriz de rotación (R) dado un eje de rotación (v) y un ángulo de rotación (θ), tal como muestra la expresión (7.13).

$$R = I + [v]_{\times} \cdot \text{sen}\theta + [v]_{\times}^2 \cdot (1 - \cos\theta) \quad (7.13)$$

donde $[v]_{\times}$ representa el eje v obtenido como producto vectorial en (7.12) expresado en términos de matriz antisimétrica, tal como se muestra en (7.14).

$$[v]_{\times} = \begin{pmatrix} 0 & -v_3 & v_2 \\ v_3 & 0 & -v_1 \\ -v_2 & v_1 & 0 \end{pmatrix} \quad (7.14)$$

Puesto que $X_{sección}$ y $X_{referencia}$ son vectores unitarios, se puede obtener el coseno del ángulo entre ellos como el productor escalar de ambos vectores, expresión (7.15).

$$\cos\theta = X_{sección} \cdot X_{referencia} \quad (7.15)$$

Y, teniendo en cuenta la misma premisa, el seno del ángulo entre ellos se puede calcular, mediante la ecuación (7.16). Es decir, como la norma del eje obtenido como resultado del producto vectorial de ambos vectores en (7.12).

$$\sen\theta = ||v|| \quad (7.16)$$

De esta forma, se obtienen todos los términos necesarios para calcular la matriz de rotación, R , a partir de la fórmula de Rodrigues (7.13). Aplicando dicha matriz a todos los vértices que forman la sección se rectifica dicha sección alineando la dirección del cultivo en esa sección con el eje X deseado y, de esa forma, corrigiendo la deriva. Para que la sección quede correctamente situada se deshace la traslación realizada anteriormente, de forma que todos los vértices de la sección queden referenciados respecto al punto origen de coordenadas de la fila reconstruida. Como se explicó en el apartado 7.2.3, una vez corregida la deriva se deshace el cambio en la longitud del segmento, escalándolo de modo que tenga de nuevo la longitud establecida inicialmente.

Una vez corregida la deriva de cada sección, las secciones se encuentran alineadas, y con ello se ha logrado corregir la deriva producida durante la reconstrucción 3D. En la Figura 7.16 se muestra una reconstrucción de una fila de viñedos con deriva y el resultado obtenido una vez aplicado el procedimiento propuesto para la eliminación de la deriva.

Figura 7.16. Reconstrucción 3D con deriva de una fila de viñedos (arriba) y resultado una vez eliminada la deriva (abajo)

7.3. Extracción de información: cálculo de parámetros

A partir de la información de la reconstrucción 3D de la línea de cultivo corregida, se calculan una serie de parámetros (volumen, altura, anchura) que permiten un tratamiento individualizado del cultivo. Estos parámetros pueden calcularse a partir de la reconstrucción 3D ya que la reconstrucción generada mantiene las proporciones del escenario real. Conocidas las posiciones geográficas del inicio y del final de la línea de cultivo, cada una de las secciones obtenidas en el procedimiento anterior pueden ser correctamente georreferenciadas en un mapa. Calculando los parámetros por cada sección se pueden construir mapas de volúmenes, alturas y anchuras que serán la base de una gestión más precisa del cultivo.

7.3.1. Extracción de copas de cada sección

Ahora que las secciones están correctamente alineadas, se puede utilizar el eje Z (eje de altura) para extraer los vértices pertenecientes a las copas de los árboles. Filtrar por color no es una buena opción para extraer las copas, ya que puede haber cubierta vegetal en el suelo que podría etiquetarse equivocadamente como perteneciente a las copas. Como ahora cada sección está alineada con el eje Z, sabemos que el suelo está en la parte inferior y la copa está en la parte superior. Además, por lo general los vértices de la sección se agrupan claramente en dos zonas diferentes, copa y suelo, separadas por una zona mucho más delgada y pequeña de puntos correspondiente al tronco. Teniendo esto en cuenta se utiliza un algoritmo de aprendizaje automático para clasificar los vértices de la sección en dos categorías diferentes o grupos. Concretamente se emplea el algoritmo K-means (McQueen, 1967), considerando solo la componente z de los vértices. Como puede verse en la Figura 7.17, en general los vértices se agrupan alrededor de dos grupos claramente definidos, siendo los vértices del grupo con los valores más altos en la coordenada z los que pertenecen a la copa.

Figura 7.17. A la izquierda, los vértices de la sección original sin componente de color. En el centro, los dos grupos encontrados por el algoritmo K-means aplicado sobre la componente z de los vértices. A la derecha, los dos grupos obtenidos representados en verde y marrón sobre la sección original

7.3.2. Cálculo del volumen de la copa de cada sección

Una vez obtenidos los vértices pertenecientes a la copa, se calcula el volumen definido por esos vértices. Para obtener el volumen de una superficie 3D se debe tener una superficie cerrada. Para conseguirla se utilizan las *alpha shape*. Una *alpha shape* representa el contorno que envuelve un conjunto de puntos 2D o 3D (Edelsbrunner & Mücke, 1994). Una *alpha shape* representa el contorno que envuelve un conjunto de puntos 2D o 3D. Para conseguirlo, este método genera círculos o esferas (según sean puntos 2D o 3D) de radio *alpha*, que no contienen ningún punto en su interior y a su vez su superficie está en contacto con más de un punto. Uniendo estos puntos con los de los círculos o esferas más próximas se forma el contorno que los envuelve (Figura 7.18).

Figura 7.18. Ejemplo de contorno generado a partir de un conjunto de puntos utilizando *alpha shapes*

El parámetro *alpha* que especifica cómo de ceñido es el ajuste del contorno a los puntos. En la Figura 7.19 se pueden ver diferentes *alpha shapes* para la misma sección seleccionando distintos valores para el parámetro *alpha*. Valores bajos generan contornos muy ceñidos, mientras que valores más altos muestran contornos menos ajustados. Tras realizar múltiples experimentos con diferentes valores de *alpha* se eligió un valor igual a 0,2 para la aplicación desarrollada por representar más fielmente la forma del árbol para el cálculo del volumen.

Figura 7.19. (a) Vista frontal de la copa de una sección capturada por un solo lado de la fila, (b) *Alpha shape* para la copa mostrada en (a) con $\alpha = 0.1$, (c) con $\alpha = 0.2$ y (d) con $\alpha = 0.4$; (e)-(h) Vistas laterales de las imágenes de (a) a (d)

Para calcular las *alpha shape* de las copas de cada sección, así como el volumen que encierran, se utilizó el paquete *alphashape3d* de R (Lafarge & Pateiro-Lopez, 2016) basado en el trabajo original de (Edelsbrunner & Mücke, 1994). Si se ha realizado la reconstrucción 3D de la línea de cultivo por ambos lados de la fila, este procedimiento se lleva a cabo teniendo en cuenta las reconstrucciones realizadas en ambos lados.

7.3.3. Cálculo de la altura máxima del árbol en cada sección

Como todos los vértices se encuentran referenciados respecto al origen en el suelo, encontrar la altura máxima en cada sección consiste simplemente en encontrar el vértice situado a una mayor altura. Para eliminar la influencia de algún posible vértice espurio, que no se haya eliminado en la etapa de filtrado y que altere las medidas, también se calcula el percentil 95 y 90 de la altura máxima de cada sección.

Si se ha realizado la reconstrucción 3D de la línea de cultivo por ambos lados de la fila, este procedimiento se lleva a cabo teniendo en cuenta las reconstrucciones realizadas por ambos lados, de forma que se calcula la altura máxima, el percentil 95 y 90 teniendo en cuenta las alturas obtenidas en ambos lados.

7.3.4. Cálculo de la anchura proyectada máxima del árbol en cada sección

Para encontrar la anchura proyectada máxima en cada sección, se divide cada una en subsecciones de 1 cm según la componente x , calculándose la anchura máxima de cada subsección mediante la diferencia entre el vértice con la componente y más alta y la más baja. Posteriormente se calcula el valor máximo de todas las anchuras máximas de las subsecciones, siendo ésta la anchura proyectada máxima de la sección. Al igual que en el apartado 7.3.3, para eliminar la influencia de algún posible vértice espurio se calcula el percentil 95 y 90 de la anchura proyectada máxima. Igualmente, si se ha llevado a cabo la reconstrucción 3D de la línea de cultivo por ambos lados de la fila, este proceso se realiza teniendo en cuenta las reconstrucciones realizadas en ambos lados.

7.4. Resultados

Para verificar el correcto funcionamiento de la aplicación desarrollada, se realizaron varios muestreos en campos reales en diferentes meses de 2016, en parcelas de viñedos comerciales propiedad de Codorníu S.A. y situadas en Raimat (Lérida).

Para muestrear los viñedos, se utilizó el vehículo eléctrico presentado en el Capítulo 5, desplazándose a una velocidad aproximada de 3 km/h y conducido manualmente. Para recoger la información de los viñedos se colocó el sensor Kinect v2 a 1,4 m de altura orientado hacia las cepas con un ángulo de cabeceo (*pitch*) de 10°. Durante el recorrido del vehículo el sensor se encontraba aproximadamente a una distancia de 1 m de la fila (Figura 7.20).

Figura 7.20. Detalle del muestreo en los viñedos de Codorníu S.A. en Raimat (Lérida) en mayo de 2016

La inspección de cada línea de cultivo se realizó por ambas caras para tener información de ambos lados de la hilera. De cada línea que se inspeccionó se almacenó la posición geográfica del inicio y del final de línea que suministraba el receptor GPS-RTK a bordo del vehículo.

En la Figura 7.21 se muestran ejemplos de la información proporcionada por el sensor Kinect v2 durante el muestreo. En la columna izquierda se pueden ver imágenes de la escena captadas por la cámara RGB del sensor, mientras que en la columna derecha se muestran unas representaciones en falso color de la información de profundidad (distancia de la cámara a los objetos de la escena) obtenida a partir de la información de la cámara de infrarrojos. Ambas imágenes (RGB y profundidad) corresponden al mismo instante de tiempo. En la imagen de profundidad, los objetos cercanos aparecen de color rojo, los lejanos en azul y los objetos en el medio aparecen en varios tonos de naranja, amarillo, y verde. En estas últimas imágenes se puede comprobar que el rango de operación del sensor cumple con los requerimientos de la inspección, ya que los objetos muy cercanos no aparecen, al igual que las zonas más alejadas, por ejemplo, las otras filas del cultivo que sí se distinguen en las imágenes RGB. También se puede apreciar en la figura la diferente resolución y campo de visión entre las cámaras RGB e infrarrojos del sensor Kinect v2, tal y como se comentó en el apartado 5.1.2.

Figura 7.21. (a) y (c) Imágenes RGB adquiridas por el sensor Kinect v2; (b) y (d) Imágenes de profundidad adquiridas por el sensor en el mismo instante de tiempo que (a) y (c)

Con toda la información suministrada por el sensor Kinect v2 y almacenada en el ordenador a bordo del vehículo, se procedió a la reconstrucción 3D de las diferentes líneas muestreadas del viñedo, así como al cálculo de los distintos parámetros de interés. Para ello se utilizó un ordenador de sobremesa con un procesador Intel Core i7-6900K@3.2GHz, 64 GB de memoria RAM, y una tarjeta gráfica NVIDIA GeForce GTX Titan X.

En la Figura 7.22 se muestra un ejemplo de una de estas reconstrucciones generadas, mientras que en la Figura 7.23 se puede apreciar la estructura de la malla 3D obtenida en una de las reconstrucciones.

Figura 7.22. Reconstrucción 3D de una fila de viñedos

Figura 7.23. Detalle de la reconstrucción 3D de un viñedo en el que se aprecia el mallado obtenido a partir de la nube de puntos

Como se comentó en el apartado 7.2, al realizar reconstrucciones 3D de filas de cultivo tan largas, puede aparecer una deriva que provoca deformaciones en la reconstrucción. En la Figura 7.24 se muestra la deformación que aparece en la reconstrucción de una de las líneas muestreadas del viñedo de 85 m de longitud.

Figura 7.24. Reconstrucción 3D de una de las filas de viñedo con presencia importante de deriva

Aplicando el procedimiento descrito en el apartado 7.2, se logran corregir las derivas obtenidas durante la reconstrucción de las filas. En la Figura 7.25 se muestra la reconstrucción corregida de la fila presentada en la Figura 7.24.

Figura 7.25. Reconstrucción 3D con la deriva corregida de la fila de viñedos que aparece en la Figura 7.24

El tiempo medio de generación de una reconstrucción 3D con la deriva corregida para una línea de viñedos de 50 m, utilizando el ordenador descrito anteriormente, es de aproximadamente 15 minutos. El número medio de vértices en una reconstrucción de una fila de 50 m es 8 millones.

En la Figura 7.26 se muestran cuatro filas de viñedos, pertenecientes a una parcela de viñedo ecológico con presencia de cubierta vegetal muy desarrollada. El muestreo se realizó a mediados del mes de julio de 2016. En la Figura 7.27 se muestran esas mismas filas de viñedos en una representación en escala de colores según su altura respecto al suelo.

Figura 7.26. 4 filas de viñedos pertenecientes a una misma parcela. Muestreo realizado el julio de 2016

Figura 7.27. Representación en falso color de las filas de viñedos de la Figura 7.26. El color representa la altura de los distintos puntos con respecto al suelo

Una vez obtenidas las reconstrucciones 3D de cada fila, se calculan los volúmenes, alturas máximas y anchuras proyectadas máximas de los viñedos para cada sección de 50 cm de la fila. Al ser conocidas las posiciones geográficas del inicio y del final de cada línea, se puede georreferenciar cada sección y obtener un mapa con todos los parámetros calculados.

En la Figura 7.28 se muestra el perfil de alturas máximas para una de las filas de las parcelas muestreadas.

Figura 7.28. Perfil de alturas máximas de una fila de viñedos

En la Figura 7.29 se muestran las anchuras proyectadas máximas para la misma fila de viñedos.

Figura 7.29. Anchuras proyectadas máximas de una fila de viñedos

Por último, en la Figura 7.30 se representan de forma gráfica la distribución de volúmenes obtenida para la misma fila de viñedos.

Figura 7.30. Distribución de volúmenes de una fila de viñedos

Finalmente conviene destacar que los procedimientos desarrollados proporcionan una herramienta válida para la extracción automática de parámetros de los cultivos leñosos que permite un tratamiento individualizado de cada árbol, posibilitando la detección de posibles anomalías causadas por alguna plaga, estrés hídrico, etc. En pocas palabras, se espera que la herramienta desarrollada permita realizar un seguimiento de los cultivos leñosos durante la campaña permitiendo una gestión de precisión que se adapte a las necesidades individuales de cada árbol, contribuyendo a mejorar la rentabilidad y salud del cultivo.

8. CONCLUSIONES Y TRABAJO FUTURO

8.1. Conclusiones

El concepto de Agricultura de Precisión propone la adaptación de la gestión de los cultivos a la variabilidad espacial y temporal de éstos. Una tarea imprescindible para implantar una gestión de precisión es la inspección de los campos. Entre los diversos medios de recolección de información bien estructurada a un precio razonable, los vehículos equipados con sensores de a bordo pueden considerarse una de las tecnologías más prometedoras a medio plazo. En esta línea, el trabajo de investigación descrito en esta memoria contribuye al desarrollo de una plataforma autónoma para la inspección efectiva de cultivos, así como al desarrollo de diferentes métodos para la extracción de información útil a partir de los datos adquiridos con los sensores embarcados en el vehículo. Las conclusiones se pueden agrupar en dos grandes bloques, un primer grupo relacionado con la plataforma de inspección y un segundo grupo unido a las técnicas de reconstrucción del entorno a partir de los datos de campo.

8.1.1. Vehículos de inspección

Para explorar grandes extensiones de cultivo es necesario la utilización de vehículos. El uso de vehículos de tamaño pequeño o mediano para inspeccionar un cultivo completo es una opción adecuada frente a máquinas grandes ya que se minimiza el daño en el cultivo y la compactación del suelo. Esto abre la puerta a la realización de múltiples muestreos a lo largo de una campaña que ayuden a tener un seguimiento prácticamente continuo del estado del cultivo. En este contexto se ha trabajado con tres tipos de vehículos, candidatos a ser la plataforma de inspección, y que presentan características muy diferentes.

Se han mejorado las prestaciones de un robot comercial, realizando actuaciones electrónicas y software para lograr un mejor rendimiento del robot como vehículo de inspección de cultivos. Se ha integrado una cámara réflex comercial y un receptor GPS-RTK en el robot para conseguir que navegue autónomamente, adquiriendo la información del cultivo en el recorrido.

Se han llevado a cabo actuaciones electrónicas, mecánicas y software para conseguir la automatización de una cuatrimoto comercial (ATV), indispensable para poder teleoperar el vehículo. Asimismo, se ha integrado una IMU de bajo coste y un receptor GPS-RTK para conseguir el control del vehículo. La automatización se ha realizado respetando la posibilidad de que el ATV pueda conducirse también manualmente. Se ha dejado preparado el vehículo para una integración posterior de otros sensores (cámara réflex, sensor RGB-D, etc.) con el fin de navegar autónomamente y recoger información del cultivo durante el recorrido.

Se han llevado a cabo actuaciones electrónicas, mecánicas y software para lograr la automatización de un vehículo eléctrico, requisito indispensable para poder teleoperar el vehículo o conseguir que navegue autónomamente en el futuro. Se ha integrado un sensor RGB-D, una cámara réflex comercial y un receptor GPS-RTK así como un ordenador de altas prestaciones en este vehículo para adquirir la información de los cultivos. Este vehículo está preparado para la inspección tanto de cultivos herbáceos como de cultivos leñosos. El proceso de automatización se ha llevado a cabo respetando la posibilidad de que el vehículo pueda conducirse también manualmente, de hecho, los muestreos llevados a cabo en viñedos comerciales en la campaña de 2016 se han realizado con esta plataforma con conductor.

Se han desarrollado sistemas de teleoperación para los tres vehículos analizados y automatizados que permiten e que un operario envíe órdenes al vehículo tanto desde una interfaz gráfica que se ejecuta en una tableta como desde un mando tipo joystick. En el caso del robot comercial, este sistema de teleoperación resulta imprescindible, mientras que en los otros dos vehículos resulta una alternativa a la conducción manual. Se ha comprobado el correcto funcionamiento de todos los sistemas de teleoperación.

Se ha desarrollado un método robusto para la extracción de una línea de cultivo en tiempo real invariante a las condiciones de iluminación en campos de cultivo extensivos con esquema de siembra en líneas separadas a partir de la información suministrada por una cámara réflex convencional. Es fundamental conseguir una detección robusta de la línea para que el guiado del vehículo sea bueno. El método debe ser capaz de separar la línea de cultivo del resto de elementos del campo y, además, a la hora de seguir la línea, debe funcionar sin verse afectado por la presencia de malas hierbas, errores de siembra, etc. Se ha desarrollado un método robusto capaz de aislar la cubierta vegetal del resto de elementos del campo y, a continuación, seleccionar solo la línea central a seguir, obteniendo los parámetros para poder guiar un vehículo. Este método se ha probado para uno de los vehículos de inspección, en concreto el robot comercial, pero es adaptable a cualquier otro vehículo, ajustando los parámetros de configuración del algoritmo para tener en cuenta la altura a la que se encuentra la cámara, así como el grado de perspectiva en la imagen.

El método desarrollado para detectar la línea de cultivo y extraer la recta que la caracteriza, se ha comparado con uno de los métodos más utilizados para la extracción de rectas en imágenes, como es la transformada de Hough. Se probaron ambos métodos con 500 imágenes características capturadas desde un vehículo de inspección en diferentes condiciones de iluminación, etapas de crecimiento del cultivo, densidades de malas hierbas y orientaciones de la cámara, encontrándose que el método desarrollado es mejor en la extracción de líneas y también en el tiempo de procesamiento, parámetro fundamental en el caso de que la línea de cultivo sea la guía para la navegación del vehículo.

Se ha desarrollado una conducta robusta de navegación guiada por la información visual

extraída de una línea de cultivo para vehículos de inspección, mediante técnicas de control borroso en campos de cultivo extensivo con esquema de siembra en líneas separadas, a partir de la información suministrada por una cámara réflex convencional. Además, se ha desarrollado una conducta para detectar el final de la línea de cultivo de forma robusta.

Se ha desarrollado una conducta de cambio de línea de cultivo en las que el vehículo realiza las maniobras necesarias para, una vez finalizada el seguimiento de una línea, situarse correctamente orientado al comienzo de la siguiente línea a seguir. Esta conducta es una conducta fundamental para conseguir la plena autonomía del vehículo con una cobertura total del campo.

Se ha verificado el correcto funcionamiento de todas estas conductas en campos reales. Además, estas conductas individuales se pueden utilizar para inspeccionar autónomamente un cultivo siguiendo un plan predefinido.

8.1.2. Reconstrucción del entorno

Se ha desarrollado un método para generar mapas de distribución de la cubierta vegetal (línea de cultivo y malas hierbas), en cultivos sembrados con una separación entre líneas que permite visualmente distinguirlas, a partir de la información suministrada por una cámara réflex comercial y un receptor GPS-RTK ambos embarcados en un vehículo de inspección. Los mapas de distribución de la cubierta vegetal pueden servir para detectar las zonas donde aparecen rodales de malas hierbas, las zonas donde hay errores de siembra, las zonas donde hay algún problema de riego, etc. La forma tradicional de proceder para construir estos mapas es mediante un muestreo manual, en que los operarios recorren el campo muestreando una serie de puntos predeterminados y extrapolan la información al resto del cultivo. Este procedimiento no suministra información tan precisa como la de un muestreo continuo que por otra parte es una tarea inviable en campos de gran extensión, por lo que la automatización del proceso de muestreo continuo resulta esencial en Agricultura de Precisión.

Teniendo como base el método propuesto para la extracción de una línea de cultivo a partir de la información suministradas por la cámara réflex, se desarrolló un algoritmo capaz de extraer tres líneas de cultivo de la imagen lidiando con la perspectiva de la cámara y obtener un mapa del cultivo desde una vista cenital. El método desarrollado genera un mapa de distribución de la cubierta vegetal eliminando los efectos de los movimientos no deseados de la cámara producidos por el movimiento del vehículo en un terreno irregular. Los movimientos de la cámara y los efectos sobre la imagen capturada son mayores cuanto más pequeño es el vehículo. Se han realizado experimentos en campos reales de maíz verificando el buen funcionamiento del método propuesto.

Se ha probado y validado el uso de un sensor RGB-D de bajo coste, en concreto el sensor Kinect v2 de Microsoft, en exteriores bajo condiciones de iluminación no controladas. Este sensor se ha utilizado principalmente para la inspección de cultivos leñosos, realizando la reconstrucción 3D de estos escenarios a partir de la imagen RGB y la información de profundidad suministrada por el sensor.

Se han estudiado diferentes métodos para realizar la reconstrucción 3D automática, ya que es fundamental generar la reconstrucción de grandes áreas, como puede ser una línea de cultivo completa. Finalmente, el método implementado proporciona buenos resultados en la reconstrucción de grandes áreas a partir de la información suministrada directamente por el sensor RGB-D.

Se ha desarrollado y probado un método que permite corregir la deriva que aparece en la reconstrucción de líneas de cultivo utilizando la fórmula de rotación de Rodrigues junto con una

información mínima de la escena como la localización geográfica del punto inicial y del punto final, así como el hecho de que se están muestreando elementos que están alineados. Esta deriva aparece debido a las ligeras variaciones entre la posición y orientación calculada por el método de reconstrucción, y la posición y orientación real de la cámara. Esto sucede sobre todo con escenas parecidas, como son los cultivos, donde una y otra vez se repite la misma estructura, apareciendo siempre información similar, como por ejemplo copas llenas de hojas parecidas a distancias similares de la cámara. Estas ligeras variaciones en la posición y orientación calculadas dan lugar a una deriva que provoca deformaciones en la reconstrucción 3D, siendo más significativa cuanto más grande es la reconstrucción.

Se han desarrollado diferentes procedimientos para la extracción de algunas características importantes que definen la arquitectura del cultivo leñoso a partir de la reconstrucción 3D con la deriva corregida. Así los métodos desarrollados permiten estimar el volumen de las copas, las alturas y anchuras de los árboles. Además, los puntos de la reconstrucción están georreferenciados, por lo que es posible construir mapas de los valores estimados, información útil para los agricultores a la hora de tomar decisiones eficaces para gestionar sus cultivos de forma precisa.

Para validar todos los procedimientos diseñados e implementados, se equipó el vehículo eléctrico, con un sensor Kinect v2, un receptor GPS-RTK y un ordenador de altas prestaciones y se hicieron diversos muestreos en distintos momentos de la campaña 2016. Los muestreos se realizaron en viñedos reales verificando el correcto funcionamiento de todos los métodos desarrollados.

8.2. Trabajo futuro

8.2.1. Vehículos de inspección

Si se desea seguir realizando experimentos en el campo con el robot comercial es recomendable integrar un sistema de amortiguación para facilitar su desplazamiento en terrenos irregulares, con rodadas, como los campos de cultivo extensivo. De esta forma el rendimiento del vehículo en navegación autónoma mejoraría, pudiendo desplazarse a mayor velocidad.

Respecto al ATV y el vehículo eléctrico utilizados, después de la automatización y lograda la teleoperación, el siguiente paso, es adaptar todas las conductas desarrolladas en el robot móvil comercial a estos vehículos. Para ello, habrá que adaptar los controladores borrosos desarrollados y ajustar la conducta de cambio de línea de cultivo ya que el radio de giro de ambos vehículos es diferente al del robot comercial. También se desarrollarán nuevas conductas de navegación autónoma. Éstas podrían estar guiadas por la información del receptor GPS-RTK. o por la información de profundidad suministrada por la cámara RGB-D, con la que se podría seguir una fila de cepas.

Por último, para todos los vehículos de inspección que naveguen autónomamente será necesario desarrollar una conducta de detección de obstáculos y reacción ante ellos, tanto evitándolos como parando el vehículo.

8.2.2. Reconstrucción del entorno

Después de generar mapas de distribución de la cubierta vegetal en cultivos sembrados con separación entre líneas utilizando el robot, el siguiente paso, es generarlos usando el vehículo eléctrico, cuyo desplazamiento por el campo es más suave que el del robot, produciendo menos

movimientos indeseados de la cámara. Además, si éstos son despreciables y el solapamiento entre imagen e imagen es suficiente, se podrían utilizar las imágenes georreferenciadas obtenidas para generar un mapa 3D del cultivo mediante técnicas de fotogrametría. Por último, después de generar el mapa 2D del cultivo, si lo que se quiere es detectar donde se encuentran las zonas de mala hierba de forma automática para su análisis, se podrían encontrar fácilmente detectando las columnas en la imagen entre líneas de cultivo en las que aparecen zonas marcadas como grises-blancos.

Para intentar mitigar el efecto de la deriva durante la reconstrucción 3D, se podría estudiar la conveniencia de aplicar la estrategia del algoritmo SURF (del inglés *Speeded-Up Robust Features*) (Bay, Tuytelaars, & Van Gool, 2006). La idea sería elegir las correspondencias entre puntos de las superficies origen y destino que suministra el algoritmo SURF y utilizarlas en el algoritmo ICP para que calcule la matriz de transformación teniendo en cuenta solo esos puntos (Engelhard, Endres, Hess, Sturm, & Burgard, 2011).

Otra alternativa para intentar mitigar el efecto de la deriva es la instalación de una IMU solidaria al sensor Kinect v2 que registrase las variaciones en los ángulos de guiñada (*yaw*), cabeceo (*pitch*) y alabeo (*roll*) del sensor. Estos datos, junto con los datos de traslación obtenidos del receptor GPS-RTK a bordo del vehículo, se utilizarían como la transformación inicial con la que comienza el algoritmo ICP cada vez que llega una nueva imagen. En (Nießner, Dai, & Fisher, 2014) se propone una aproximación similar que solo usa la IMU.

Además, para reducir el recorrido del vehículo eléctrico a la mitad, se podrían integrar dos sensores RGB-D de forma que se inspeccionaran simultáneamente ambos lados de la calle durante el recorrido. Ahora bien, tal como funciona en estos momentos el sensor Kinect v2, sería necesario incorporar un nuevo ordenador a la plataforma.

9. BIBLIOGRAFÍA

- Adhikari, B., & Karkee, M. (2011). 3D Reconstruction of Apple Trees for Mechanical Pruning. American Society of Agricultural and Biological Engineers.
- Agrobot. (2014). Recuperado el 26 de Junio de 2017, de <http://www.agrobot.com/>
- Ahamed, T., Kulmutiwat, S., Thanpattranon, P., Tunti, S., Ryoze, N., & Takigawa, T. (2011). Monitoring of plant growth using laser range finder. In *2011 ASABE Annual International Meeting*, Louisville, Kentucky.
- Aitkenhead, M. J., Dalgetty, I. A., Mullins, C. E., McDonald, A. J. S., & Strachan, N. J. C. (2003). Weed and crop discrimination using image analysis and artificial intelligence methods. *Computers and Electronics in Agriculture*, 39(3), 157–171.
- Alenyà Ribas, G., Dellen, B., Foix Salmerón, S., & Torras, C. (2012). Robotic leaf probing via segmentation of range data into surface patches. In *Proceedings of the 2012 IROS Workshop on Agricultural Robotics: Enabling Safe, Efficient, Affordable Robots for Food Production*

(pp. 1–6).

- Alonso-Garcia, S., Gomez-Gil, J., & Arribas, J. I. (2011). Evaluation of the use of low-cost GPS receivers in the autonomous guidance of agricultural tractors. *Spanish Journal of Agricultural Research*, 9(2), 377–388.
- Andersen, J. C., Ravn, O., & Andersen, N. A. (2010). Autonomous rule-based robot navigation in orchards. *IFAC Proceedings Volumes*, 43(16), 43–48.
- Andreasen, C., Rudemo, M., & Sevestre, S. (1997). Assessment of weed density at an early stage by use of image processing. *Weed Research*, 37(1), 5–18.
- Andújar, D., Dorado, J., Fernández-Quintanilla, C., & Ribeiro, A. (2016). An Approach to the Use of Depth Cameras for Weed Volume Estimation. *Sensors*, 16(7), 972.
- Antonelli, G., Chiaverini, S., & Fusco, G. (2007). A fuzzy-logic-based approach for mobile robot path tracking. *Fuzzy Systems, IEEE Transactions on*, 15(2), 211–221.
- Arduino UNO. (2017). Recuperado el 25 de Junio 2017, de <https://store.arduino.cc/arduino-uno-rev3>
- Åstrand, B., & Baerveldt, A.-J. (2005). A vision based row-following system for agricultural field machinery. *Mechatronics*, 15(2), 251–269.
- Bac, C. W., van Henten, E. J., Hemming, J., & Edan, Y. (2014). Harvesting Robots for High-value Crops: State-of-the-art Review and Challenges Ahead. *Journal of Field Robotics*, 31(6), 888–911.
- Bak, T., & Jakobsen, H. (2004). Agricultural robotic platform with four wheel steering for weed detection. *Biosystems Engineering*, 87(2), 125–136.
- Barawid, O. C., Mizushima, A., Ishii, K., & Noguchi, N. (2007). Development of an autonomous navigation system using a two-dimensional laser scanner in an orchard application. *Biosystems Engineering*, 96(2), 139–149.
- Barnard, S. T. (1983). Interpreting perspective images. *Artificial Intelligence*, 21(4), 435–462.

- Barrientos, A., Colorado, J., Cerro, J. del, Martinez, A., Rossi, C., Sanz, D., & Valente, J. (2011). Aerial remote sensing in agriculture: A practical approach to area coverage and path planning for fleets of mini aerial robots. *Journal of Field Robotics*, 28(5), 667–689.
- Bay, H., Tuytelaars, T., & Van Gool, L. (2006). Surf: Speeded up robust features. *Computer vision—ECCV 2006*, 404–417.
- Bengochea-Guevara, J. M., Burgos Artizzu, X. P., & Ribeiro, A. (2014). Real-time image processing for crop/weed discrimination in wide-row crops. In *Proceedings of RHEA*, Madrid, Spain,
- Bengochea-Guevara, J. M., Conesa-Muñoz, J., Andújar, D., & Ribeiro, A. (2016). Merge fuzzy visual servoing and GPS-based planning to obtain a proper navigation behavior for a small crop-inspection robot. *Sensors*, 16(3), 276.
- Bergerman, M., Van Henten, E., Billingsley, J., Reid, J., & Mingcong, D. (2013). IEEE robotics and automation society technical committee on agricultural robotics and automation. *IEEE Robotics & Automation Magazine*, 20(2), 20–23.
- Besl, P. J., & McKay, N. D. (1992). Method for registration of 3-D shapes. In *Robotics-DL tentative* (pp. 586–606). International Society for Optics and Photonics.
- Bevilacqua, A., Gherardi, A., & Carozza, L. (2008). Automatic perspective camera calibration based on an incomplete set of chessboard markers. In *Computer Vision, Graphics & Image Processing, 2008. ICVGIP'08. Sixth Indian Conference on* (pp. 126–133). IEEE.
- Bezdek, J. C., Ehrlich, R., & Full, W. (1984). FCM: The fuzzy c-means clustering algorithm. *Computers & Geosciences*, 10(2–3), 191–203.
- Billiot, B., Cointault, F., Journaux, L., Simon, J.-C., & Gouton, P. (2013). 3D Image Acquisition System Based on Shape de Focus Technique. *Sensors*, 13(4), 5040–5053.
- Birch, A. N. E., Begg, G. S., & Squire, G. R. (2011). How agro-ecological research helps to address food security issues under new IPM and pesticide reduction policies for global crop production systems. *Journal of Experimental Botany*, 62(10), 3251–3261.

- Blackmore, B. S., Griepentrog, H. W., Nielsen, H., Nørremark, M., & Resting-Jeppesen, J. (2004). Development of a deterministic autonomous tractor. In *Proceedings CIGR* (Vol. 11, p. 2004).
- Blas, M. R., & Blanke, M. (2011). Stereo vision with texture learning for fault-tolerant automatic baling. *Computers and Electronics in Agriculture*, 75(1), 159–168.
- Bochtis, D. D., & Sørensen, C. G. (2009). The vehicle routing problem in field logistics part I. *Biosystems Engineering*, 104(4), 447–457.
- Bossu, J., Gée, C., Guillemin, J. P., & Truchetet, F. (2006). Development of methods based on double Hough transform and Gabor filtering to discriminate crop and weeds in agronomic images. In *Proceedings of the SPIE 18th Annual Symposium Electronic Imaging Science and Technology* (Vol. 6070).
- Bossu, J., Gée, C., Jones, G., & Truchetet, F. (2009). Wavelet transform to discriminate between crop and weed in perspective agronomic images. *Computers and Electronics in Agriculture*, 65(1), 133–143.
- Burgos Artizzu, X. P. (2009). Percepción y Actuación para el tratamiento selectivo de malas hierbas en tiempo real. Tesis Doctoral. Universidad Complutense de Madrid.
- Burgos-Artizzu, X. P., Ribeiro, A., Guijarro, M., & Pajares, G. (2011). Real-time image processing for crop/weed discrimination in maize fields. *Computers and Electronics in Agriculture*, 75(2), 337–346.
- Burgos-Artizzu, X. P., Ribeiro, A., Tellaache, A., Pajares, G., & Fernández-Quintanilla, C. (2010). Analysis of natural images processing for the extraction of agricultural elements. *Image and Vision Computing*, 28(1), 138–149.
- Busemeyer, L., Mentrup, D., Möller, K., Wunder, E., Alheit, K., Hahn, V., & Ruckelshausen, A. (2013). BreedVision — A Multi-Sensor Platform for Non-Destructive Field-Based Phenotyping in Plant Breeding. *Sensors*, 13(3), 2830–2847.
- Case New Holland. (2017). Recuperado el 26 de Junio de 2017, de

- http://assets.cnhindustrial.com/caseih/NAFTA/NAFTAASSETS/Products/Advanced-Farming-Systems/Brochures/AFS_Brochure.pdf
- Chang, C., Chatterjee, S., & Kube, P. R. (1994). A quantization error analysis for convergent stereo. In *Image Processing, 1994. Proceedings. ICIP-94., IEEE International Conference* (Vol. 2, pp. 735–739). IEEE.
- Cheein, F. A., Steiner, G., Paina, G. P., & Carelli, R. (2011). Optimized EIF-SLAM algorithm for precision agriculture mapping based on stems detection. *Computers and Electronics in Agriculture*, 78(2), 195–207.
- Chen, J., Bautembach, D., & Izadi, S. (2013). Scalable real-time volumetric surface reconstruction. *ACM Transactions on Graphics (TOG)*, 32(4), 113.
- Chen, Y., & Medioni, G. (1992). Object modelling by registration of multiple range images. *Image and Vision Computing*, 10(3), 145–155.
- Chéné, Y., Rousseau, D., Lucidarme, P., Bertheloot, J., Caffier, V., Morel, P., & Chapeau-Blondeau, F. (2012). On the use of depth camera for 3D phenotyping of entire plants. *Computers and Electronics in Agriculture*, 82, 122–127.
- Christiansen, M. P., Jensen, K., Ellekilde, L.-P., & Jørgensen, R. N. (2011). Localization in orchards using Extended Kalman Filter for sensor-fusion-A FroboMind component.
- CLAAS. (2013). Recuperado el 26 de Junio de 2017, de http://www.claas.es/productos/easy/sistemas-de-guiado/sistemas-visuales-de-guiado/cam-pilot?subject=D10030100_es_ES
- Conesa-Muñoz, Jesus, Bengochea-Guevara, J. M., Andujar, D., & Ribeiro, A. (2016). Route planning for agricultural tasks: A general approach for fleets of autonomous vehicles in site-specific herbicide applications. *Computers and Electronics in Agriculture*, 127, 204–220.
- Conesa-Muñoz, Jesús, Gonzalez-de-Soto, M., Gonzalez-de-Santos, P., & Ribeiro, A. (2015). Distributed multi-level supervision to effectively monitor the operations of a fleet of

autonomous vehicles in agricultural tasks. *Sensors*, 15(3), 5402–5428.

Conesa-Muñoz, Jesus, Pajares, G., & Ribeiro, A. (2016). Mix-opt: A new route operator for optimal coverage path planning for a fleet in an agricultural environment. *Expert Systems with Applications*, 54, 364–378.

Cortner, A., Conrad, J. M., & BouSaba, N. A. (2012). Autonomous all-terrain vehicle steering. In *Southeastcon, 2012 Proceedings of IEEE* (pp. 1–5). IEEE.

Curless, B., & Levoy, M. (1996). A volumetric method for building complex models from range images. In *Proceedings of the 23rd annual conference on Computer graphics and interactive techniques* (pp. 303–312). ACM.

Debain, C., Malartre, F., Delmas, P., Chapuis, R., Humbert, T., & Berducat, M. (2010). Smart range finder and camera fusion-Application to real-time dense digital elevation map estimation. In *Robotics 2010, International workshop of Mobile Robotics for environment/agriculture*.

Deepfield Robotics. (2016). Recuperado el 26 de Junio de 2017, de <https://www.deepfield-robotics.com/>

Dobermann, A., Witt, C., Dawe, D., Abdulrachman, S., Gines, H. C., Nagarajan, R., ... others. (2002). Site-specific nutrient management for intensive rice cropping systems in Asia. *Field Crops Research*, 74(1), 37–66.

Downey, D., Giles, D. K., & Slaughter, D. C. (2004a). Pulsed-jet microspray applications for high spatial resolution of deposition on biological targets. *Atomization and Sprays*, 14(2).

Downey, D., Giles, D., & Slaughter, D. (2004b). Weeds accurately mapped using DGPS and ground-based vision identification. *California Agriculture*, 58(4), 218–221.

Earl, R., Wheeler, P. N., Blackmore, B. S., & Godwin, R. J. (1996). Precision farming—the management of variability. *Landwards*.

Eaton, R., Katupitiya, J., Siew, K. W., & Howarth, B. (2010). Autonomous farming: Modelling and control of agricultural machinery in a unified framework. *International Journal of Intelligent*

- Systems Technologies and Applications*, 8(1), 444–457.
- Edan, Y., Han, S., & Kondo, N. (2009). Automation in agriculture. In Springer handbook of automation (pp. 1095–1128). Springer.
- Eddershaw, T. (2014). IMAGING & Machine Vision Europe. *Europa Science*, 34–36.
- Edelsbrunner, H., & Mücke, E. P. (1994). Three-dimensional alpha shapes. *ACM Transactions on Graphics (TOG)*, 13(1), 43–72.
- Emmi, L., Gonzalez-de-Soto, M., Pajares, G., & Gonzalez-de-Santos, P. (2014). Integrating sensory/actuation systems in agricultural vehicles. *Sensors*, 14(3), 4014–4049.
- Engelhard, N., Endres, F., Hess, J., Sturm, J., & Burgard, W. (2011). Real-time 3D visual SLAM with a hand-held RGB-D camera. In *Proc. of the RGB-D Workshop on 3D Perception in Robotics at the European Robotics Forum*, Vasteras, Sweden (Vol. 180, pp. 1–15).
- Euler, L. (1775). Formulae generales pro translatione quacunque corporum rigidorum. *Novi Acad. Sci. Petrop*, 20(1775), 189–207.
- Eurostat. (2013). Recuperado el 26 de Junio de 2017, de http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=aei_fm_salpest09&lang=en
- Eurostat. (2016). Recuperado el 26 de Junio de 2017, de <http://ec.europa.eu/eurostat/web/agri-environmental-indicators/overview>
- Fankhauser, P., Bloesch, M., Rodriguez, D., Kaestner, R., Hutter, M., & Siegwart, R. (2015). Kinect v2 for mobile robot navigation: Evaluation and modeling. In *Advanced Robotics (ICAR)*, 2015 International Conference on (pp. 388–394). IEEE.
- Fraichard, T., & Garnier, P. (2001). Fuzzy control to drive car-like vehicles. *Robotics and Autonomous Systems*, 34(1), 1–22.
- García-Santillán, I. D., Montalvo, M., Guerrero, J. M., & Pajares, G. (2017). Automatic detection of curved and straight crop rows from images in maize fields. *Biosystems Engineering*, 156, 61–

79.

- Garrido, M., Paraforos, D. S., Reiser, D., Vázquez Arellano, M., Griepentrog, H. W., & Valero, C. (2015). 3D Maize Plant Reconstruction Based on Georeferenced Overlapping LiDAR Point Clouds. *Remote Sensing*, 7(12), 17077–17096.
- Gauss, C. F. (1809). *Theoria motus corporum coelestium in sectionibus conicis solem ambientium* auctore Carolo Friderico Gauss. sumtibus Frid. Perthes et IH Besser.
- Gebbers, R., & Adamchuk, V. I. (2010). Precision agriculture and food security. *Science*, 327(5967), 828–831.
- Gerhards, R. (2007). Managing weeds with respect to their spatial and temporal heterogeneity. In *Proceedings (abstracts) of the 2 nd Conference on Precision Crop Protection* (pp. 10–12).
- Gerhards, R., Sökefeld, M., Schulze-Lohne, K., Mortensen, D. A., & Kühbauch, W. (1997). Site specific weed control in winter wheat. *Journal of Agronomy and Crop Science*, 178(4), 219–225.
- Global Harvest Initiative. (2014). *Global Agricultural Productivity Report* (Global Harvest Initiative).
- Gomez-Gil, J., Alonso-Garcia, S., Gómez-Gil, F. J., & Stombaugh, T. (2011). A simple method to improve autonomous GPS positioning for tractors. *Sensors*, 11(6), 5630–5644.
- Gongal, A., Amatya, S., & Karkee, M. (2014). Identification of repetitive apples for improved crop-load estimation with dual-side imaging. In *Proceedings of the ASABE and CSBE/SCGAB Annual International Meeting*, Montreal, QC, Canada (pp. 13–16).
- Gonzalez-de-Santos, P., Ribeiro, A., Fernandez-Quintanilla, C., Lopez-Granados, F., Brandstoetter, M., Tomic, S., ... others. (2016). Fleets of robots for environmentally-safe pest control in agriculture. *Precision Agriculture*, 1–41.
- Gottschalk, R., Burgos-Artizzu, X. P., Ribeiro, A., & Pajares, G. (2010). Real-time image processing for the guidance of a small agricultural field inspection vehicle. *International Journal of*

- Intelligent Systems Technologies and Applications*, 8(1), 434–443.
- GPA Group Channel. (2017a). Recuperado el 27 de Junio de 2017, <https://www.youtube.com/watch?v=zCguZbg2rUw>
- GPA Group Channel. (2017b). Recuperado el 27 de Junio de 2017, https://www.youtube.com/watch?v=GrP69_YK8Yo&t=2s
- GPA Group Channel. (2017c). Recuperado el 27 de Junio de 2017, de <https://www.youtube.com/watch?v=F7Esr-M1qm8>
- Hague, T., Marchant, J. A., & Tillett, D. (1997). A system for plant scale husbandry. *Precision Agriculture*, 2, 635–642.
- Hague, T., Tillett, N. D., & Wheeler, H. (2006). Automated crop and weed monitoring in widely spaced cereals. *Precision Agriculture*, 7(1), 21–32.
- Hamner, B., Singh, S., Bergerman, M., & others. (2010). Improving orchard efficiency with autonomous utility vehicles. In *American Society of Agricultural and Biological Engineering Annual Convention* (Vol. 28).
- Hamouz, P. (2007). The Saving Potential of Site-Specific Weed Management in Winter Cereals. In *Proceedings 2nd Conference on Precision Crop Protection*.
- Hanawa, K., Yamashita, T., Matsuo, Y., & Hamada, Y. (2012). Development of a Stereo Vision System to Assist the Operation of Agricultural Tractors. *Japan Agricultural Research Quarterly: JARQ*, 46(4), 287–293.
- Hansen, S., Bayramoglu, E., Andersen, J. C., Ravn, O., Andersen, N., & Poulsen, N. K. (2011). Orchard navigation using derivative free Kalman filtering. In *American Control Conference (ACC)*, 2011 (pp. 4679–4684). IEEE.
- Herrero-Huerta, M., González-Aguilera, D., Rodríguez-Gonzálvez, P., & Hernández-López, D. (2015). Vineyard yield estimation by automatic 3D bunch modelling in field conditions. *Computers and Electronics in Agriculture*, 110, 17–26.

- Hertwich, E. (2010). Assessing the environmental impacts of consumption and production: priority products and materials. UNEP/Earthprint.
- Hilton, A., Stoddart, A., Illingworth, J., & Windeatt, T. (1996). Reliable surface reconstruction from multiple range images. *Computer Vision—ECCV'96*, 117–126.
- Hough, P. V. (1962). Method and means for recognizing complex patterns. *U.S. Patent No. 3,069,654*. Washington, DC: U.S. Patent and Trademark Office.
- I2C. (2017). Recuperado el 26 de Junio de 2017, de http://cache.nxp.com/documents/user_manual/UM10204.pdf
- IGN. (2017). Recuperado el 26 de Junio de 2017, de www.ign.es
- Izadi, S., Newcombe, R. A., Kim, D., Hilliges, O., Molyneaux, D., Hodges, S., & Fitzgibbon, A. (2011). Kinectfusion: real-time dynamic 3d surface reconstruction and interaction. In *ACM SIGGRAPH 2011 Talks* (p. 23). ACM.
- Jiang, L., Zhu, B., Cheng, X., Luo, Y., & Tao, Y. (2009). 3D Surface Reconstruction and Analysis in Automated Apple Stem-End/Calyx Identification. *Transactions of the ASABE*, 52(5), 1775–1784.
- John Deere. (2017). Recuperado el 26 de Junio de 2017, de https://www.deere.com/en_US/products/equipment/ag_management_solutions/guidance/autotracs2/autotracs2.page
- Johnson, A. E., & Kang, S. B. (1999). Registration and integration of textured 3D data. *Image and Vision Computing*, 17(2), 135–147.
- Kise, M., Zhang, Q., & Rovira Más, F. (2005). A stereovision-based crop row detection method for tractor-automated guidance. *Biosystems Engineering*, 90(4), 357–367.
- Kise, Michio, Noguchi, N., Ishii, K., & Terao, H. (2002). The development of the autonomous tractor with steering controller applied by optimal control. *Proceeding of the Automation Technology for Off-Road Equipment. Chicago-IL*.

- Kodagoda, K. R. S., Wijesoma, W. S., & Teoh, E. K. (2002). Fuzzy speed and steering control of an AGV. *Control Systems Technology, IEEE Transactions on*, 10(1), 112–120.
- Kropff, M. J., Wallinga, J., & Lotz, L. A. P. (2007). Modelling for Precision Weed Management. In *Ciba Foundation Symposium 210 - Precision Agriculture: Spatial and Temporal Variability of Environmental Quality* (pp. 182–207). John Wiley & Sons, Ltd.
- Ladybird. (2014). Recuperado el 26 de Junio de 2017, <http://confluence.acfr.usyd.edu.au/display/AGPub/Our+Robots>.
- Lafarge, T., & Pateiro-Lopez, B. (2016). Package Alphashape3d. Recuperado el 26 de Junio de 2017, de <https://cran.r-project.org/web/packages/alphashape3d/alphashape3d.pdf>
- Leemans, V., & Destain, M.-F. (2006). Application of the Hough transform for seed row localisation using machine vision. *Biosystems Engineering*, 94(3), 325–336.
- Li, L., Zhang, Q., & Huang, D. (2014). A review of imaging techniques for plant phenotyping. *Sensors*, 14(11), 20078–20111.
- Li, M., Imou, K., Wakabayashi, K., & Yokoyama, S. (2009). Review of research on agricultural vehicle autonomous guidance. *International Journal of Agricultural and Biological Engineering*, 2(3), 1–16.
- Libby, J., & Kantor, G. (2011). Deployment of a point and line feature localization system for an outdoor agriculture vehicle. In *Robotics and Automation (ICRA), 2011 IEEE International Conference on* (pp. 1565–1570). IEEE.
- Lino, A. C. L., & Fabbro, I. M. D. (2004). Fruit profilometry based on shadow Moiré techniques. *Ciência E Agrotecnologia*, 28(1), 119–125.
- Liu, F., & O'connell, N. V. (2002). Off-site movement of surface-applied simazine from a citrus orchard as affected by irrigation incorporation. *Weed Science*, 50(5), 672–676.
- Lorensen, W. E., & Cline, H. E. (1987). Marching cubes: A high resolution 3D surface construction algorithm. In *ACM siggraph computer graphics* (Vol. 21, pp. 163–169). ACM.

- Low, K.-L. (2004). Linear least-squares optimization for point-to-plane icp surface registration. *Chapel Hill, University of North Carolina*, 4.
- Lubuntu. (2017). Recuperado el 26 de Junio de 2017, de <http://lubuntu.net/>.
- Mallot, H. A., Bühlhoff, H. H., Little, J. J., & Bohrer, S. (1991). Inverse perspective mapping simplifies optical flow computation and obstacle detection. *Biological Cybernetics*, 64(3), 177–185.
- Mamdani, E. H. (1974). Application of fuzzy algorithms for control of simple dynamic plant. In *Proceedings of the institution of electrical engineers* (Vol. 121, pp. 1585–1588). IET.
- MAPAMA. (2015). Recuperado el 26 de Junio de 2017, de http://www.mapama.gob.es/es/estadistica/temas/estadisticas-agrarias/memofinalvinedo_tcm7-443391.pdf
- Marchant, J. A. (1996). Tracking of row structure in three crops using image analysis. *Computers and Electronics in Agriculture*, 15(2), 161–179.
- Marchant, John A., & Onyango, C. M. (2000). Shadow-invariant classification for scenes illuminated by daylight. *JOSA A*, 17(11), 1952–1961.
- Marshall, E. J. P. (1988). Field-scale estimates of grass weed populations in arable land. *Weed Research*, 28(3), 191–198.
- McQueen, J. (1967). Some methods for classification and analysis of multivariate observations. Paper presented at the 5th Berkeley Symposium on Mathematics, Statistics, and Probability. Univ. of Calif., Berkeley.
- Meyer, G. E., & Neto, J. C. (2008). Verification of color vegetation indices for automated crop imaging applications. *Computers and Electronics in Agriculture*, 63(2), 282–293.
- Microsoft. (2017). Recuperado el 26 de Junio de 2017, de <https://developer.microsoft.com/es-es/windows/kinect/develop>

- Moonrinta, J., Chaivivatrakul, S., Dailey, M. N., & Ekpanyapong, M. (2010). Fruit detection, tracking, and 3D reconstruction for crop mapping and yield estimation. In *Control Automation Robotics & Vision (ICARCV), 2010 11th International Conference on* (pp. 1181–1186). IEEE.
- Moreda, G. P., Ortiz-Cañavate, J., García-Ramos, F. J., & Ruiz-Altisent, M. (2009). Non-destructive technologies for fruit and vegetable size determination – A review. *Journal of Food Engineering*, 92(2), 119–136.
- Mulla, D. J. (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering*, 114(4), 358–371.
- Nagasaka, Y., Umeda, N., Kanetai, Y., Taniwaki, K., & Sasaki, Y. (2004). Autonomous guidance for rice transplanting using global positioning and gyroscopes. *Computers and Electronics in Agriculture*, 43(3), 223–234.
- Naio Technologies. (2016). Recuperado el 26 de Junio de 2017, de <http://www.naio-technologies.com/machines-agricoles/robot-de-desherbage-oz/>
- Nakarmi, A. D., & Tang, L. (2012). Automatic inter-plant spacing sensing at early growth stages using a 3D vision sensor. *Computers and Electronics in Agriculture*, 82, 23–31.
- Naranjo, J. E., Sotelo, M., Gonzalez, C., Garcia, R., & Sotelo, M. A. (2007). Using fuzzy logic in automated vehicle control. *Intelligent Systems, IEEE*, 22(1), 36–45.
- Newcombe, R. A., Izadi, S., Hilliges, O., Molyneaux, D., Kim, D., Davison, A. J., & Fitzgibbon, A. (2011). KinectFusion: Real-time dense surface mapping and tracking. In *Mixed and augmented reality (ISMAR), 2011 10th IEEE international symposium on* (pp. 127–136). IEEE.
- Nguyen, C. V., Izadi, S., & Lovell, D. (2012). Modeling kinect sensor noise for improved 3d reconstruction and tracking. In *3D Imaging, Modeling, Processing, Visualization and Transmission (3DIMPVT), 2012 Second International Conference on* (pp. 524–530). IEEE.

- Nießner, M., Dai, A., & Fisher, M. (2014). Combining Inertial Navigation and ICP for Real-time 3D Surface Reconstruction. In *Eurographics* (Short Papers) (pp. 13–16).
- Nießner, M., Zollhöfer, M., Izadi, S., & Stamminger, M. (2013). Real-time 3D reconstruction at scale using voxel hashing. *ACM Transactions on Graphics (TOG)*, 32(6), 169.
- NMEA. (2017). Recuperado el 26 de Junio de 2017, de http://www.nmea.org/content/nmea_standards/nmea_0183_v_410.asp
- Noguchi, N., Kise, M., Ishii, K., & Terao, H. (2002). Field automation using robot tractor. In *Proceedings of Automation Technology for off-road equipment* (pp. 239–245).
- Nvidia. (2017). Recuperado el 26 de Junio de 2017, de <http://www.nvidia.es/object/cuda-parallel-computing-es.html>
- Oerke, E.-C., Dehne, H.-W., Schönbeck, F., & Weber, A. (2012). Crop production and crop protection: estimated losses in major food and cash crops. Elsevier.
- Pajares, G., & De la Cruz, J. M. (2001). Visión por computador. *Imágenes Digitales Y Aplicaciones*. Ra-Ma.
- Paulus, S., Behmann, J., Mahlein, A.-K., Plümer, L., & Kuhlmann, H. (2014). Low-cost 3D systems: suitable tools for plant phenotyping. *Sensors*, 14(2), 3001–3018.
- Peña, J. M., Torres-Sánchez, J., de Castro, A. I., Kelly, M., & López-Granados, F. (2013). Weed mapping in early-season maize fields using object-based analysis of unmanned aerial vehicle (UAV) images. *PLoS One*, 8(10).
- Perez, A. J., Lopez, F., Benlloch, J. V., & Christensen, S. (2000). Colour and shape analysis techniques for weed detection in cereal fields. *Computers and Electronics in Agriculture*, 25(3), 197–212.
- Pérez-Ortiz, M., Peña, J. M., Gutiérrez, P. A., Torres-Sánchez, J., Hervás-Martínez, C., & López-Granados, F. (2015). A semi-supervised system for weed mapping in sunflower crops using unmanned aerial vehicles and a crop row detection method. *Applied Soft Computing*, 37,

533–544.

- Pérez-Ruiz, M., Gonzalez-de-Santos, P., Ribeiro, A., Fernández-Quintanilla, C., Peruzzi, A., Vieri, M., & Agüera, J. (2015). Highlights and preliminary results for autonomous crop protection. *Computers and Electronics in Agriculture*, 110, 150–161.
- Piron, A., Heijden, F. van der, & Destain, M. F. (2011). Weed detection in 3D images. *Precision Agriculture*, 12(5), 607–622.
- Polder, G., Lensink, D., & Veldhuisen, B. (2013). PhenoBot-a robot system for phenotyping large tomato plants in the greenhouse using a 3D light field camera. *Phenodays; Wageningen UR: Vaals, Holand*.
- Pomerleau, D. A. (1989). *Alvin: An autonomous land vehicle in a neural network*. DTIC Document.
- Pradhan, S. K., Parhi, D. R., & Panda, A. K. (2009). Fuzzy logic techniques for navigation of several mobile robots. *Applied Soft Computing*, 9(1), 290–304.
- Press, W. H., Flannery, B. P., Teukolsky, S. A., Vetterling, W. T., & Kramer, P. B. (1987). *Numerical recipes: the art of scientific computing*. AIP.
- Qt. (2017). Qt. Recuperado el 25 de Junio de 2017, de <http://www.qt.io/es/>
- Reddy, P. P. (2015). Climate resilient agriculture for ensuring food security (Vol. 373). Springer.
- Reid, J. F. (2011). The impact of mechanization on agriculture. *Bridge*, 41(3), 22–29.
- Rew, L. J., & Cousens, R. D. (2001). Spatial distribution of weeds in arable crops: are current sampling and analytical methods appropriate? *Weed Research*, 41(1), 1–18.
- Ribeiro, A., Fernández-Quintanilla, C., Barroso, J., García-Alegre, M. C., & Stafford, J. V. (2005). Development of an image analysis system for estimation of weed pressure. In *Precision agriculture '05. Papers presented at the 5th European Conference on Precision Agriculture, Uppsala, Sweden*. (pp. 169–174). Wageningen Academic Publishers.
- Rider, T. W., Vogel, J. W., Dille, J. A., Dhuyvetter, K. C., & Kastens, T. L. (2006). An economic

evaluation of site-specific herbicide application. *Precision Agriculture*, 7(6), 379–392.

Rodrigues, O. (1840). Des lois géométriques qui régissent les déplacements d'un système solide dans l'espace: et de la variation des coordonnées provenant de ces déplacements considérés indépendamment des causes qui peuvent les produire. *Journal de Mathématiques Pures et Appliquées*, 5, 380–440.

Romeo, J., Pajares, G., Montalvo, M., Guerrero, J. M., Guijarro, M., & Ribeiro, A. (2012). Crop row detection in maize fields inspired on the human visual perception. *The Scientific World Journal*, 2012.

ROS. (2017). Robot Operating System. Recuperado June 23, 2017, de <http://www.ros.org/>

Rosell, J. R., & Sanz, R. (2012). A review of methods and applications of the geometric characterization of tree crops in agricultural activities. *Computers and Electronics in Agriculture*, 81, 124–141.

Ross, P., English, A., Ball, D., Upcroft, B., Wyeth, G., & Corke, P. (2014). Novelty-based visual obstacle detection in agriculture. In *Robotics and Automation (ICRA)*, 2014 IEEE International Conference on (pp. 1699–1705). IEEE.

Rossetter, E. J., & Gerdes, J. C. (2002). Performance guarantees for hazard based lateral vehicle control. In *ASME 2002 International Mechanical Engineering Congress and Exposition* (pp. 731–738). American Society of Mechanical Engineers.

Roth, S. D. (1982). Ray casting for modeling solids. *Computer Graphics and Image Processing*, 18(2), 109–144.

Rovira-Más, F., Han, S., Wei, J., & Reid, J. F. (2007). Autonomous guidance of a corn harvester using stereo vision. *Agricultural Engineering International: The CIGR Ejournal, Manuscript ATOE*, 7, 013.

Rovira-Más, F., Zhang, Q., Reid, J. F., & Will, J. D. (2005). Hough-transform-based vision algorithm for crop row detection of an automated agricultural vehicle. *Proceedings of the*

- Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 219(8), 999–1010.
- Rovira-Más, Francisco, Chatterjee, I., & Sáiz-Rubio, V. (2015). The role of GNSS in the navigation strategies of cost-effective agricultural robots. *Computers and Electronics in Agriculture*, 112, 172–183.
- Ruiz, D., Escribano, C., & Fernández-Quintanilla, C. (2006). Assessing the opportunity for site-specific management of *Avena sterilis* in winter barley fields in Spain. *Weed Research*, 46(5), 379–387.
- Saeys, W., Lenaerts, B., Craessaerts, G., & De Baerdemaeker, J. (2009). Estimation of the crop density of small grains using LiDAR sensors. *Biosystems Engineering*, 102(1), 22–30.
- Sainz-Costa, N., Ribeiro, A., Burgos-Artizzu, X. P., Guijarro, M., & Pajares, G. (2011). Mapping wide row crops with video sequences acquired de a tractor moving at treatment speed. *Sensors*, 11(7), 7095–7109.
- Satow, T., Matsuda, K., Ming, S. B., Hironaka, K., & Tan, D. L. S. (2004). Development of laser crop row sensor for automatic guidance system of implements. In *Conference on Automation Technology for Off-road Equipment*, Kyoto, Japan.
- Šeatović, D., Kutterer, H., Anken, T., & Holpp, M. (2009). Automatic weed detection in grassland. In *Innovations to meet future challenges/Conference: Agricultural Engineering, Land. Technik-AgEng* (p. 530).
- Senay, G. B., Ward, A. D., Lyon, J. G., Fausey, N. R., & Nokes, S. E. (1998). Manipulation of high spatial resolution aircraft remote sensing data for use in site-specific farming. *Transactions of the ASAE*, 41(2), 489–495.
- Sheikholeslam, S., & Desoer, C. (1992). Design of decentralized adaptive controllers for a class of interconnected nonlinear dynamical systems. In *Decision and Control, 1992., Proceedings of the 31st IEEE Conference on* (pp. 284–288). IEEE.

- Slaughter, D. C., Giles, D. K., & Downey, D. (2008). Autonomous robotic weed control systems: A review. *Computers and Electronics in Agriculture*, 61(1), 63–78.
- Sobel, I. (1978). Neighborhood coding of binary images for fast contour following and general binary array processing. *Computer Graphics and Image Processing*, 8(1), 127–135.
- Søgaard, H. T., & Olsen, H. J. (2003). Determination of crop rows by image analysis without segmentation. *Computers and Electronics in Agriculture*, 38(2), 141–158.
- Spliid, N. H., & Køppen, B. (1998). Occurrence of pesticides in Danish shallow ground water. *Chemosphere*, 37(7), 1307–1316.
- Srinivasan, A. (2006). *Handbook of precision agriculture: principles and applications*. Food Products Press.
- Stafford, J. V. (2000). Implementing precision agriculture in the 21st century. *Journal of Agricultural Engineering Research*, 76(3), 267–275.
- Steinbrucker, F., Kerl, C., & Cremers, D. (2013). Large-scale multi-resolution surface reconstruction from RGB-D sequences. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 3264–3271).
- Stoll, A., & Kutzbach, H. D. (2000). Guidance of a forage harvester with GPS. *Precision Agriculture*, 2(3), 281–291.
- Subramanian, V., Burks, T. F., Dixon, W. E., & others. (2009). Sensor fusion using fuzzy logic enhanced Kalman filter for autonomous vehicle guidance in citrus groves. *Transactions of the ASAE*, 52(5), 1411–1422.
- Sugeno, M. (1999). On stability of fuzzy systems expressed by fuzzy rules with singleton consequents. *Fuzzy Systems, IEEE Transactions on*, 7(2), 201–224.
- Tellaeche, A., Burgos-Artizzu, X. P., Pajares, G., & Ribeiro, A. (2008). A vision-based method for weeds identification through the Bayesian decision theory. *Pattern Recognition*, 41(2), 521–530.

- Tellaeche, A., BurgosArtizzu, X. P., Pajares, G., Ribeiro, A., & Fernández-Quintanilla, C. (2008). A new vision-based approach to differential spraying in precision agriculture. *Computers and Electronics in Agriculture*, 60(2), 144–155.
- Tellaeche, A., Pajares, G., Burgos-Artizzu, X. P., & Ribeiro, A. (2011). A computer vision approach for weeds identification through Support Vector Machines. *Applied Soft Computing*, 11(1), 908–915.
- Teschner, M., Heidelberger, B., Müller, M., Pomerantes, D., & Gross, M. H. (2003). Optimized Spatial Hashing for Collision Detection of Deformable Objects. In *Vmv* (Vol. 3, pp. 47–54).
- Torres-Sánchez, J., López-Granados, F., Borra-Serrano, I., & Peña, J. M. (2017). Assessing UAV-collected image overlap influence on computation time and digital surface model accuracy in olive orchards. *Precision Agriculture*, 1–19.
- Torres-Sánchez, J., López-Granados, F., De Castro, A. I., & Peña-Barragán, J. M. (2013). Configuration and specifications of an unmanned aerial vehicle (UAV) for early site specific weed management. *PloS One*, 8(3).
- Torres-Sánchez, J., López-Granados, F., Serrano, N., Arquero, O., & Peña, J. M. (2015). High-throughput 3-D monitoring of agricultural-tree plantations with unmanned aerial vehicle (UAV) technology. *PloS One*, 10(6).
- Tsubota, Ryo, Noguchi, Noboru, & Mizushima, Akira. (2004). Automatic guidance with a laser scanner for a robot tractor in an orchard. In *Proceedings of the International Conference on Automation Technology for Off-road Equipment, ATOE* (pp. 369–373).
- Tyler Miller, G. (2002). *Sustaining the Earth: an Integrated Approach*. Toronto: Nelson Thompson Publishing.
- Ubuntu. (2017). Recuperado el 25 de Junio de 2017, de <http://www.ubuntu.com/>
- Van Evert, F. K., Van Der Heijden, G. W., Lotz, L. A., Polder, G., Lamaker, A., De Jong, A., ... Van der Zalm, T. (2006). A Mobile Field Robot with Vision-Based Detection of Volunteer Potato

Plants in a Corn Crop 1. *Weed Technology*, 20(4), 853–861.

Vazquez Arellamo, M., Reiser, D., Garrido Izaard, M., & Griepentrog, H. W. (2016). Reconstruction of geo-referenced maize plants using a consumer time-of-flight camera in different agricultural environments.

Vázquez-Arellano, M., Griepentrog, H. W., Reiser, D., & Paraforos, D. S. (2016). 3-D Imaging Systems for Agricultural Applications—A Review. *Sensors*, 16(5), 618.

Vioix, J.-B., Douzals, J.-P., Truchetet, F., Assémat, L., & Guillemin, J.-P. (2002). Spatial and spectral methods for weed detection and localization. *EURASIP Journal on Applied Signal Processing*, 2002(1), 679–685.

Wang, Q., Nuske, S., Bergerman, M., & Singh, S. (2013). Automated crop yield estimation for apple orchards. In *Experimental robotics* (pp. 745–758). Springer.

Wang, Q., Zhang, Q., Rovira-Más, F., & Tian, L. (2011). Stereovision-based lateral offset measurement for vehicle navigation in cultivated stubble fields. *Biosystems Engineering*, 109(4), 258–265.

Wang, W., & Li, C. (2014). Size estimation of sweet onions using consumer-grade RGB-depth sensor. *Journal of Food Engineering*, 142, 153–162.

Weiss, U., & Biber, P. (2011). Plant detection and mapping for agricultural robots using a 3D LIDAR sensor. *Robotics and Autonomous Systems*, 59(5), 265–273.

Weisz, R., Fleischer, S., & Smilowitz, Z. (1996). Site-specific integrated pest management for high-value crops: impact on potato pest management. *Journal of Economic Entomology*, 89(2), 501–509.

Wheeler, M. D., Sato, Y., & Ikeuchi, K. (1998). Consensus surfaces for modeling 3D objects de multiple range images. In *Computer Vision, 1998. Sixth International Conference on* (pp. 917–924). IEEE.

Whelan, T., Kaess, M., Fallon, M., Johansson, H., Leonard, J., & McDonald, J. (2012). Kintinuous:

- Spatially extended kinectfusion. In *Proc. Workshop RGB-D, Adv. Reason. Depth Cameras*, 2012, article 4.
- Woebbecke, D. M., Meyer, G. E., Von Bargen, K., & Mortensen, D. A. (1995). Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*, 38(1), 259–269.
- Wolff, A. (2012). *Phänotypisierung in Feldbeständen Mittels 3D-Lichtschnitt-Technik*. Söllingen, Germany: Strube Research GmbH.
- Wulder, M. A., White, J. C., Nelson, R. F., Næsset, E., Ørka, H. O., Coops, N. C., & Gobakken, T. (2012). Lidar sampling for large-area forest characterization: A review. *Remote Sensing of Environment*, 121, 196–209.
- Yang, C., Prasher, S. O., Landry, J.A., & Ramaswamy, H. S. (2003). Development of an image processing system and a fuzzy algorithm for site-specific herbicide applications. *Precision Agriculture*, 4(1), 5–18.
- Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338–353.
- Zeng, M., Zhao, F., Zheng, J., & Liu, X. (2013). Octree-based fusion for realtime 3D reconstruction. *Graphical Models*, 75(3), 126–136.
- Zhao, Y., Sun, Y., Cai, X., Liu, H., & Lammers, P. S. (2012). Identify Plant Drought Stress by 3D-Based Image. *Journal of Integrative Agriculture*, 11(7), 1207–1211.
- Zhou, Q.Y., & Koltun, V. (2013). Dense scene reconstruction with points of interest. *ACM Transactions on Graphics (TOG)*, 32(4), 112.