

UNIVERSIDAD COMPLUTENSE DE MADRID
FACULTAD DE INFORMÁTICA
DEPARTAMENTO DE INGENIERÍA DEL SOFTWARE
E INTELIGENCIA ARTIFICIAL



TESIS DOCTORAL

Métodos de visión por computador para detección automática de líneas de cultivo curvas/rectas y malas hierbas en campos de maíz

MEMORIA PARA OPTAR AL GRADO DE DOCTOR

PRESENTADA POR

Iván Danilo García Santillán

DIRECTOR

Gonzalo Pajares Martinsanz

Madrid, 2018

UNIVERSIDAD COMPLUTENSE DE MADRID

FACULTAD DE INFORMÁTICA

**Departamento de Ingeniería del Software e Inteligencia
Artificial**



**Métodos de visión por computador para detección
automática de líneas de cultivo curvas/rectas y malas
hierbas en campos de maíz**

MEMORIA PARA OPTAR AL GRADO DE DOCTOR

PRESENTADA POR

Iván Danilo García Santillán

Bajo la dirección del doctor

Gonzalo Pajares Martinsanz

Madrid, 2017

Dedicatoria

A mi esposa Sary y mis hijos Andy y Yamileth, motivo de mi esfuerzo y dedicación.

Agradecimientos

A la Facultad de Informática de la Universidad Complutense de Madrid (FDI-UCM) por la oportunidad de formar parte de tan prestigiosa Institución a nivel internacional.

A mi director de tesis, el Prof. Dr. Gonzalo Pajares, por su gran generosidad, paciencia y apoyo incondicional en todo momento durante esta larga travesía académica-científica, del cual aprendí mucho y sin su ayuda no habría podido llegar a estas instancias finales.

Al Prof. Dr. Narciso Martí Oliet, Vicedecano de posgrado de la FDI-UCM, por toda la colaboración brindada cuando se ha requerido.

A mis colegas del grupo de investigación ISCAR de la FDI-UCM: Martín Montalvo, José Miguel Guerrero, Juan Romeo, Yerania Campos; que tuve el gusto de conocerlos y compartir experiencias.

A la comunidad que conforma la Universidad Politécnica Estatal del Carchi – UPEC– (Tulcán, Ecuador) y la Universidad Técnica del Norte –UTN– (Ibarra, Ecuador) que contribuyeron significativamente a la culminación de la presente obra.

A todos ellos mis sentimientos de aprecio y gratitud.

Índice de contenidos

Resumen	- 15 -
Abstract.....	- 17 -
Capítulo 1. Introducción.....	- 19 -
1.1 Antecedentes.....	- 19 -
1.2 Descripción del problema.....	- 21 -
1.3 Motivación.....	- 23 -
1.4 Objetivos.....	- 25 -
1.5 Metodología.....	- 26 -
1.6 Aportes a la investigación	- 29 -
1.6.1 Publicaciones en Revistas Internacionales	- 29 -
1.6.2 Congreso Internacional	- 31 -
1.7 Organización de la tesis	- 31 -
Capítulo 2. Estado del arte	- 33 -
2.1 Introducción.....	- 33 -
2.2 Sistemas de visión por computador	- 33 -
2.2.1 Selección de la banda espectral	- 34 -
2.2.2 Parámetros intrínsecos del sistema de visión	- 39 -
2.2.2.1 Sensor de imagen	- 39 -
2.2.2.2 Sistema óptico.....	- 41 -
2.2.3 Parámetros extrínsecos del sistema de visión	- 43 -
2.2.4 Diseño del sistema de visión en el proyecto RHEA.....	- 45 -
2.3 Identificación de la vegetación	- 47 -
2.3.1 Métodos basados en índices de vegetación en el espectro visible	- 48 -
2.3.2 Procedimientos basados en umbralización.....	- 49 -
2.3.3 Enfoques basados en aprendizaje.....	- 50 -
2.3.4 Técnicas basadas en wavelets	- 51 -
2.3.5 Comparación de enfoques en la identificación de vegetación	- 52 -
2.4 Detección de líneas de cultivo	- 53 -
2.4.1 Transformada de Hough (TH).....	- 53 -
2.4.2 Regresión lineal.....	- 54 -
2.4.3 Exploración de franjas horizontales	- 56 -
2.4.4 Alineación de píxeles verdes.....	- 57 -

2.4.5 Punto de Fuga.....	- 57 -
2.4.6 Análisis de la frecuencia	- 57 -
2.4.7 Análisis de agrupaciones de píxeles.....	- 58 -
2.4.8 Visión estereoscópica.....	- 58 -
2.4.9 Patrones regulares	- 59 -
2.4.10 Comparación de técnicas para la detección de líneas de cultivo.....	- 59 -
Capítulo 3. Detección de líneas de cultivo rectas y curvas	- 63 -
3.1 Introducción.....	- 63 -
3.2 Materiales y métodos.....	- 65 -
3.2.1 Colección de imágenes.....	- 65 -
3.2.2 Arquitectura lógica del método de visión	- 68 -
3.2.2.1 Segmentación	- 68 -
3.2.2.2 Identificación de puntos de inicio	- 70 -
3.2.2.3 Detección de líneas de cultivo.....	- 73 -
3.2.3 Densidad de las malas hierbas.....	- 87 -
3.2.4 Batería de imágenes (ground truth).....	- 87 -
3.3 Resultados y discusión	- 88 -
3.3.1 Análisis comparativo y medidas de rendimiento	- 89 -
3.3.2 Evaluación de los métodos propuestos	- 91 -
3.3.3 Impacto de la curvatura.....	- 97 -
3.3.4 Consideraciones adicionales	- 98 -
Capítulo 4. Discriminación de cultivo y malas hierbas.....	- 99 -
4.1 Introducción.....	- 99 -
4.2 Materiales y métodos.....	- 100 -
4.2.1 Colección de imágenes.....	- 100 -
4.2.2 Arquitectura del método de visión	- 102 -
4.2.2.1 Segmentación	- 104 -
4.2.2.2 Entrenamiento	- 107 -
4.2.2.3 Pruebas	- 109 -
4.3 Resultados y discusión	- 111 -
Capítulo 5. Conclusiones y trabajo futuro	- 119 -
5.1 Conclusiones.....	- 119 -
5.2 Trabajo futuro	- 122 -
Referencias	- 125 -

Índice de Figuras

Fig. 2.1	Efecto de un filtro de corte UV/IR: (a) sin filtro; (b) con filtro.	36
Fig. 2.2	Efecto de <i>vignetting</i>	37
Fig. 2.3	Balance de blancos: (a) imagen original; (b) imagen corregida.	38
Fig. 2.4	Reflectancia espectral típica para el cultivo y suelo.	38
Fig. 2.5	Configuración de un sistema óptico genérico.	42
Fig. 2.6	Geometría del sistema de visión.	43
Fig. 2.7	Sistema de visión por computador.	45
Fig. 2.8	Discriminación de la vegetación y las malas hierbas.	47
Fig. 2.9	Ejemplos de ROIs con líneas de cultivo detectadas.	53
Fig. 3.1	Ejemplos ilustrativos de las imágenes obtenidas en el campo de cultivo.	66
Fig. 3.2	Localización de la ROI en la imagen original RGB.	67
Fig. 3.3	Arquitectura lógica del método de visión por computador.	69
Fig. 3.4	Imágenes después de aplicar <i>ExG</i> , doble umbralización y morfología.	71
Fig. 3.5	Localización de los puntos de inicio en la franja inferior de la ROI.	71
Fig. 3.6	ROI después de aplicar la dilatación y división en sub-franjas horizontales.	74
Fig. 3.7	Parte de la ROI mostrando tres puntos (1-3) dentro de la franja inferior.	75
Fig. 3.8	Parte de la ROI mostrando dos puntos <i>A</i> y <i>B</i> en la franja superior.	75
Fig. 3.9	Parte de la ROI mostrando dos puntos <i>C</i> y <i>D</i> dentro de la franja superior.	76
Fig. 3.10	Parte de la ROI mostrando parábolas ajustadas por mínimos cuadrados.	76
Fig. 3.11	Parte de la ROI con cinco puntos significativos en la línea de cultivo.	77
Fig. 3.12	Conjunto de cinco puntos significativos sobre cada línea de cultivo.	78
Fig. 3.13	División de la ROI en dos franjas horizontales de igual longitud.	79
Fig. 3.14	Primera micro-ROI ubicada en la primera subfranja de la ROI.	80
Fig. 3.15	Ejemplos de casos especiales: malas hierbas y discontinuidades.	80
Fig. 3.16	Cuarta micro-ROI colocada en la cuarta subfranja de la ROI.	81
Fig. 3.17	Quinta micro-ROI colocada en la quinta subfranja de la ROI.	82
Fig. 3.18	Doceava micro-ROI colocada en la doceava subfranja de la ROI.	82
Fig. 3.19	Ubicación de las micro-ROIs en cada línea de cultivo dentro de la ROI.	83
Fig. 3.20	Gráficas de dos polinomios ajustados a cada línea de cultivo de la ROI.	84
Fig. 3.21	Proceso de verificación para las líneas de cultivo detectadas.	86

Fig. 3.22	Reflexión especular vertical sobre líneas orientadas hacia la derecha.	87
Fig. 3.23	ROIs con las métricas CRDA y CRDA* para DAGP y DBMR	92
Fig. 4.1	Ilustraciones de imágenes procesadas por el método ODMD.	101
Fig. 4.2	Delimitación de la ROI y detección de líneas de cultivo.	102
Fig. 4.3	Arquitectura del método de visión propuesto.	103
Fig. 4.4	Imágenes después de aplicar <i>ExG</i> y umbralización basada en Otsu.	105
Fig. 4.5	Ilustración de la ROI con cuatro líneas de cultivo y márgenes respectivos. ...	105
Fig. 4.6	Imágenes binarias o máscaras	106
Fig. 4.7	Píxeles que representan las clases de malas hierbas inter-líneas y cultivos. ...	107
Fig. 4.8	Distribución de los píxeles <i>RGB</i> en el espacio R^3 con el centroide	108
Fig. 4.9	Clasificación y refinamiento de píxeles de la clase cultivo	111
Fig. 4.10	Discriminación cultivo/malas hierbas aplicando Mahalanobis	112
Fig. 4.11	División de la ROI en 20 sub-imágenes de igual tamaño (300×150)	112
Fig. 4.12	Ejemplos del <i>ground-truth</i>	113
Fig. 4.13	Identificación cultivo/malas hierbas utilizando Mahalanobis y filtrado.	115
Fig. 4.14	Ejemplos de clasificaciones sin y con refinamiento.	116

Índice de Tablas

Tabla 2.1	Banda espectral (S) y longitud de onda λ (nm)	35
Tabla 2.2	Comparación de enfoques para la identificación de la vegetación.	52
Tabla 2.3	Comparativa de técnicas para la detección de líneas de cultivo.....	60
Tabla 3.1	Métrica CRDA para las pruebas realizadas en líneas rectas de cultivo.	93
Tabla 3.2	CRDA sobre líneas de cultivo curvas espaciadas regularmente	94
Tabla 3.3	CRDA* sobre las líneas de cultivo espaciadas irregularmente	94
Tabla 3.4	Tiempo de ejecución para cada módulo del método DBMR	95
Tabla 3.5	Tiempo de ejecución para cada módulo del método DAGP	96
Tabla 3.6	Tiempo de ejecución para los métodos TMGEM, DAGP y DBMR.....	97
Tabla 3.7	Valores permitidos para los coeficientes de grado superior	98
Tabla 4.1	Exactitud y Kappa (k) para los clasificadores: Mahalanobis y Euclidiano ..	114
Tabla 4.2	Grado de acuerdo asociado con el estadístico Kappa.....	114
Tabla 4.3	Aciertos obtenidos por los métodos SVM, LVQ, AES y ODMD.....	117
Tabla 4.4	Tiempo de procesamiento para cada módulo del ODMD.	118

Abreviaturas

CRD	<i>Crop Row Detection</i>
CRDA	<i>Crop Row Detection Accuracy</i>
CRDA*	<i>slight variant of CRDA</i>
DAGP	<i>Detection by Accumulation of Green Pixels</i>
DBMR	<i>Detection Based on Micro-ROIs</i>
ExG	<i>Excess Green</i>
GNSS	<i>Global Navigation Satellite Systems</i>
GPS	<i>Global Positioning System</i>
HT	<i>Hough Transform</i>
LRQ	<i>Linear Regression based on least squares</i>
LTS	<i>Linear regression based on the Theil-Shen estimator</i>
RHEA	<i>Robotics and associated High-technologies and Equipment for Agriculture and forestry</i>
ROI	<i>Region of Interest</i>
RTK-GPS	<i>Real Time Kinematics-Global Positioning System</i>
TMGEM	<i>Template Matching followed by Global Energy Minimization</i>

Resumen

Cada día es mayor el uso de sistemas de visión por computador a bordo de vehículos autónomos para agricultura de precisión y su utilización en distintas tareas, demandando una atención especial. La discriminación entre cultivo y malas hierbas así como la identificación de las líneas de cultivo en imágenes obtenidas en campos de maíz (cultivo de surcos anchos) representan importantes retos, tanto desde el punto de vista de la aplicación de tratamientos selectivos como para un guiado preciso en la navegación de los mencionados vehículos.

En cualquier caso, la calidad de las imágenes se ve afectada por las condiciones de iluminación no controladas en entornos agrícolas de exterior. Además, diferentes alturas y volúmenes de las plantas que se manifiestan por los distintos estados de crecimiento y la presencia de discontinuidades a lo largo de las líneas de cultivo debido a una mala germinación o defectos durante la siembra, dificultan los procesos de detección de líneas de cultivo y discriminación entre cultivo y malas hierbas. Las imágenes fueron tomadas bajo proyección de perspectiva con una cámara instalada a bordo del tractor y convenientemente colocada en la parte frontal.

Con respecto a la detección de las líneas de cultivo, se han propuesto dos nuevos métodos para la detección de líneas curvas y rectas en campos de maíz durante los estados iniciales de crecimiento del cultivo y malas hierbas. El objetivo final es la identificación de las líneas de cultivo con dos propósitos: a) guiado preciso en vehículos autónomos; b) tratamientos específicos, incluyendo la eliminación de malas hierbas, situadas entre las líneas. Los métodos propuestos se diseñaron con la robustez requerida para abordar el problema de las condiciones adversas indicadas previamente y constan de tres fases consecutivas: (i) segmentación de la imagen, (ii) identificación de los puntos de comienzo de las líneas de cultivo y (iii) detección de las propias líneas. La principal contribución de estos métodos estriba en su capacidad para detectar líneas de cultivo curvas y rectas con espaciados regulares o irregulares entre las líneas, incluso cuando coexisten tipos de líneas en el mismo campo e imagen. Ambos métodos, difieren entre ellos en la fase de detección. Uno se basa en la acumulación de píxeles verdes y el otro en lo que se conoce como concepto de micro-ROIs (*Region Of Interest*). Los rendimientos de los métodos propuestos se compararon cuantitativamente frente a

cinco estrategias existentes, consiguiendo precisiones entre el 86.3% y el 92.8%, dependiendo de si las líneas de cultivo son curvas o rectas con espaciado regular o irregular, con tiempos de procesamiento menores que 0.64 s por imagen.

Con respecto a la discriminación entre cultivo y malas hierbas, se ha diseñado un método automático basado en un criterio de mínima distancia de Mahalanobis, que deriva del clásico método de clasificación Bayesiano. Se basa en la similitud de las componentes espectrales, de suerte que es posible cuantificar de forma más precisa las malas hierbas situadas entre las líneas de cultivo y en las propias líneas, entremezcladas con el cultivo, cuyo objetivo final es la aplicación de tratamientos específicos, incluyendo su eliminación. Este método requiere de la aplicación de un proceso previo de detección de las líneas de cultivo. El método propuesto se diseñó de una forma suficientemente robusta para tratar con las situaciones adversas mencionadas previamente, constando de las tres fases siguientes consecutivas: (i) segmentación, (ii) entrenamiento y (iii) prueba. Las tres fases se ejecutan de forma on-line para cada imagen, siendo el entrenamiento específico de cada una de las imágenes, no precisando entrenamiento previo, a diferencia de lo que ocurre en los procesos de aprendizaje automático clásicos. Este hecho proporciona una primera contribución a la investigación. Además, el método identifica separadamente las malas hierbas entre las líneas de cultivo y entre las propias líneas, aportando así una segunda contribución a la investigación en esta temática. El rendimiento de la propuesta fue comparado favorablemente frente a tres estrategias de aprendizaje, consiguiendo exactitudes de aproximadamente el 90.1% que se sitúan al mismo nivel o superior sobre las mismas y sin necesidad de entrenamiento previo, con tiempos de procesamiento menores o iguales a 280 ms, siendo suficientes desde el punto de vista de aplicaciones en tiempo real.

Con ambas estrategias, relativas tanto a la detección de las líneas de cultivo rectas y curvas como a la discriminación entre cultivo y malas hierbas, se han obtenido resultados satisfactorios para su uso en vehículos autónomos equipados con sistemas de visión por computador en tiempo real para agricultura de precisión.

Palabras clave: *discriminación cultivo/malas hierbas, detección de líneas de cultivo, distancia de Mahalanobis, acumulación de píxeles verdes, micro-ROI, segmentación de imágenes, visión por computador, guiado automático.*

Abstract

The use of automatic machine vision systems onboard autonomous vehicles in precision agriculture is being widely used for different tasks demanding special attention. Crop/weed discrimination and crop rows detection in images captured from maize fields (wide row crops) represent important challenges for site-specific treatments and precise guidance for navigation purposes. This thesis addresses both problems with specific improvements with respect existing approaches. Image quality is affected by uncontrolled lighting conditions in outdoor agricultural environments. Also different plant (crops, weeds) heights, volumes and gaps along the crop rows due to lack of germination or defects during planting appear due to different growth stages affecting the crop/weed identification and the crop row detection process. The images were obtained under imaging perspective projection with a camera installed on board and conveniently arranged at the front part of a tractor.

Regarding crop row detection, two new methods have been proposed for detecting curved and straight crop rows in images captured in maize fields during the initial growth stages of crop and weed plants. The final goal is the identification of the crop rows with two purposes: a) precise autonomous guidance; b) site-specific treatments, including weed removal, where weeds are identified as plants outside the crop rows. The proposed methods were designed with the required robustness to cope with the above adverse situations and consist of three linked phases: (i) image segmentation, (ii) identification of starting points for determining the beginning of the crop rows and (iii) crop rows detection. The main contribution of these methods is the ability to detect curved and straight crop rows having regular or irregular inter-row spacing, even when both row types coexist in the same field and image. Both approaches differ among them in the crop rows detection phase. One is based on the accumulation of green pixels and the other in the micro-ROI (Region Of Interest) concept. The performances of the proposed approaches were quantitatively compared against five existing strategies, achieving accuracies between 86.3% and 92.8%, depending on whether crop rows were straight/curved with regular or irregular spacing, with processing times less than 0.64 s per image.

Regarding crop and weeds discrimination, an automatic approach is designed by applying a minimum criterion distance based on the Mahalanobis distance derived from

a Bayesian classification approach. The minimum distance is determined based on spectral similarities, where the intra- and inter-row weeds turns out to be useful for a more accurate weed quantification for site-specific treatments, including weed removal, based on the identification of plants outside the crop rows. The proposed approach requires a previous process of crop row detection. The proposed method was designed to be robust enough to deal with the above undesired outdoor situations and it consists of three linked phases: (i) segmentation, (ii) training and (iii) testing. The three phases are executed on-line for each image, where training is specific of each single image, requiring no prior training, as it is usual in common machine learning-based approaches. This makes the first contribution of this thesis. In addition, the method identifies separately both kinds inter- and intra-row weed. This makes the second research contribution in the research. The performance of the proposed approach was quantitatively compared against three existing machine learning strategies, achieving an accuracy of about 90.1% with similar or above performance than those strategies, always with processing times lower or equal than 280 ms, which are sufficient for real time applications.

Both strategies, curved and straight crop rows detection and crop and weeds discrimination, have achieve satisfactory results for their use on autonomous agricultural vehicles equipped with computer vision systems for real-time applications on precision agriculture.

Keywords: *crop/weed discrimination, crop rows detection, Mahalanobis distance, accumulation of green pixels, micro-ROI, image segmentation, machine vision, automatic guidance.*

CAPÍTULO 1

Introducción

1.1 Antecedentes

Los sistemas de visión por computador aplicados a las tareas agrícolas tienen un gran potencial, como indican Brosnan y Sun (2002) y Davies (2009). El uso de la tecnología, incluyendo los sistemas de visión a bordo de vehículos autónomos, en las aplicaciones agrícolas puede reducir las tareas manuales, el costo de producción del cultivo (Barreda et al., 2009) y contribuir a la productividad y competitividad de los agricultores, asegurando los suministros agrícolas. El uso exclusivo de métodos agrícolas tradicionales, sin incorporar la tecnología, puede llevar al uso indiscriminado de químicos (herbicidas, fertilizantes), incrementando el coste de producción, deterioro del suelo y la contaminación ambiental (Astrand and Baerveldt, 2005; Kataoka et al., 2003).

La necesidad de crear mecanismos autónomos capaces de evaluar las características visuales de una escena en el campo de cultivo y tomar decisiones a partir del conjunto de información que recogen es cada vez mayor. La revolución tecnológica de la electrónica y la informática ha alcanzado, entre otras, a la ingeniería agronómica, lo que ha llevado al auge de nuevos campos de investigación como la agricultura de precisión o el guiado automático de vehículos agrícolas en tiempo real, que presentan un futuro prometedor (Rovira-Más et al., 2003).

En este contexto, nace la presente investigación doctoral que fue inspirada y tiene sus orígenes en el Proyecto *Robot fleets for Highly Effective Agriculture and forestry management* (RHEA, 2014), financiado por la Unión Europea, el cual fue destinado para tareas de agricultura de precisión en los campos de maíz, trigo y olivar. En este proyecto, una flota de vehículos autónomos (terrestres y aéreos) equipados con diferentes sensores, todos incluyendo un sistema de visión por computador, fueron una parte importante de los elementos innovadores usados para tal propósito. El sistema de visión por computador a bordo de los vehículos autónomos fue la pieza más importante de todo el sistema de percepción, específicamente para el control efectivo de las malas hierbas en los campos de maíz (cultivo de línea ancha).

Las principales tareas del sistema de visión por computador en el Proyecto RHEA estuvieron destinadas a tratar principalmente: (i) la detección automática de las líneas de cultivo o surcos (Romeo et al., 2012; Guerrero et al., 2013; Montalvo et al.,

2012a), (ii) identificación de las malas hierbas para tratamientos selectivos (Romeo et al., 2013a; Guerrero et al., 2012; Montalvo et al., 2013), (iii) guiado preciso de vehículos autónomos basado en el seguimiento de las líneas de cultivo (Li et al., 2009; Rovira-Más et al., 2003), (iv) y la detección de obstáculos para propósitos de seguridad (Xue et al., 2012; Campos et al., 2016). El alcance del presente trabajo doctoral cubre los dos primeros temas de investigación, por ser tareas comunes de vital importancia en la agricultura de precisión.

En la misma dinámica del Proyecto RHEA (2014), el objetivo de esta investigación doctoral es diseñar nuevos métodos de visión por computador para la detección automática de líneas de cultivo y la discriminación del cultivo y los rodales de malas hierbas. Estos procesos resultan de utilidad para el guiado de vehículos agrícolas (tractor) de forma que no cause daños mayores al campo de cultivo, y a futuro prescindir del operador humano de la maquinaria; así como también para la cuantificación de las malas hierbas y la aplicación de tratamientos selectivos. Además, una vez que el vehículo pueda navegar de forma autónoma en el campo, se podría utilizar sensores adicionales para la obtención de otros tipos de información, tales como: el grado de maduración, rendimiento productivo, necesidades hídricas, uniformidad de la cosecha, detección precoz de infestaciones por enfermedades y plagas.

Aunque varios trabajos, antes mencionados, fueron propuestos para tratar adecuadamente con los problemas planteados en el marco del Proyecto RHEA, algunos asuntos no se abordaron en profundidad. Específicamente, (i) la detección de líneas *curvas* de cultivo y (ii) la identificación de las malas hierbas *intra-fila*, es decir, aquellas malas hierbas localizadas dentro de la misma línea que el cultivo, de forma entrelazada y solapada, conteniendo similares firmas espectrales (colores rojos, verdes y azules). Estos dos problemas son abordados en el presente trabajo doctoral, constituyendo las principales contribuciones de investigación.

Asimismo, la investigación es pertinente y de singular importancia para la complementación de los trabajos desarrollados en el Proyecto RHEA, debido a la profundización y aporte en los temas de interés mencionados. En la misma vía para la Universidad Complutense de Madrid (España), como miembro del consorcio del proyecto RHEA; y para las universidades de Ecuador, Universidad Técnica del Norte y la Universidad Politécnica Estatal del Carchi (donde el autor principal labora como docente titular auxiliar), por su contribución a la innovación tecnológica del sector agrícola y las zonas de influencia.

1.2 Descripción del problema

La necesidad de automatizar las tareas en la agricultura con la finalidad de mejorar la producción agrícola y disminuir la contaminación ambiental no es exclusiva de los países del primer mundo. Los países en vías de desarrollo (como Ecuador) también requieren aplicar la tecnología en el sector agrícola, que resulte pertinente al contexto y las realidades/características propias de las regiones.

Ecuador es un país latinoamericano que basa principalmente su economía en la explotación del petróleo y la exportación de ciertos recursos marinos (p. ej. camarón, atún) y agrícolas (banano, cacao, flores). Específicamente, la provincia del Carchi, donde gran parte de la investigación fue llevada a cabo, depende mayoritariamente de la actividad agropecuaria (GPC, 2011; Senplades, 2015). Los productos agrícolas (p. ej. papa, maíz, haba, quinua, arveja, fréjol, cebolla) y ganaderos (carne, leche) que se producen en esta zona abastecen al consumo interno del norte del Ecuador y parte del sur de Colombia. Las labores agrícolas se han realizado históricamente utilizando técnicas tradicionales y manuales de cultivo, que entre otros problemas generan la baja calidad de los productos, altos costes de producción y contaminación del suelo. Por lo que la incorporación de tecnología en el sector del agro, para automatizar ciertas tareas, resulta vital para minimizar los efectos adversos ya mencionados, con la consecuente contribución a la mejora de la calidad de vida de los agricultores y la población de la provincia, así como el aseguramiento de la soberanía alimentaria de la región.

La automatización de los procesos agrícolas utilizando sistemas de visión por computador, instalados a bordo de vehículos agrícolas, está ganando una relevancia importante hoy en día. La detección de líneas de cultivo (fila ancha) es un problema mayúsculo para (i) la identificación de malas hierbas y (ii) el guiado autónomo preciso. En el primer caso, la discriminación de cultivo/malas hierbas ha recibido especial dedicación en la agricultura de precisión. En efecto, las plantas localizadas dentro de los espacios entre las filas de cultivo pueden ser consideradas como malas hierbas con alta probabilidad, requiriendo la aplicación de tratamientos selectivos (Emmi et al., 2014; RHEA, 2014). Además, la identificación de las malas hierbas intra-fila (localizadas dentro del mismo surco) es una tarea determinante. Sin embargo, este problema es complejo de tratar, debido a que el cultivo y las malas hierbas intra-fila se encuentran entrelazados y solapados, con un alto grado de similitud en sus firmas espectrales. En el segundo caso, la navegación en tractores autónomos está principalmente basada en el

sistema de posicionamiento global (*GPS* en inglés), y aunque esta tecnología proporciona una buena precisión (Emmi et al. 2014) para el guiado, cuando ocurren pequeñas desviaciones, la detección de las líneas de cultivo es crucial para la corrección precisa (Kise & Zhang, 2008; Rovira-Más et al., 2003).

Existen otras dificultades que afectan los procesos de identificación del cultivo/malas hierbas y la detección de líneas de cultivo, como: (i) las condiciones de iluminación no controlada, destacando principalmente sombras y excesiva o pobre iluminación, comunes en los entornos agrícolas por ser de exterior, que deterioran la calidad de la imagen; (ii) diferentes alturas y volúmenes de plantas (cultivos, malas hierbas); (iii) discontinuidades o huecos libres de plantas presentes en las filas de cultivo por la falta de germinación, defectos en la siembra, enfermedades o plagas; (iv) alta densidad de malas hierbas, con gran similitud en la firma espectral con respecto al cultivo; (v) líneas de cultivo curvadas y con espacios irregulares entre hileras; (vi) movimientos del tractor o desviaciones durante la navegación debido a los terrenos accidentados dada su orografía.

Varias soluciones han sido propuestas para hacer frente a las situaciones adversas mencionadas, tanto para la discriminación entre cultivo y malas hierbas (Ahmed et al., 2012, Guerrero et al., 2012, Tellaeche et al., 2011, Montalvo et al., 2012b) como para la detección de las líneas de cultivo (Hague et al., 2006; Ramírez, 2013; Ribeiro et al., 2005; Vidović et al., 2016). Algunas de ellas combinan varias técnicas y todas aplican algún tipo de conocimiento *a priori*, traducido como restricciones para disminuir la complejidad computacional (número de líneas de cultivo a detectar, espacio entre líneas, posición y orientación esperada, punto de fuga en la proyección de perspectiva, parámetros intrínsecos y extrínsecos de la cámara).

Sin embargo, debido a la dificultad intrínseca involucrada en los entornos agrícolas, un esfuerzo extra de investigación es todavía requerido. Concretamente, para la discriminación de cultivo/malas hierbas sin necesitar un proceso de entrenamiento exhaustivo como ocurre con las técnicas de aprendizaje supervisado; así como también, para la detección de líneas de cultivo con curvatura, las cuales pueden ser comunes en algunas regiones agrícolas debido a la orografía del terreno, incluyendo terrazas accidentadas con pendientes considerables. En este caso, las líneas curvadas suelen ser el arreglo común en el campo para evitar la erosión del suelo causado por el agua de la irrigación natural o artificial. Además, estas curvas no solo aparecen en terrazas agrícolas, sino también en parcelas planas de tierra con una geometría irregular.

Adicionalmente de los problemas ya referidos, se deben considerar también varios asuntos concernientes a los sistemas de visión por computador a bordo de vehículos agrícolas, ya que resultan ser de gran relevancia para la efectividad y eficiencia del sistema de visión por computador (Pajares et al., 2016). Estos son: (i) la selección de la banda espectral; (ii) sensor de imagen y el sistema óptico (parámetros intrínsecos); (iii) arreglo y pose del sistema visual (parámetros extrínsecos); (iv) determinación de la región de interés (*Region of Interest*, ROI) y el campo de visión; (v) compromiso entre las especificaciones del sistema de visión y su rendimiento desde el punto de vista del procesamiento de las imágenes. Las respuestas a éstas y otras cuestiones problemáticas son cruciales, las cuales deben ser consideradas para cualquier diseño de ingeniería considerando los sistemas de visión computacional.

De acuerdo con las complejidades descritas, se sugiere una nueva estrategia basada en visión por computador para (i) la discriminación del cultivo/malas hierbas en cultivos de línea ancha (entre 35 y 95 cm de separación), enfocándose en las malas hierbas entremezcladas y solapadas con las plantas de maíz dentro del mismo surco, así como también para (ii) la detección de líneas de cultivo curvas y rectas, espaciadas de forma regular e irregular, incluso con ambos tipos de líneas coexistiendo en la misma imagen, es decir, en el campo de cultivo. Ambos procedimientos destinados a tratar con las condiciones adversas señaladas previamente, con la máxima precisión posible y rendimientos adecuados en términos de exactitud y eficiencia y con potencial para aplicaciones en tiempo real.

1.3 Motivación

El presente trabajo de investigación tiene su origen en dos proyectos:

- a) El primero, enmarcado en la investigación realizada por el grupo ISCAR, oficialmente reconocido por la Universidad Complutense de Madrid, en la línea de investigación de Ingeniería del Software e Inteligencia Artificial, a través del Proyecto RHEA (2014), financiado por la Unión Europea dentro del VII Programa Marco de Investigación y Desarrollo tecnológico (FP7) durante los años 2010-2014. El proyecto RHEA se diseñó para agricultura de precisión, cuyo objetivo fue diseñar tres prototipos que forman parte de una flota de tractores robotizados y coordinados, en conjunción con vehículos aéreos no tripulados (drones). Cada uno de los prototipos robotizados actuaba en tres campos de cultivo: maíz, cereal y olivos. Los tres tractores fueron equipados con distintas tecnologías sensoriales con el objetivo

de realizar la navegación autónoma y la localización de las áreas de interés, para la aplicación de tratamientos selectivos, con el fin de eliminar malas hierbas en el cereal y maíz, y combatir plagas en el olivar, minimizando el uso de agroquímicos, a la vez que se reducen los costes de producción, tiempo y energía. El grupo ISCAR se centró específicamente en el tractor dedicado al cultivo de maíz, que fue equipado con un sistema de visión instalado en la parte superior, mediante el cual se llevaron a cabo procesos para la detección de líneas de cultivo, así como también, para la identificación de malas hierbas localizadas fuera de las líneas de cultivo (inter-líneas). La investigación doctoral plasmada en este documento aborda dos temas que fueron identificados como trabajos a futuro en el Proyecto RHEA. (i) La detección de líneas de cultivo *curvas* y rectas y (ii) la identificación de malas hierbas inter- e *intra-línea*. Estas temáticas representan la contribución en la investigación que se presenta.

- b) El segundo, enmarcado dentro del proyecto de investigación No. 113.1-CSUP-2014 denominado “*Desarrollo de métodos basados en visión artificial para la detección automática de malas hierbas y líneas de cultivo para el guiado de vehículos de inspección en entornos agrícolas*”, aprobado y financiado por el Centro de Investigación y Transferencia Tecnológica (CITT) de la Universidad Politécnica Estatal del Carchi (UPEC) durante los años 2014-2016. El proyecto se desarrolló mayoritariamente en la Hacienda “San Francisco”, ubicada en la provincia del Carchi-Ecuador, propiedad de la UPEC, donde el autor principal trabajó como docente titular auxiliar. Este proyecto beneficia a la tecnificación, competitividad y sustentabilidad del sector agroalimentario de la Zona 1 del Ecuador (Imbabura, Carchi, Esmeraldas y Sucumbíos), cuya economía proviene principalmente de la actividad agrícola (mayoritariamente de la papa y el maíz) y ganadera de la población, coadyuvando de esta manera a uno de los sectores priorizados por el gobierno nacional del Ecuador y el MAGAP (Ministerio de Agricultura, Ganadería, Acuicultura y Pesca) para alcanzar el buen vivir de los Ecuatorianos.

De esta manera, la investigación propuesta resulta ser pertinente y de gran importancia para el Ecuador y específicamente para la zona de planificación 1, compuesta por las provincias de Imbabura, Carchi, Sucumbíos y Esmeraldas. La pertinencia se evidencia en el siguiente marco jurídico: La **Constitución de la**

República (2008), en el artículo 385, literal 3 manifiesta que se deben desarrollar tecnologías e innovaciones que impulsen la producción nacional, eleven la eficiencia y la productividad. El **Plan Nacional del Buen Vivir** 2013-2017 indica, en los lineamientos para la inversión de los recursos públicos, que las universidades deberán enfocar sus esfuerzos de inversión en la investigación aplicada, para lograr una articulación con los sectores estratégicos y los sectores productivos priorizados (agropecuario), impulsando el intercambio de técnicas y tecnologías para mejorar los procesos productivos, especialmente de la agricultura familiar campesina. La **Transformación de la Matriz Productiva** señala que se debe fomentar la incorporación de tecnologías de punta en el sector agropecuario rural y fortalecer y garantizar la soberanía alimentaria mediante el impulso de la capacidad endógena de desarrollar tecnología agropecuaria. El **Plan Nacional de Ciencia, Tecnología, Innovación y Saberes Ancestrales** manifiesta que se deben incorporar las TIC a la generación y difusión del conocimiento para que contribuyan a impulsar la producción nacional (agropecuaria). El **Plan de Desarrollo Regional** indica que se debe involucrar a las universidades en la adaptación y utilización de la ciencia y tecnología en los diferentes procesos productivos, en nuestro caso, enfocado al sector agropecuario por la naturaleza misma de las provincias del Carchi e Imbabura, con la finalidad de tecnificar el sector e incentivar la producción, la productividad y la competitividad; asegurar la soberanía alimentaria, contribuyendo de esta manera a la anhelada revolución agraria a través de la revolución del conocimiento.

Por otro lado, el Reglamento de Carrera y Escalafón del Profesor e Investigador del Sistema de Educación Superior, en su Art. 21, literal 1 señala como requisito del personal académico titular principal de las Universidades o Escuelas Politécnicas: Tener grado académico de Doctor (PhD o su equivalente), en el campo de conocimiento vinculado a sus actividades de docencia e investigación.

Finalmente, la temática del proyecto de investigación se enmarca en la línea de investigación de Inteligencia Artificial, específicamente en la disciplina de Visión por Computador, la cual concuerda con el interés, conocimientos y trabajos previos del autor y director de tesis, lo cual contribuyó significativamente para llegar a feliz término de la investigación propuesta.

1.4 Objetivos

De acuerdo al contexto de la investigación propuesta, se plantearon los

siguientes objetivos:

General:

Desarrollar métodos de visión por computador para la detección automática de líneas de cultivo curvas/rectas y malas hierbas y en campos de maíz.

Específicos:

1. Revisar la literatura existente sobre el tema de investigación en bases de datos bibliográficas para la identificación de métodos, técnicas y futuras líneas de investigación.
2. Configurar un sistema de visión a bordo de un tractor para la adquisición de imágenes digitales en campos de maíz bajo diferentes etapas de crecimiento y condiciones climáticas.
3. Desarrollar métodos de visión por computador para la detección automática de malas hierbas y líneas de cultivo en campos de maíz utilizando la herramienta Matlab.
4. Evaluar los resultados de los métodos propuestos utilizando medidas cuantitativas para la comparación con otros existentes en la literatura.
5. Diseminar los resultados obtenidos en la investigación en revistas de alto impacto y congresos internacionales a través de artículos científicos y ponencias.

1.5 Metodología

El presente trabajo se desarrolló siguiendo las directrices marcadas por el método científico. La tipología del estudio corresponde a la investigación *Aplicada*, debido a que persigue fines más directos e inmediatos y por su interés en la aplicación, utilización y consecuencias prácticas de los conocimientos.

La modalidad de la investigación fue la *cuantitativa*, usada para medir y evaluar estadísticamente los métodos desarrollados para el proceso de detección automática de malas hierbas y líneas de cultivo, así como también para la comparación de los resultados obtenidos con otros métodos existentes en la literatura, utilizando como medidas la exactitud y los tiempos de respuestas.

Los tipos de investigación utilizados fueron los siguientes:

- *Documental*.- Se analizó la información existente sobre el campo de estudio. Para esto se utilizaron los artículos científicos publicados en bases de datos especializadas

a los que tiene acceso la Universidad Complutense de Madrid que proporcionó el soporte investigador.

- *Casos de estudio.*- Para analizar detalladamente los métodos de detección aplicados a ciertos cultivos. El Proyecto RHEA (2014) fue un referente clave en la investigación.
- *Experimental.*- Para analizar los efectos producidos por la manipulación y variación de los métodos y técnicas de visión por computador en los resultados obtenidos en la detección de malas hierbas y líneas de cultivo respecto a la exactitud y eficiencia.
- *Proyectiva.*- consistió en el diseño de una propuesta innovadora (métodos) para la detección automática de malas hierbas y líneas de cultivo en campos de maíz.

Las técnicas de investigación empleadas para la recolección de datos fueron básicamente las siguientes:

- *Fichaje.*- Para registrar la literatura revisada referente al tema, las imágenes y videos adquiridos en el campo de maíz en las diferentes etapas de cultivo.
- *Entrevista estructurada.*- dirigida a expertos en el tema, tanto en el ámbito tecnológico relativo a la visión por computador como en el agronómico, incluyendo agricultores e ingenieros agrónomos.

Los instrumentos de investigación utilizados fueron los siguientes:

- Cuestionario de entrevista
- Ficha de observación
- Cámara digital GoPro, filtros ópticos IR/UV, laptop Asus
- Programa Matlab R2015a, EndNote X7, MS Word 2013
- GPS, UMI (*Inertial Measurement Unit*)
- Tractor New Holland TD90

Para el cumplimiento de los objetivos, y por tanto del tema de investigación, se realizaron las siguientes estrategias y tareas:

Primer objetivo.- Se realizó una revisión adecuada de la literatura existente sobre las técnicas y métodos de segmentación y detección en imágenes digitales de los elementos de interés en el campo, tales como: líneas de cultivo y malas hierbas. Para el efecto se

utilizaron los trabajos publicados a nivel internacional, utilizando principalmente las bases de datos bibliográficas de la red del Consorcio Madroño al que están suscritas las Universidades de la Comunidad de Madrid, tales como: IEEE Xplore, ACM Digital Library, ISI Web of Knowledge, Scopus, ScienceDirect, SpringerLink.

Segundo objetivo.- Se capturaron imágenes digitales en campos de maíz ubicados en la Hacienda “San Francisco” de la Universidad Politécnica Estatal del Carchi (Tulcán, Ecuador) durante los años 2014 y 2015. Se utilizó una cámara a color GoPro Hero 3+ Black Edition, convenientemente arreglada bajo la proyección de perspectiva en la parte frontal de un tractor New Holland TD90. Las imágenes tienen una resolución de 3000×2250 píxeles (7 Mpx) y fueron guardadas en el espacio de color RGB en el formato JPG. Para la captura de las imágenes se consideraron diferentes aspectos: orientación y ángulo, altura desde el suelo, etapa de crecimiento, densidad del cultivo, iluminación, condiciones climáticas, etc. Para las tareas agrícolas se contó con el apoyo del personal, equipos y maquinaria de la Facultad de Industrias Agropecuarias y Ciencias Ambientales (FIACA) de la UPEC. Otro conjunto importante de imágenes utilizado en la investigación fue el experimentado en el marco del Proyecto RHEA (2014).

Tercer objetivo.- En primer lugar, se desarrollaron dos algoritmos (métodos) para la detección automática de líneas de cultivo curvas y rectas utilizando las imágenes adquiridas en la tarea anterior (capítulo tres). Los algoritmos fueron implementados en la herramienta de programación Matlab (R2015a) ejecutándose en un procesador Intel Core i7 de cuarta generación con 8 GB de RAM. Esta herramienta se utilizó debido a su facilidad y potencia para un prototipado rápido de aplicaciones. En segundo lugar, se desarrolló un algoritmo para la discriminación automática entre cultivo/malas hierbas, incluyendo la malas hierbas inter e intra-línea (capítulo cuatro). Los métodos propuestos fueron probados cualitativa y cuantitativamente como se explica enseguida.

Cuarto objetivo.- Se validaron los métodos propuestos utilizando diferentes conjuntos de imágenes en dos instancias: (i) cualitativamente, a través del criterio visual de un experto, el cual permitió depurar y realizar ciertos ajustes a los procedimientos preliminares; (ii) cuantitativamente, utilizando una medida denominada *CRDA* (*Crop Row Detection Accuracy*) para la detección de líneas de cultivo, cuya descripción detallada se proporciona en el capítulo tres. El rendimiento del método se comparó

frente a cinco estrategias existentes. Para la discriminación entre cultivo/malas hierbas, la clasificación se realizó comparando con una batería de imágenes (*Ground Truth*) previamente creada y analizando la matriz de confusión creada al efecto, tal y como se describe en el capítulo cuatro. Con tal propósito se calcularon la tasa de exactitud y el coeficiente de Kappa. El rendimiento del método se comparó frente a tres estrategias existentes con probada eficiencia. En este contexto se obtuvieron las conclusiones relevantes del estudio y se logró identificar posibles mejoras y trabajos a futuro.

Quinto objetivo.- Se documentaron los resultados obtenidos en la investigación en una serie de artículos científicos, los cuales fueron enviados a las revistas internacionales de alto impacto para su posible publicación. Luego de un proceso largo y riguroso de revisión, se logró la aceptación y publicación de varios manuscritos, y con ello un importante aval para la investigación realizada. Además, los resultados relevantes fueron diseminados como ponencias en varios congresos internacionales organizados en Ecuador, cuyas memorias fueron plasmadas en libros con su respectivo ISBN.

1.6 Aportes a la investigación

1.6.1 Publicaciones en Revistas Internacionales

Pajares, G., **García-Santillán, I.**, Campos, Y., Montalvo, M., Guerrero, J.M., Emmi, L., et al. (2016). Machine-Vision Systems Selection for Agricultural Vehicles: A Guide. *Journal of Imaging*, 2(4), 34. ISSN: 2313-433X

Este trabajo proporciona las directrices para la selección de sistemas de visión por computador para un óptimo rendimiento, considerando las condiciones adversas en los entornos agrícolas al aire libre con alta variabilidad en la iluminación, terrenos irregulares o diferentes etapas de crecimiento de plantas, entre otras cuestiones. Es este sentido, tres cuestiones principales fueron convenientemente abordados para la mejor selección: (i) banda espectral (visible e infrarroja); (ii) sensor de imagen y sistema óptico (incluyendo los parámetros intrínsecos) y (iii) arreglo y pose del sistema visual geométrico (considerando los parámetros extrínsecos y sistemas de estereo visión). En él se proporciona una visión general, con una descripción detallada y soporte técnico para cada tema con ejemplos ilustrativos enfocándose en aplicaciones específicas en la agricultura. Se proporciona un caso de estudio como resultado de la investigación en el Proyecto RHEA para el control efectivo de malas hierbas en campos de maíz donde los sistemas de visión por computadora a bordo de los vehículos autónomos fueron la parte

más importante del sistema completo de percepción. Además, en el citado trabajo se proporciona una revisión de métodos y enfoques en las siguientes temáticas: detalles y resultados acerca de la detección de líneas de cultivo, identificación de rodales de malas hierbas, guiado de vehículos autónomos y detección de obstáculos.

García-Santillán, I., Guerrero, M., Montalvo, M., Pajares, G. (2017). Curved and straight crop row detection by accumulation of green pixels from images in maize fields. *Precision Agriculture*.

doi: <http://dx.doi.org/10.1007/s11119-016-9494-1> ISSN: 1385-2256

Este estudio propone un nuevo método para la detección de líneas de cultivo rectas y curvas, basado en la acumulación de píxeles verdes en imágenes capturadas en campos de maíz durante las etapas iniciales de crecimiento. Las imágenes fueron obtenidas bajo la proyección de perspectiva con una cámara instalada a bordo y convenientemente posicionada en la parte frontal del tractor. El objetivo final fue la identificación de las líneas de cultivo que son cruciales para guiado autónomo preciso como ayuda al guiado basado en GPS, así como la aplicación de tratamientos selectivos, incluyendo la remoción de malas hierbas basada en la identificación de plantas situadas fuera de las líneas de cultivo, que se identifican como tal. La calidad de la imagen es afectada por las condiciones de iluminación no controladas en entornos agrícolas al aire libre y por discontinuidades en las líneas de cultivo (debido a la falta de germinación o defectos durante la siembra). También, las diferentes alturas y volúmenes de las plantas, debido a las diferentes etapas de crecimiento, afectan al proceso de detección automático de líneas de cultivo en las imágenes. El método propuesto fue diseñado con la robustez requerida para solventar las situaciones indeseadas constando de tres fases secuenciadas en el tiempo: (i) segmentación; (ii) identificación de puntos de inicio de las líneas de cultivo y (iii) detección de las propias líneas. La principal contribución fue la habilidad del método para detectar líneas curvas y rectas de cultivo coexistiendo en la imagen, es decir en el campo, incluso con espacios irregulares entre las dichas líneas. El rendimiento del método fue probado en términos de precisión y tiempos de respuesta.

García-Santillán, I., Montalvo, M., Guerrero, M., Pajares, G. (2017). Automatic detection of curved and straight crop rows from images in maize fields. *Biosystems Engineering*, 156, 61-79.

doi: <http://dx.doi.org/10.1016/j.biosystemseng.2017.01.013> ISSN:1537-5110

Este estudio propone un nuevo método para la detección de líneas curvas y rectas de cultivo, basado en pequeñas regiones de interés (*micro ROI*), en imágenes capturadas en campos de maíz también durante etapas iniciales de crecimiento. Como en el trabajo anterior, el método propuesto fue diseñado con la robustez requerida para cubrir con las situaciones adversas en los entornos agrícolas al aire libre y consistió igualmente de las mismas tres fases secuenciales: (i) segmentación; (ii) identificación de puntos de inicio de las líneas de cultivo y (iii) detección de las propias líneas. Las dos primeras fases son comunes con el manuscrito previo. La tercera fase fue la variante, basada en el concepto de *micro-ROI* en lugar de la técnica de la acumulación de píxeles verdes. El rendimiento del enfoque propuesto fue cuantitativamente comparado frente a cinco estrategias existentes, logrando exactitudes entre 86.3% y 92.8%, dependiendo de si las líneas de cultivo son rectas o curvas con espaciado entre líneas regular o irregular, siempre con tiempos de procesamiento inferiores a 0.64 s.

1.6.2 Congreso Internacional

García-Santillán, I., Pajares, G. (2016). Detección automática de líneas de cultivo: estado del arte y futuras perspectivas. En F. Rivas, S. Arciniegas, & C. P. U. Andes (Ed.), *Avances y aplicaciones de sistemas inteligentes y nuevas tecnologías* (pp. 381-398). Mérida, Venezuela: Gráficas el Portatítulo.
ISBN: 978-980-11-1836-7

El presente estudio fue presentado en el *Congreso Internacional de Sistemas Inteligentes y Nuevas Tecnologías - COISINT 2016*, realizado en Ibarra-Ecuador (20-22 de Abril, 2016), donde se realizó una revisión exhaustiva de la literatura existente respecto a los métodos para la detección automática de líneas de cultivo, haciendo énfasis en el rendimiento de los métodos en términos de robustez, exactitud y tiempos de ejecución. Se expuso un análisis comparativo entre las diferentes técnicas para la detección de líneas de cultivo en términos de ventajas e inconvenientes, así como también posibles líneas futuras de investigación.

1.7 Organización de la tesis

La memoria de tesis está estructurada en capítulos, siguiendo el orden natural de la investigación como sigue:

Primer capítulo. Introducción, donde se presentan los antecedentes, el problema a resolver, la motivación, los objetivos y la metodología que se abordó en la investigación.

Segundo capítulo. Revisión de la literatura, para examinar los sistemas de visión por computador utilizados en tareas automatizadas en agricultura, así como los diferentes métodos para la detección automática de malas hierbas y líneas de cultivo, que sirven de sustento técnico-científico para la investigación.

Tercer capítulo. Detección de líneas de cultivo, donde se proponen dos nuevos métodos para la detección de líneas rectas y curvas de cultivo. El primero está basado en la técnica de acumulación de píxeles verdes y el segundo en el concepto de pequeñas regiones de interés (*micro ROI*).

Cuarto capítulo. Discriminación de cultivo/malas hierbas, en el que se propone un nuevo método automático basado en la distancia de Mahalanobis como criterio de similitud.

Quinto capítulo. Relativo a conclusiones y trabajo futuro, donde se exponen los principales hallazgos de la investigación, así como las líneas de investigación futuras y posibles mejoras de los métodos propuestos.

CAPÍTULO 2

Estado del arte

2.1 Introducción

En el presente capítulo se realiza una revisión de métodos y técnicas existentes en la literatura actual respecto a (i) los sistemas de visión por computador; (ii) extracción del verdor de las plantas y (iii) detección de líneas de cultivo, utilizando imágenes digitales adquiridas en campos de cultivo bajo la proyección en perspectiva y cenital a través de sistemas de visión instalados a bordo de vehículos agrícolas terrestres. El primer tema resulta útil para la selección adecuada de la banda espectral más apropiada en relación al sensor de imagen, sistema óptico, arreglo y pose del sistema visual. El segundo asunto es importante para la identificación de las malas hierbas y la aplicación de tratamientos selectivos. El tercer tema resulta imperativo para el guiado autónomo y preciso de vehículos agrícolas, y para la remoción de malas hierbas localizadas fuera de las líneas de cultivo; así como también para el análisis del suelo/cultivo (por ejemplo enfermedades, plagas, necesidades hídricas, estado de maduración, etc.) a través de sensores adicionales.

2.2 Sistemas de visión por computador

Los sistemas de visión por computador instalados a bordo de un vehículo agrícola –terrestre o aéreo– pueden ser utilizados para diferentes tareas agrícolas, como por ejemplo: la detección de líneas de cultivo (Romeo et al., 2012; Guerrero et al., 2013; Montalvo et al., 2012a) y la identificación de las malas hierbas para la aplicación de tratamientos selectivos (López-Granados, 2011; Romeo et al., 2013a; Guerrero et al., 2012; Gée et al., 2008; Montalvo et al., 2013; Guijarro et al., 2011; Burgos-Artizzu et al., 2011; Sainz-Costa et al., 2011; Tellaeche et al., 2008a; Jones et al., 2009; Tellaeche et al., 2008b), las cuales suelen ser tareas comunes en lo que se conoce como Agricultura de Precisión; el guiado basado en el seguimiento de las líneas de cultivo (Li et al., 2009; Reid & Searcy, 1997; Billingsley & Schoenfisch, 1997; Rovira-Más et al., 2003); detección de obstáculos para propósitos de seguridad (Kise & Zhang, 2008; Xue et al., 2012; Wei et al., 2005; Nissimov et al., 2015; Campos et al., 2016) o la representación o mapeo del terreno y cultivo (Cheein et al., 2011), entre otros.

Sin embargo, varias interrogantes emergen respecto al sistema de visión por computador y su integración a bordo del vehículo agrícola. Por ejemplo: ¿qué sistema de visión utilizar?, ¿qué especificaciones debe tener?, ¿dónde ubicarlo en el vehículo agrícola?, ¿cómo debe ser orientado hacia la escena 3D en el campo? Las respuestas a estas y a otras cuestiones son cruciales, las cuales deben ser consideradas para cualquier diseño de ingeniería basado en visión por computador eficiente.

Además, se deben considerar los siguientes aspectos (Pajares et al., 2016):

- *Compromiso entre las especificaciones del sistema de visión y el rendimiento:* los rangos espectrales, es decir, multiespectral e hiperspectral, incluyendo el espectro visible, infrarrojo, térmico o ultravioleta. La resolución espectral y espacial del sensor de la cámara, así como los parámetros intrínsecos asociados. Todo ello repercute directamente en el coste económico del sistema de visión.
- *Definición de la ROI y el campo de visión:* el sistema óptimo juega un papel significativo a la hora de adquirir imágenes con suficiente calidad, es decir, que posean una resolución adecuada para discriminar cultivo/malas hierbas y evitar distorsiones y aberraciones ópticas.
- *El arreglo (disposición) del sistema de visión:* con una pose específica a bordo del vehículo agrícola, altura respecto al suelo, distancia al área de trabajo (ROI), ángulos de rotación: inclinación (*pitch*), balanceo (*roll*), orientación (*yaw*). Todos ellos considerados como parámetros extrínsecos del sistema de visión que aparecen directamente involucrados.

En síntesis, se deben abordar tres problemas principales concernientes a los sistemas de visión por computador instalados a bordo de vehículos agrícolas para conseguir su máxima eficiencia: (i) selección de la banda espectral; (ii) sensor de imagen y sistema óptico y (iii) arreglo y pose del sistema visual.

2.2.1 Selección de la banda espectral

La Tabla 2.1 resume los diferentes rangos de longitudes de onda (λ) expresadas en *nm*, y relacionados con las bandas espectrales (S) comúnmente utilizadas en las aplicaciones agrícolas basadas en sistemas de visión computacional, particularmente para la identificación del verdor. Dichas bandas espectrales cubren básicamente los siguientes rangos: Ultra-Violeta (*UV*); Visible con azul (*B*), verde (*G*), rojo (*R*); Infra-

rojo (*IR*) el cual está dividido en NIR (*Near-Infrared*), SWIR (*Short-Wave*), MWIR (*Mid-Wave*) y LWIR (*Long-Wave*).

Tabla 2.1 Banda espectral (S) y longitud de onda λ (nm) (Pajares et al., 2016)

S	λ (nm)	S	λ (nm)	S	λ (nm)	S		λ (nm)
UV	1-380	Visible	380-780	Blue	450-500	IR	Near (NIR)	760-1400
				Green	500-600		Short-Wave (SWIR)	1400-3000
				Red	600-760		Mid-Wave (MWIR)	3000-8000
Long-Wave (LWIR)	8000-15000							

A continuación, se detallan los espectros visible e infrarrojo, frecuentemente usados en los sistemas de visión por computador en aplicaciones agrícolas.

Espectro Visible. La mayoría de las tareas agrícolas que utilizan los sistemas de visión por computador requieren de técnicas de procesamiento de imágenes con el fin de identificar firmas espectrales específicas (colores). Los índices de vegetación permiten la extracción de características espectrales, combinando dos o más bandas espectrales, basados en las propiedades de la reflectancia producidas por la vegetación (Meyer & Camargo-Neto, 2008). Algunas de ellas usan solamente tres bandas espectrales: rojo (*R*, *red*), verde (*G*, *green*) y azul (*B*, *blue*), donde el objetivo es mejorar ciertas bandas específicas, acentuando las propiedades de las firmas espectrales (color) de interés. En la Tabla 2.1 se indica el espectro visible y las longitudes de onda respectivas comprendido entre 380 y 780 nm. Al respecto, si el verdor es el de interés para una determinada aplicación, el valor de la banda *G* debe ser mejorada, cuando la segmentación del suelo es la de interés en un momento determinado, el valor de la banda *R* debe ser realizada o mejorada, según convenga. El Exceso de verde (*ExG*) y el Exceso de rojo (*ExR*) son dos índices de vegetación bien conocidos para tal propósito (Guijarro et al., 2011). El primero es aplicado para detectar las plantas verdes, incluyendo líneas de cultivo, hojas de las plantas, rodales de malas hierbas y otras partes de vegetación. El segundo es usado para otros propósitos, tales como el análisis de suelo (composición orgánica, humedad, etc.).

En resumen, se puede decir que el mejor sensor para la identificación de verdes será aquel con una alta respuesta a la reflectancia en la banda correspondiente al verde

(*G*) entre 500-570 nm y nulo para el rojo (*R*), por consiguiente, con un mínimo solapamiento entre las bandas espectrales *R* y *G* (Pajares et al., 2016).

Corrección espectral. En los entornos agrícolas al aire libre, el sistema de visión por computador trabaja en condiciones adversas, donde la iluminación natural contiene también componentes espectrales *NIR* y *UV* (radiación). El *NIR* contamina fuertemente los tres canales espectrales (*R*, *G* y *B*), principalmente el canal rojo en el rango 760-800 nm, produciendo imágenes de colores rojizos (calientes). Esto hace inviable la identificación del verdor de la vegetación. Para evitar este efecto adverso, se requieren filtros de corte, tal como el Schneider UV/IR 486 (Schneider Kreuznach, 2008), el cual fue usado en el Proyecto RHEA (2014). La curva de operación específica que las longitudes de onda por debajo de 370 nm y por encima de 760 nm están bloqueadas, es decir, tanto las radiaciones *UV* como *NIR*. La Fig. 2.1(a) muestra una imagen dañada, adquirida con un sensor CCD sin el filtro de corte UV/IR 486 y en (b) equipado con tal filtro.



Fig. 2.1 Efecto de un filtro de corte UV/IR: (a) sin filtro; (b) con filtro. Tomado de Pajares et al. (2016)

No obstante, a pesar del filtrado de bloqueo, el efecto del *vignetting* todavía puede permanecer, requiriendo una corrección. Este efecto es más pronunciado cuanto menor es la longitud focal de la lente, es decir, lentes con ángulos de visión amplios. El efecto del *vignetting* causa anomalías importantes en las características espectrales. Por proximidad de las longitudes de onda *IR* y roja (*R*) en el espectro electromagnético, los valores correspondientes a la banda roja se ven afectados con un exceso de filtrado a expensas de las bandas verde (*G*) y azul (*B*), introduciendo un exceso de *G* con respecto a *R*, que se manifiesta por la presencia de un alto verdor en las partes más alejadas del

centro de la imagen y particularmente en las esquinas. La Fig. 2.2(a) muestra una imagen con la segmentación del verdor aplicando el índice ExG .

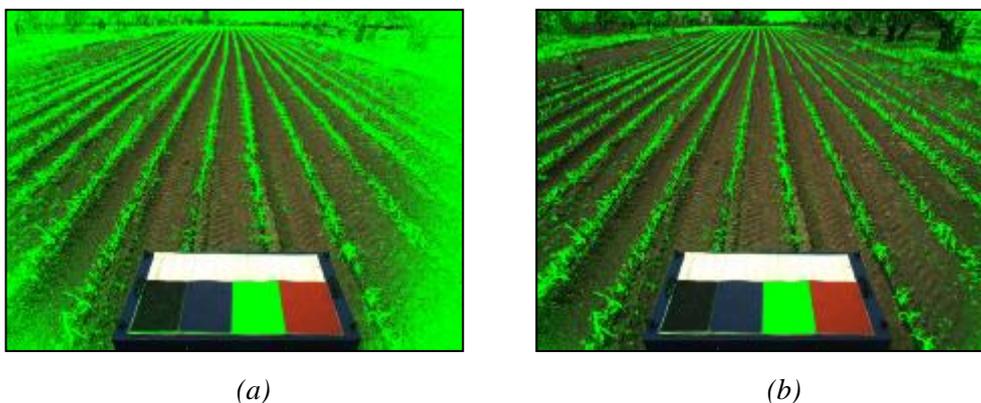


Fig. 2.2 Efecto del *vignetting*: (a) imagen dañada con exceso de verde en las partes externas; (b) imagen corregida utilizando una máscara de corrección. Tomado de Pajares et al. (2016)

Dos enfoques pueden ser considerados para corregir este efecto adverso y provocado por la ausencia de los filtros ópticos UV/IR necesarios para el corte de la radiación ultravioleta e infrarroja, ambas presentes en la radiación lumínica procedente del sol. El primero consiste en la instalación de un filtro de corte UV/IR justo delante y superpuesto al sensor (CCD, CMOS), con el fin de minimizar la distancia recorrida por los rayos. En las cámaras digitales comerciales este filtro viene instalado de fábrica y la mayoría de veces no requiere de acciones adicionales, tal es el caso de la cámara utilizada en los experimentos llevados a cabo en los campos de cultivo de Ecuador. El segundo enfoque, cuando el primero no funciona o no es posible, se requiere una corrección de las bandas espectrales específicas (R , G y B) vía software usando una máscara de corrección (Romeo et al., 2013b; Pajares et al., 2016).

El balance de blancos también es otra opción para mejorar la calidad de la imagen, basado en la corrección con referencia a los valores espectrales blancos previamente conocidos. La Fig. 2.3 muestra en (a) una imagen original y en (b) con corrección de balance de blancos.

En general, en cualquier sistema óptico el objetivo final debe ser la obtención de imágenes con la máxima calidad espectral como sea posible, evitando o minimizando en cualquier caso los efectos indeseados tales como distorsiones y aberraciones del sistema óptico o el efecto *vignetting*, además de conseguir una resolución espectral y también espacial adecuadas para discriminar entre cultivo/malas hierbas.



Fig. 2.3 Balance de blancos: (a) imagen original; (b) imagen corregida. Tomado de Pajares et al. (2016)

Espectro Infrarrojo. Ampliamente utilizado en aplicaciones agrícolas para detección remota (Tucker, 1979), donde el verde de la vegetación debe ser identificado a través de plataformas aéreas o satelitales, equipadas con sensores de imagen multi/hiper espectrales. El infrarrojo cercano (*NIR*) es una banda útil para la identificación y fenotipado de las plantas, debido a que la vegetación verde produce un valor alto de reflectancia en la banda *NIR* por la actividad derivada de la función clorofílica (Ollinger, 2011; Rabatel et al., 2011). Al respecto, de acuerdo con la aplicación agrícola a desarrollar, el mejor enfoque consiste en determinar la correspondencia entre los objetos agrícolas a detectar y la respuesta espectral del sensor. La Fig. 2.4 muestra el espectro de reflectancia típico en diferentes longitudes de onda para el cultivo y suelo según Ollinger (2011), donde la máxima reflectancia se logra entre 700 y 1300 nm. Así, considerando que *NIR* corresponde a longitudes de onda dentro del rango de 760 y 1400 nm, el mejor sensor para capturar la reflectancia del cultivo debe ser uno con la mayor respuesta dentro de este rango.

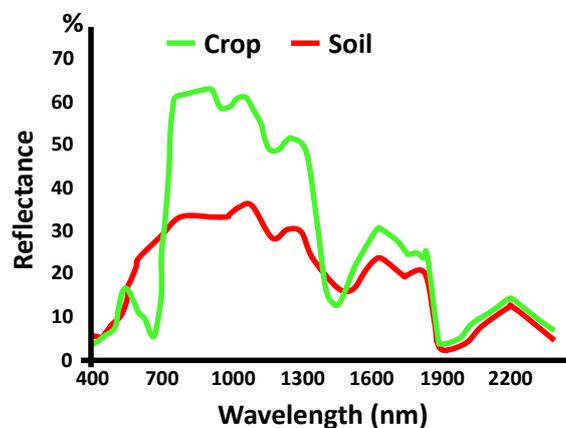


Fig. 2.4 Reflectancia espectral típica para el cultivo y suelo, según Ollinger (2011)

En la Tabla 2.1 se indica el espectro infrarrojo (*IR*) y las longitudes de onda respectivas. *IR* está dividido en *NIR* (*Near-Infrared*) comprendido entre 760 y 1400 nm, *SWIR* (*Short-Wave*) entre 1400 y 3000 nm, *MWIR* (*Mid-Wave*) entre 3000 y 8000 nm y *LWIR* (*Long-Wave*) entre 8000 y 15000 nm.

2.2.2 Parámetros intrínsecos del sistema de visión

2.2.2.1 Sensor de imagen

Se pueden distinguir dos tipos básicos de sensores de imagen: (i) los *pasivos* que detectan la radiación electromagnética emitida o reflejada desde fuentes naturales y que pueden utilizarse en los entornos agrícolas al aire libre, como en esta investigación; (ii) los *activos* que poseen fuentes internas que generan artificialmente la radiación (láser, radar) y se utilizan para estudios de fenotipos de plantas basados en NDVI (*Normalized Difference Vegetation Index*) y densidades del follaje (Svensgaard, 2014). El fenotipado de plantas representa un desafío importante en las aplicaciones agrícolas, donde la selección de la banda espectral y la longitud de onda asociada juegan un rol sustancial para determinar algunos parámetros específicos de las plantas, tales como: morfología, biomasa, formas de hojas, características de las frutas, estimación del rendimiento, contenido de agua, actividad fotosintética o estrés.

Las tecnologías frecuentemente usadas en los sensores de imagen son: CCD (*Charge Coupled Device*) y CMOS (*Complementary Metal Oxide Semiconductor*). Algunas diferencias entre ellas se determinan porque la uniformidad de salida es superior en CCD que en CMOS, generando mayor calidad de la imagen pero con mayor ruido. Por el contrario, la tecnología CMOS produce niveles más bajos de ruido con una lectura más rápida y menor consumo de energía.

Los dispositivos CCD o CMOS constan de píxeles organizados en matrices con tamaños horizontal (H) y vertical (V) específicos. El producto $H \times V$ determina lo que se conoce como resolución espacial, que en los dispositivos actuales se identifica generalmente como Mega Píxeles (MP) en términos de millones de píxeles, por ejemplo un dispositivo con una resolución de 3000×2250 se mide como 7 MP. Físicamente, cada píxel en sus respectivos sensores tiene sus propios tamaños horizontal (h) y vertical (v), expresados generalmente en μm . Los tamaños nominales del sensor, horizontal (Sh) y vertical (Sv), pueden calcularse como $Sh = h \times H$ y $Sv = v \times V$.

Los tamaños de los chips CCD y CMOS varían considerablemente (Bockaert, 2002), y son diseñados con dimensiones rectangulares con sus correspondientes

longitudes diagonales. La asociación (tipo, diagonal) se establece entre el tipo de sensor y su diagonal en unidades de longitud expresado en mm: por ejemplo (1/2.3", 7.7). Esto llevará a ciertas restricciones geométricas de particular interés en los sistemas de visión por computador para la agricultura y también cuando se elige el sistema óptico.

En el ámbito de las aplicaciones agrícolas, la elección de un sensor será determinado por sus características potenciales. En concreto, si se tiene previsto trabajar en condiciones de iluminación escasa o baja, como en el caso del amanecer o atardecer, lo más adecuado debe ser la utilización de una tecnología CMOS. También resulta apropiada cuando el tiempo de respuesta es muy crítico. En algunos escenarios, el tiempo entre la adquisición de la imagen y la actuación es extremadamente bajo. Esto podría ser el caso durante la eliminación de las malas hierbas aplicando herbicida donde el sensor se sitúa perpendicularmente al suelo y la aplicación del herbicida es inmediata. Sin embargo, en la mayoría de aplicaciones agrícolas, involucrando procesamiento de imágenes, el tiempo es crítico pero no extremo. Aquí, los sensores CCD pueden ser apropiados, conectados convenientemente a procesadores de tiempo real, bajo arquitecturas eficientes HW/SW (Emmi et al., 2014a). En este sentido, Giga Ethernet (GigE), USB 3.0 o IEEE 1394 (*FireWire*) son interfaces apropiadas para garantizar suficientes tasas de transmisión de datos (imágenes).

Adicionalmente, existen dos recursos para tratar con las condiciones adversas de iluminación no controlada en los entornos agrícolas al aire libre: tiempo de exposición y apertura del iris. Ambos pueden controlarse convenientemente para lograr suficiente calidad en las imágenes, por ende se evita la sobre o infra exposición del sensor. Esto puede controlarse por actuación directa sobre los mecanismos de control del sistema óptico vía señales externas o mediante el procesamiento de las imágenes o combinando ambos (Cambridge in Colour, 2017). La exposición es el tiempo durante el cual el sensor recibe la radiación, de forma continuada, hasta que la señal es producida. Cuanto mayor sea el tiempo de exposición, mayor será la radiación recibida por el sensor y viceversa, incrementando la intensidad de la señal, pudiendo llegar a la saturación en casos de exposición prolongada o la falta de señal por una infra exposición. El nivel de apertura del iris produce efectos similares en relación a la intensidad de la señal. En este sentido, se debe lograr un equilibrio entre el tiempo de exposición y la apertura.

Otro aspecto referido a la selección del sensor es la capacidad para capturar las imágenes, medido en cuadros por segundo (fps, *frame per second*), dependiendo de la tecnología del sensor y la resolución. En general, la tecnología CMOS permite alcanzar

fps mayores que CCD. Desde el punto de vista de las aplicaciones agrícolas y por rendimiento, es requerido determinar la mejor elección de *fps*. Las velocidades comunes de operación en los vehículos agrícolas terrestres pueden variar entre 3 km/h (0.83 m/s) y 8 km/h (2.22 m/s). Esto significa que la ROI a ser procesada, una vez que es proyectada en el plano de la imagen, debe definirse con suficiente tamaño para garantizar que pueda procesarse dentro de los límites de tiempo cuando el tractor autónomo navega a lo largo del campo de cultivo. Los *fps* y las tareas asignadas al procesador de la imagen deben considerarse convenientemente, dado que probablemente en el procesador se realizarán otros procesos diferentes, provenientes de otros sensores (Emmi et al., 2014a).

2.2.2.2 Sistema óptico

La cantidad de radiación recibida por el sensor es controlada por el sistema óptico, el cual consta de los siguientes elementos y características (Schneider Kreuznach, 2013):

- *Conjunto de lentes*: es la parte principal del sistema óptico. Los fabricantes proporcionan información acerca de la longitud focal (f) y otros parámetros relacionados. La longitud focal es un parámetro crítico en las aplicaciones agrícolas, que debe considerarse para la disposición geométrica del sistema de visión. Existen sistemas con una longitud focal variable, basados en un equipo motorizado con un control externo. A veces, incluye también una configuración de enfoque manual o autoenfoco para obtener imágenes con una nitidez apropiada.
- *Diafragma del iris*: consiste en una estructura compuesta por cuchillas móviles (manual o automática) la cual produce una apertura que controla el área por donde pasa la radiación hacia el sensor. Los fabricantes lo especifican en términos de un valor conocido como *f-stop*.
- *Filtros ópticos*: usados para atenuar o enfatizar la intensidad de ciertas bandas espectrales específicas; es decir, transmiten o impiden el paso de longitudes de onda específicas. Sus diferentes parámetros deben ser considerados para lograr la máxima eficiencia, incluyendo la longitud de onda central, ancho de banda, rango de bloqueo, densidad óptica (Edmund of Optics, 2017). Un ejemplo es el filtro Schneider UV/IR 486 (Schneider Kreuznach, 2008), usado en el Proyecto RHEA (2014).

La elección del sistema óptico para las aplicaciones agrícolas es de especial relevancia, con la finalidad de garantizar un rendimiento correcto, orientado hacia la adquisición de imágenes con suficiente calidad, por tanto, con suficiente resolución y sin distorsiones o efectos adversos. En este sentido, la imagen debe estar correctamente enfocada (manualmente o con autoenfoco) debido a que la extracción de las características de los objetos en la imagen depende, altamente, del enfoque. Las plantas y las estructuras desenfocadas no suministran las características apropiadas para la discriminación. Es necesario un sistema compatible entre el sensor y la lente para evitar distorsiones. El diafragma del iris puede también controlarse manualmente para obtener una suficiente cantidad de iluminación que junto con el control del tiempo de exposición y un análisis de la imagen, permitan la adquisición de las imágenes con la calidad requerida. Además, los filtros ópticos deben ser elegidos apropiadamente en relación a su transmitancia para minimizar efectos adversos, tales como el *vignetting*.

En aplicaciones agrícolas, la selección de la longitud focal (f) es crucial para la definición de la ROI más apropiada. Es bien conocido que, el dispositivo principal en el sistema óptico son las lentes con su correspondiente longitud focal. La Fig. 2.5 muestra los elementos básicos de un sistema óptico genérico. H representa el campo de visión en la escena, h es el tamaño del sensor, D es la distancia de trabajo y d es la distancia desde los lentes al plano de la imagen, es decir, la distancia de enfoque, donde el objeto aparece enfocado en el plano de la imagen.

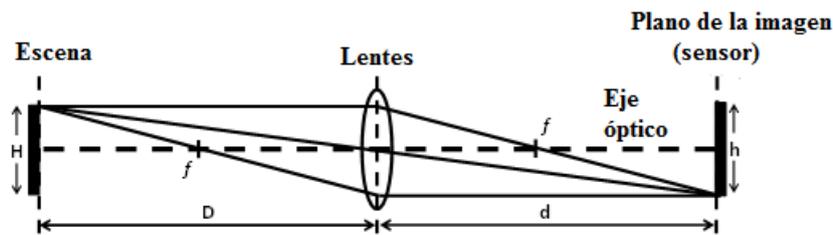


Fig. 2.5 Configuración de un sistema óptico genérico (Pajares et al., 2016)

La expresión de la lente Gaussiana y el factor de amplificación (m) vienen dados como sigue:

$$\frac{1}{f} = \frac{1}{D} + \frac{1}{d} \quad m = \frac{h/2}{H/2} = \frac{d}{D} \quad (2.1)$$

Combinando ambas expresiones, se obtiene la siguiente relación para seleccionar la longitud focal:

$$f = \frac{hD}{h+H} \quad (2.2)$$

Por ejemplo, considérese una aplicación agrícola que utiliza un sistema de visión por computador basada en el sensor Kodak KAI 04050M/C, el cual tiene una resolución horizontal de 2336 píxeles y un ancho de sensor de 12.85 mm. Si la ROI tiene 3m de ancho o un elemento en la escena, por ejemplo un árbol tiene 3m de altura, es decir, $H = 3\text{m}$ y la distancia de trabajo es $D = 5\text{m}$, aplicando la Ec. (2.2), la f requerida resulta en 10.68 mm, que es una referencia para seleccionar la longitud focal.

2.2.3 Parámetros extrínsecos del sistema de visión

Estos parámetros son críticos para garantizar áreas de trabajo (ROIs) apropiadas, proyectadas en la imagen, con la suficiente resolución y calidad. Por lo que, el objetivo consiste en determinar la pose (parámetros extrínsecos) del sistema visual a bordo del vehículo agrícola autónomo en relación a los correspondientes sistemas de referencia, como se muestra en la Fig. 2.6. $OXYZ$ es el sistema de referencia localizado en el suelo con los ejes orientados como se indica; h es la altura desde O al origen o del sistema de referencia $oxyz$ ligado a la cámara; cabeceo (α , pitch), guiñada (β , yaw) y alabeo (θ , roll) definen los tres grados de libertad del plano de la imagen con respecto al sistema referencial $oxyz$; d es la distancia desde el inicio de la ROI al eje X.

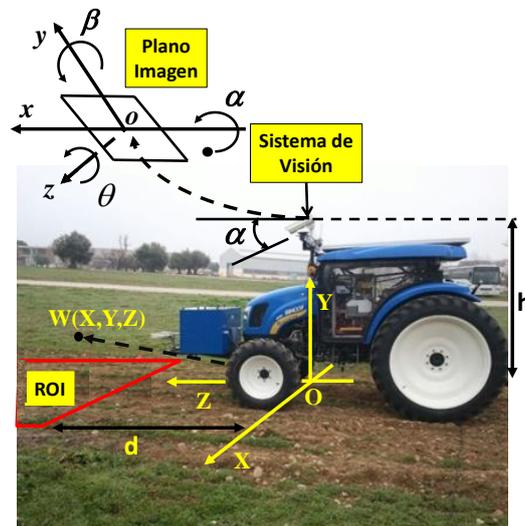


Fig. 2.6 Geometría del sistema de visión. Imagen tomada de Emmi et al. (2014a).

Los parámetros extrínsecos combinados con los parámetros intrínsecos (longitud focal, dimensiones y resolución del sensor) permiten determinar la proyección de la escena 3D en el campo sobre el plano 2D de la imagen digital. Por lo tanto, la correcta

definición de estos parámetros determinará la efectividad del sistema de visión por computador en las tareas agrícolas, como se enuncia a continuación:

- *Detección de líneas de cultivo:* a veces se debe detectar un número fijo de líneas de cultivo para el guiado preciso o la discriminación entre cultivo y malas hierbas con fines de aplicación de tratamientos selectivos (Romeo et al., 2012; Montalvo et al., 2012a; Guerrero et al., 2012; Guijarro et al., 2011; Burgos-Artizzu et al., 2009; Sainz-Costa et al., 2011; Tellaache et al., 2008a; Jones et al., 2009; Tellaache et al., 2008b). El sistema de visión debe ser convenientemente diseñado de manera que el número requerido de líneas de cultivo, considerando el espacio entre dichas líneas, pueda ser proyectado con suficiente resolución en la imagen.
- *Identificación de hojas de plantas, rodales de malas hierbas, frutas y enfermedades:* se han desarrollado diferentes aplicaciones basadas en los tamaños y estructuras de los objetos (hojas, frutas). El sistema de visión debe proporcionar suficiente información para su identificación de forma que las estructuras deben proyectarse sobre el plano de la imagen con tamaños y dimensiones suficientes para obtener características discriminantes para la clasificación o la identificación requerida. En este sentido, la proyección de pequeñas áreas podrían resultar insuficiente para tales propósitos. En Jeon et al. (2011), la morfología de las hojas fue aplicada para la discriminación entre cultivo y malas hierbas usando redes neuronales. Linker et al. (2012) identificaron y contaron manzanas en los árboles frutales. Moshou et al. (2011) y Oberti et al. (2014) reconocieron enfermedades por hongos y moho.
- *Variaciones espaciales:* altura de la planta, rendimiento frutal y características topográficas (pendiente y elevación) han sido estudiadas por Farooque et al. (2012), incluyendo varios posicionamientos específicos del sistema de visión por computador.
- *Determinación de la estructura 3D y guiado automático:* los sistemas de visión estereoscópica, basados en lentes convencionales, son utilizados en la construcción de mapas 3D para diferentes propósitos en agricultura (Rong et al., 2014) entre los que se encuentran la navegación de vehículos, sistemas autónomos y asistidos por el operador (Kise et al., 2005), agricultura de

precisión (Rovira-Más et al., 2008), reconocimiento de frutas (Steen et al., 2016) o evitación de obstáculos por razones de seguridad (Barnard & Fishler, 1982).

2.2.4 Diseño del sistema de visión en el proyecto RHEA

Como se ha indicado previamente, el Proyecto *Robot fleets for Highly Effective Agriculture and forestry management* (RHEA, 2014), financiado por la Unión Europea, fue destinado para tareas de agricultura de precisión en campos de maíz, trigo y olivos. Los experimentos fueron realizados durante cuatro años con una demostración final en Madrid-España (21 de Mayo de 2014). Una flota de vehículos autónomos (terrestres y aéreos) equipados con diferentes sensores, todos incluyendo un sistema de visión por computador, fueron los elementos innovadores usados para las tareas agrícolas. Esta sección se centra en el sistema de visión por computadora instalado a bordo de uno de los vehículos terrestres basado en un tractor comercial, Fig. 2.7(a), usado para la detección de malas hierbas y su eliminación en campos de maíz (cultivo de línea ancha). La detección de las malas hierbas se basó en la localización de las líneas de cultivo, con respecto al vehículo agrícola, que permitió la ubicación de los rodales de malas hierbas y también actuó como ayuda para el guiado preciso del vehículo. El sistema completo abordó los problemas descritos en las secciones anteriores: (i) la selección de la banda espectral, (ii) sensor de imagen y sistema óptico y (iii) geometría del sistema visual (arreglo y pose). A continuación se describe cada uno de ellos (Pajares et al., 2016):

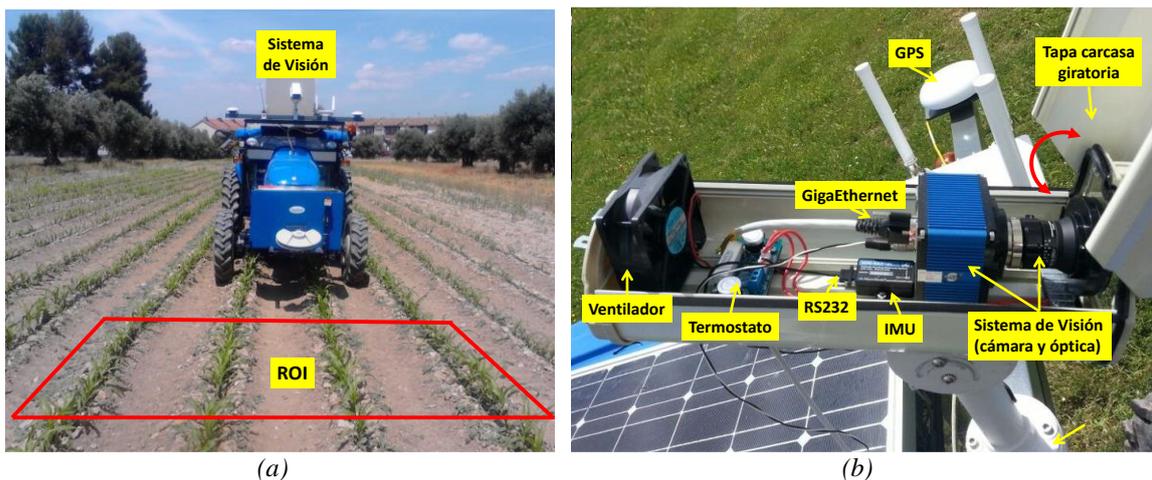


Fig. 2.7 Sistema de visión por computador: (a) a bordo de un vehículo terrestre autónomo; (b) cámara, sistema óptico y otros elementos dentro de una carcasa. Imágenes adaptadas y tomadas desde Emmi et al. (2014a).

(i) *Selección de la banda espectral*: se utilizaron las bandas espectrales correspondientes al espectro visible. Por lo tanto, un se utilizó un sensor *RGB* para

la adquisición de las imágenes agrícolas, cuya sensibilidad cubre los rangos típicos en el espectro visible, con sensibilidades entre 300 nm y 760 nm y con colas por encima de este valor, es decir, con sensibilidad al impacto de las radiaciones UV/IR.

- (ii) *Sensor de imagen y sistema óptico*: El sensor de imagen utilizado fue el modelo SVS4050CFLGEA de SVS-VISTEK (2017), construido con el sensor *CCD* Kodak KAI 04050M/C y el filtro de color Bayer *GR*. La Fig. 2.7 (b) muestra la cámara, el sistema óptico y otros componentes incorporados en una carcasa con protección IP65. La resolución fue 2336×1752 píxeles (H×V) con un tamaño de píxel de 5.5×5.5 μm , velocidad de adquisición de fotogramas 16.8 fps, tamaño del sensor 12.85×9.64 mm (h×v), formato del sensor 1" y diagonal óptica 16.06 mm.

El sistema óptico consistió en una lente con una longitud focal f de 10 mm, equipado por un filtro externo UV/IR 486 con longitudes de ondas de corte por debajo de 370 nm y por encima de 760 nm. La cámara es compatible con Gigabit Ethernet.

El tiempo de exposición fue controlado por el procedimiento descrito en Montalvo et al. (2013b), basado en el análisis del histograma de la ROI. Además se aplicó corrección de *Vignetting*, si bien no se aplicó corrección por balance de blancos. La velocidad de adquisición de fotogramas se fijó a 3 fps, los cuales fueron suficientes considerando que la velocidad máxima de operación del tractor fue de 6 Km/h.

- (iii) *Geometría del sistema visual (configuración y posicionamiento)*: con el objetivo de aplicar los tratamientos selectivos sobre la ROI ubicada por delante del vehículo agrícola, se estableció un área rectangular de 3m×2m (ancho × largo), Fig. 2.7(a). La ROI cubre cuatro filas de cultivo separadas 0.75 m una de otra, iniciando a 3m con respecto al eje vertical virtual que atraviesa el centro del plano de la imagen en la cámara (parámetro d en la Fig. 2.6), es decir, tiene coordenadas XYZ (0,0,3) m, respectivamente. Los parámetros extrínsecos de la cámara se fijaron como sigue: $(X_0, Y_0, Z_0) \equiv (0, 2, 0)$ m and $(\alpha, \beta, \theta) \equiv (20^\circ, 0^\circ, 0^\circ)$.

Bajo las anteriores consideraciones se dio solución a varios problemas, a saber: la detección de líneas de cultivo (Romeo et al., 2012; Montalvo et al., 2012; Gonzalez-Santos et al., 2016), la determinación de la cobertura de malas hierbas (Romeo et al.,

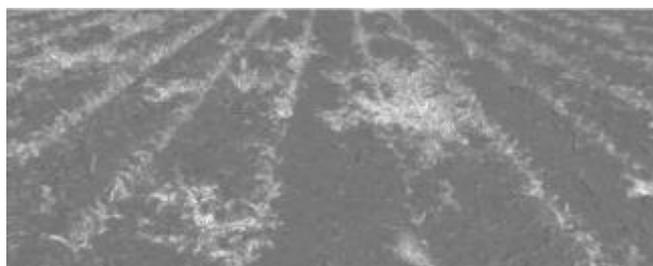
2013a; Guerrero et al., 2012), guiado preciso (Emmi et al., 2014a; Conesa-Muñoz et al., 2016) y detección de obstáculos (Campos et al., 2016).

2.3 Identificación de la vegetación

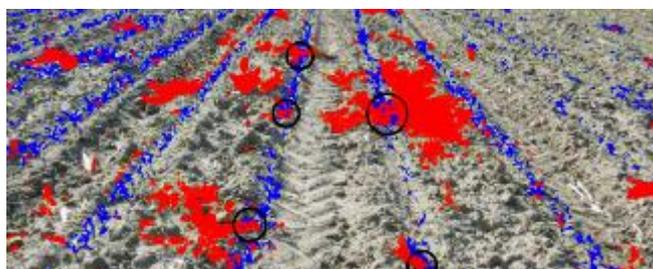
La identificación del verdor de las plantas (Fig. 2.8a) se puede abordar desde dos enfoques: (i) la discriminación entre la vegetación y el suelo, Fig. 2.8 (b), donde la vegetación se muestra en píxeles brillantes, mientras que el suelo en píxeles oscuros; (ii) la discriminación entre el cultivo y la malas hierbas, Figura 2.8(c), aquí las plantas de maíz aparecen en color azul y las malas hierbas en rojo. En cualquier caso, las técnicas para la identificación de la vegetación se enmarcan en las siguientes categorías: índice espectral visible, umbralización, aprendizaje y procesamiento mediante wavelets (Guijarro et al., 2015).



(a)



(b)



(c)

Fig. 2.8 (a) Imagen agrícola RGB; (b) Discriminación de la vegetación: cultivo y malas hierbas en píxeles brillantes y el suelo en píxeles oscuros; (c) Discriminación del cultivo (en azul) y las malas hierbas (en rojo).

2.3.1 Métodos basados en índices de vegetación en el espectro visible

Los índices de vegetación permiten la extracción de características espectrales por combinar dos o más bandas espectrales, basándose en las propiedades de la reflectancia producidas por la vegetación (Meyer & Camargo-Neto, 2008). Algunos de los índices usan solamente tres bandas espectrales visibles: rojo (R), verde (G) y azul (B), siendo el objetivo enfatizar alguna banda específica frente a las otras, acentuando la firma espectral (color) de interés.

Los índices de vegetación tienen la finalidad de obtener una imagen en escala de grises con el máximo contraste posible para resaltar la vegetación frente a otros elementos en la imagen. De esta forma se puede obtener una imagen de gris resultante de la segmentación donde los píxeles más intensos identifican las plantas y los píxeles más oscuros corresponden al suelo y demás residuos o estructuras existentes en el campo (piedras, árboles, cielo). A partir de la imagen en escala de grises, se aplica una técnica basada en métodos conocidos como de umbralización para separar definitivamente la vegetación del resto. Estas técnicas fueron diseñadas con el fin de resolver el problema de la alta variabilidad debida a la iluminación cambiante existente en los entornos agrícolas al aire libre. Woebbecke et al. (1995) analizaron varios índices de contraste en imágenes a color: $R-G$, $G-B$, $(G-B)/|R-G|$, $2G-R-B$. Este último conocido como exceso de verde (ExG , *excess green*) resultó adecuado para las imágenes agrícolas, incluso en días soleados con y en ausencia de sombras. Kataoka et al. (2003) usaron el índice de color de extracción de vegetación (*color index of vegetation extraction*) $CIVE=0.441R-0.811G+0.385B+18.78745$ para segmentar cultivos de habas y remolacha dulce bajo una vista cenital de la cámara. Camargo-Neto (2004) combinó el ExG y el exceso en rojo (*excess red*) $ExR=1.4R-G$ (propuesto por Meyer et al., 1998) para crear un nuevo índice conocido como exceso en verde menos exceso en rojo (*excess green minus excess red index*) $ExGR=ExG-ExR$. Pérez et al. (2000) crearon el índice de diferencias normalizadas (*normalized difference index*) $NDI=(G-R)/(G+R)$, el cual usa un cociente para distinguir las plantas de otros elementos. Una comparativa entre los índices ExG , $ExGR$ y NDI puede encontrarse en Meyer y Camargo-Neto (2008). Ribeiro et al. (2005) usaron una combinación lineal con los coeficientes $r=-0.7$, $g=0.588$, $b=0.136$ los cuales fueron obtenidos mediante la aplicación de algoritmos genéticos. Hague et al. (2006) describieron un enfoque para estimar un mapa de densidad de malas hierbas y cultivo usando el índice de vegetación (*vegetative index*) $VEG=G/(R^a B^{1-a})$ con $a=0.667$. Recientemente, Montalvo et al. (2016) obtuvieron una

imagen en escala de grises mejorada combinando los índices *ExG*, *ExGR*, *CIVE*, *VEG*, *NDI* y reduciendo el número de variables a través del análisis de componentes principales (*PCA*, *principal component analysis*), el cual disminuye la complejidad computacional y determina el peso que se asigna a cada índice individual en la combinación.

2.3.2 Procedimientos basados en umbralización

Estos métodos comúnmente asumen un problema bi-clase, donde las plantas y el suelo constituyen el objeto de la identificación. Otsu (1979) propuso uno de los métodos de umbralización automática, que ha sido utilizado en contextos agrícolas, basándose en que maximiza la varianza entre los píxeles de las clases del cultivo y del suelo en el correspondiente histograma de niveles de gris, previa transformación de la imagen por aplicación de alguno de los índices de vegetación indicados previamente. Esta técnica proporciona un umbral de forma automática, con comportamientos apropiados incluso bajo condiciones de iluminación cambiantes o adversas. Burgos-Artizzu et al. (2011) discriminaron las malas hierbas y el cultivo usando una combinación lineal con coeficientes $r = -0.884$, $g = 1.262$, $b = -0.311$. La imagen en escala de grises resultante fue binarizada usando el valor medio de la intensidad en lugar del método de Otsu, debido a que este último producía una infra-segmentación en las imágenes utilizadas, es decir, se obtenía menor cantidad de vegetación que la realmente existente. Guijarro et al. (2011) usaron una combinación lineal (*COM*) promediando cuatro índices de vegetación: *EXG*, *ExGR*, *CIVE* y *VEG* con los siguientes pesos específicos 0.25, 0.30, 0.33 y 0.12 que determinaron la contribución de cada uno de los índices respectivos. Los resultados obtenidos con la combinación mejoraron los obtenidos por cada índice de forma separada. La desventaja fue el incremento del tiempo de procesamiento por un factor de cuatro. Montalvo et al. (2013a) combinaron *EXG*, *CIVE* y *VEG* con las contribuciones 0.36, 0.47 y 0.17 respectivamente, y luego aplicaron una doble umbralización utilizando el método de Otsu. La primera umbralización separa la vegetación del suelo y la segunda aísla las plantas de maíz y las malas hierbas. Romeo et al. (2013a) propusieron un sistema experto para identificar el verdor de las plantas, inspirado en la técnica de agrupamiento borroso. Este procedimiento consistió de dos fases: (i) el aprendizaje para determinar un umbral dinámico para cada imagen y (ii) la clasificación, donde se aplicó una simple regla de decisión. Gée et al. (2008) presentaron un método para estimar la cantidad de malas hierbas presentes en cultivos

de cereal. La discriminación fue realizada por una segmentación basada en regiones a través del análisis de color y su similitud en base a la proximidad espacial entre píxeles vecinos.

2.3.3 Enfoques basados en aprendizaje

Estos métodos tienen su fundamento en procesos de aprendizaje tanto supervisado como no supervisado. En relación al aprendizaje supervisado, Guerrero et al. (2012) propusieron un procedimiento para identificar las plantas en campos de maíz, basado en máquinas de vectores soporte (*SVM, Support Vector Machines*), con el fin de separar los píxeles en dos clases identificando dos tipos de plantas, unas con un verdor significativo y otras con éste atenuado debido bien a que aparecían cubiertas por barro procedente de fuertes lluvias o como consecuencia del inicio del secado por actuación del herbicida. Los vectores soporte establecen los límites entre estas clases. La fase de entrenamiento se efectuó durante los periodos de inactividad del sistema de visión y la clasificación durante el proceso de actuación. El método fue útil para pre y pos tratamientos con tasas de éxito del 93.1%, en el primer caso para identificar plantas cubiertas por barro y en el segundo para determinar la efectividad de los herbicidas. Tellaeche et al. (2011) usaron SVM y una base de datos (conocimiento) con muestras previamente clasificadas. El rendimiento del algoritmo fue evaluado utilizando el porcentaje de clasificación correcta y el coeficiente de Yule. Ahmed et al. (2012) clasificaron las malas hierbas y el cultivo aplicando SVM. Un total de 14 características, que describen la plantación y las malas hierbas, fueron evaluadas para determinar la combinación óptima que proporcionó la tasa de clasificación más alta del 97%.

Por otra parte, en lo que respecta al aprendizaje no supervisado, Montalvo et al. (2012b) propusieron un método aplicando una doble umbralización y la técnica *LVQ (Learning Vector Quantization)* para separar las malas hierbas y el cultivo, con los consiguientes procesos de entrenamiento y clasificación. El método resultó ser útil para los tratamientos selectivos en aplicaciones de tiempo real. Guijarro et al. (2011) usaron agrupamiento borroso en primera instancia para discriminar plantas y suelo, y luego en una segunda etapa, el cultivo de las malas hierbas. El enfoque no supervisado fue también aplicado por Romeo et al. (2013a) para separar la vegetación y el suelo, y Meyer et al. (2004) para segmentar regiones de interés a partir de los índices *ExR* y *ExG*.

2.3.4 Técnicas basadas en wavelets

En el procesamiento de imágenes agrícolas resulta a veces necesario resaltar los detalles (bordes) y detectar las texturas, analizando la imagen desde diferentes ángulos. Es así que se pueden establecer dos categorías: (1) análisis del contenido de la frecuencia, considerada como una señal para separar las bajas (suaves variaciones en color) y las altas frecuencias (bordes que proporcionan detalles). En este enfoque, Bossu et al. (2009) propusieron un método para discriminar el cultivo y las malas hierbas aplicando la transformada *wavelets*. Compararon el rendimiento de cuatro familias de *wavelets*: *Daubechies*, *Meyer*, *Biorthogonal* y *Gabor*, los métodos basados en *Daubechies* superaron al resto en términos de precisión y tiempo de procesamiento en imágenes reales y sintéticas.

(2) Análisis de características de la textura, bajo la suposición de que plantas desiguales (cultivo y malas hierbas) responden de una manera diferente al filtrado de paso bajo/alto. En este enfoque, Ramírez (2013) discriminó entre suelo y cultivo en campos de maíz, utilizando el análisis textural de *wavelets*, al considerar que las frecuencias espaciales son diferentes dependiendo de la textura. Aplicó una combinación de técnicas de clasificación basada en redes neuronales (perceptrón multicapa) utilizando descriptores de textura como entrada al método, el cual logró una tasa de clasificación del 94.77%. Guijarro et al. (2015) propusieron un procedimiento para distinguir suelo y vegetación, basado en la transformada discreta de *wavelets* (*DWT, discrete wavelet transform*), con la familia *Daubechies* (*Haar*). En dicho método se combinaron: (i) el verdor de las plantas aplicando *ExG* y (ii) la información espacial de la textura, a través de la transformada *wavelets* y los descriptores estadísticos de primer orden (media y desviación estándar). El método obtuvo una nueva imagen *ExG* mejorada que proporciona mejores resultados en la binarización que cuando no se incorporan características de textura. El porcentaje promedio de error fue del 7.12%. Chou et al. (2007) propusieron un procedimiento para identificar el cultivo aplicando la transformada *wavelets* en paquetes (*WPT, wavelet packet transform*) combinado con la distancia Bayesiana ponderada, basada en la textura de la plantación y las características de las hojas, obteniendo tasas de exactitud del 94.63%. Ishak et al. (2009) usaron una combinación de una *wavelet* de Gabor con la distribución del campo gradiente (*GFD, gradient field distribution*) para identificar varios tipos de malas hierbas, bajo la hipótesis de que las malas hierbas con hojas ancha y estrecha despliegan diferentes características. La precisión de la clasificación total fue del 93.75%.

2.3.5 Comparación de enfoques en la identificación de vegetación

La elección de una determinada técnica debe ser evaluada particularmente para cada contexto de aplicación, prestando atención a varios factores, tales como: la variabilidad de los datos de la imagen, presencia de ruido, disponibilidad de ejemplos para el entrenamiento y pruebas, niveles aceptables de precisión, aplicación en tiempo real, entre otros (Davies, 2009). En la Tabla 2.2 se presenta una síntesis de ventajas y desventajas de los diferentes enfoques para la identificación de la vegetación.

Tabla 2.2 Comparación de los enfoques utilizados en la identificación de la vegetación.

Enfoque	Ventajas	Desventajas
Índices de vegetación en el espectro visible	<p>Mejora alguna banda específica (<i>R</i>, <i>G</i>, <i>B</i>), acentuando la firma espectral (color) de interés.</p> <p>Son bien conocidos y probados en diferentes cultivos y condiciones de iluminación.</p> <p>Han demostrado ser robustos a la variabilidad de la iluminación, propio de los entornos agrícolas (días soleados, nublados y claros).</p> <p>Coste computacional moderado y adecuado, incluso para trabajar en tiempo real.</p>	<p>Su coste computacional podría incrementar, dependiendo de la combinación lineal de los índices de vegetación y otras técnicas adicionales.</p>
Umbralización	<p>Proporcionan un umbral automático (auto-ajutable), que es adecuado para las imágenes capturadas bajo diferentes condiciones de iluminación.</p>	<p>Pueden producir infra-segmentación, es decir, la cantidad de vegetación resulta disminuida ligeramente.</p>
Aprendizaje	<p>Proporcionan buenos resultados, tanto en la tasa de clasificación como en el tiempo de ejecución.</p>	<p>La fase de entrenamiento en el aprendizaje supervisado es un proceso realizado fuera de la operatividad del sistema de visión (<i>off-line</i>) que suele ser exhaustivo y tedioso.</p>
<i>Wavelet</i>	<p>Extraen patrones característicos que resultan convenientes para la clasificación de diferentes plantas (cultivo y malas hierbas).</p>	<p>La discriminación basada en el análisis textural se afecta por la densidad vegetal en un estado crecido de las plantas.</p> <p>Se debe experimentar con el nivel de la descomposición, el tipo de familia de <i>wavelets</i> y las bandas de frecuencia que contienen la información necesaria para la clasificación.</p>

En los métodos que se proponen en el presente trabajo de investigación se han utilizado estrategias específicas basadas en los trabajos relacionados hasta aquí, cuya descripción detallada se incluye en el capítulo cuatro, destacando: a) *índices de vegetación*, para resaltar el verdor en la imagen a escala de grises; b) *umbralización*, para obtener una imagen binaria y separar los píxeles que pertenecen al suelo y la vegetación; c) *centroides de las clases* (cultivo y malas hierbas), para la clasificación de los píxeles utilizando una medida de similitud.

2.4 Detección de líneas de cultivo

El problema de la detección de líneas de cultivo ha sido abordado en la literatura bajo diferentes perspectivas. El caso de las líneas rectas (Fig. 2.9a) ha sido estudiado ampliamente (Guerrero et al., 2013; Montalvo et al., 2012a; Romeo et al., 2012), mientras que para las líneas curvas (Fig. 2.9b), las propuestas han sido más escasas (Vidović et al. 2016). Los enfoques propuestos para tales propósitos son: transformada de Hough, regresión lineal, exploración de franjas horizontales, acumulación de píxeles verdes, punto de fuga, análisis de frecuencia, análisis de agrupaciones de píxeles, visión estéreo y patrones regulares.

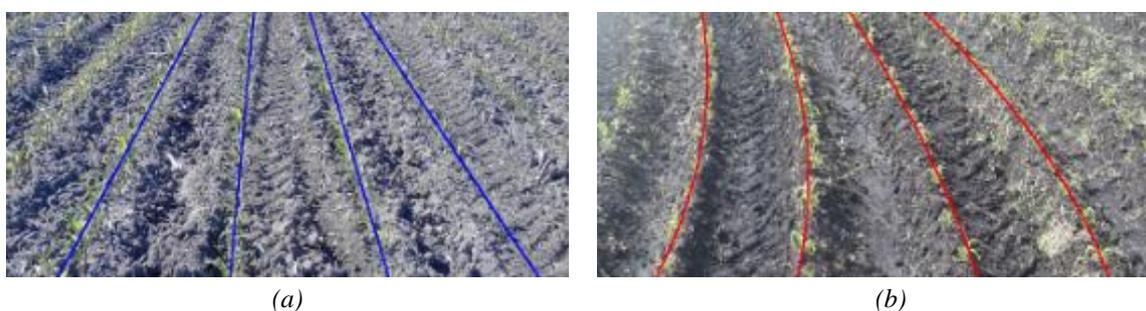


Fig. 2.9 Ejemplos de ROIs con líneas de cultivo detectadas; (a) rectas; (b) curvas

2.4.1 Transformada de Hough (TH)

La TH es una técnica muy popular que permite la detección de contornos en una imagen que puedan ser modelados matemáticamente (recta, círculo, elipse). Fue originalmente propuesta por Hough (1962) para detectar líneas rectas y después fue adaptada por Duda y Hart (1972) y Ballard (1981) para curvas. Desde entonces ha sido ampliamente estudiada en el campo de la visión por computador (Davies, 2004; Gonzalez & Woods, 2010; Pajares & de la Cruz, 2008).

La TH permite la detección de las líneas de cultivo, debido a que las plantas de

maíz se encuentran alineadas a lo largo del campo de cultivo, mientras que las malas hierbas crecen en forma irregular, mayoritariamente en los espacios ubicados entre las líneas de cultivo. La presencia de tales alineaciones se traduce en la aparición de picos máximos en el espacio de Hough, lo que permite identificar líneas rectas.

Para aplicaciones de tiempo real es común considerar algunas restricciones, de acuerdo a la disponibilidad de cierta información y conocimiento *a priori* del contexto de aplicación. Esto permite una reducción significativa de la cantidad de cálculos, tiempo de procesamiento y almacenamiento requerido por la TH.

Varios estudios han sido realizados aplicando la TH. Marchant (1996) detectó las líneas de cultivo asumiendo un número fijo de ellas y conocido previamente. La robustez del método fue verificada en campos de coliflor, remolacha dulce y trigo. Astrand y Baerveldt (2005) y Bakker et al. (2008, 2011) usaron esta técnica en plantaciones de remolacha dulce. En el primer trabajo se utilizó una cámara en escala de grises con un filtro de corte cercano al infrarrojo (780nm). El proceso fue computacionalmente preciso y eficiente. En el segundo estudio se combinó la información del GPS y algoritmos visuales. El resultado fue bastante aceptable con centímetros de precisión. Rovira-Más et al. (2005) realizaron un análisis de conectividad para obtener las ecuaciones de las líneas de cultivo. Barreda et al. (2009) utilizaron el punto de fuga para ajustar las líneas de cultivo. Ji y Qi (2011) aplicaron la TH con una variante aleatoria basada en el gradiente y obtuvieron rendimientos eficientes. Gée et al. (2008) emplearon una doble TH. Han et al. (2012) extrajeron las líneas de cultivo para el guiado con tiempos de procesamiento inferiores a 0.6 s. Leemans y Destain (2006) usaron una variante de la TH aplicando conocimiento *a priori* respecto a la posición y dirección de las líneas de cultivo con la finalidad de restringir la búsqueda en el espacio de Hough. Jafri y Deravi (1995) desarrollaron un método para detectar curvas parabólicas, reduciendo el tamaño del acumulador de Hough de 4D a 3D para parábolas con diferentes orientaciones.

2.4.2 Regresión lineal

Este enfoque estima la pendiente y el intercepto de la ecuación de la línea recta y asigna una ecuación a cada una de las líneas de cultivo. El método de mínimos cuadrados es el más común para estimar los parámetros y realizar el ajuste de la ecuación de la recta. A continuación se describen algunos trabajos en los cuales se aplicó esta técnica.

Billingsley y Schoenfisch (1997) desarrollaron un sistema visual bajo la proyección en perspectiva para la orientación automática de vehículos agrícolas en campos de algodón. Definieron una ventana en la imagen para definir el área donde se espera encontrar las líneas de cultivo. Los resultados obtenidos con las pruebas realizadas mostraron un rendimiento aceptable en términos de precisión.

Sogaard y Olsen (2003) localizaron las líneas de cultivo en campos de cebada usando regresión lineal ponderada. Los centros de gravedad de varios segmentos proporcionan los puntos para el ajuste de la recta. El método proporcionó unos resultados favorables para campos de cultivo con bajas densidades de malas hierbas.

Tillett y Hague (1999) y Hague et al. (2006) estimaron automáticamente un mapa de las densidades de malas hierbas y cultivo (cereal). La posición y orientación de las líneas de cultivo fueron estimadas aplicando el filtro extendido de Kalman y las líneas de cultivo se ajustaron por mínimos cuadrados. La consistencia del método se verificó frente a una evaluación manual realizada por un experto.

Montalvo et al. (2012a) y Guerrero et al. (2013) desarrollaron métodos específicos para campos de maíz. En el primer trabajo se aplicó mínimos cuadrados para ajustar las líneas rectas y una plantilla (máscara binaria) para determinar los límites de las líneas de cultivo esperadas en una determinada región de la imagen, logrando una tasa de eficiencia del 95.5% incluso con una alta densidad de malas hierbas. En el segundo experimento, se utilizó una predicción sobre la posición esperada de las líneas de cultivo, basada en el conocimiento geométrico del sistema visual. Posteriormente se realizaron los ajustes pertinentes de las líneas predichas a través del estimador Theil-Sen y basándose en la detección real de píxeles correspondientes a las plantas. El método fue probado con eficiencia y robustez, incluso con alta dispersión de píxeles.

Xue y Ju (2010) aplicaron operaciones morfológicas y mínimos cuadrados para el ajuste de la recta. Los resultados alcanzaron una precisión con errores por debajo del 29.5 mm con tiempos de procesamiento entre 0.7 y 1.3s.

Vidović y Scitovski (2014) desarrollaron un método general para la detección de líneas, siendo modificado para la identificación de dos o tres líneas de cultivo con opción de su extensión a un número superior. Combinaron la regresión lineal por mínimos cuadrados y un método de agrupamiento incremental, que fue probado en datos sintéticos. Definieron una serie de filas en la imagen junto con las alineaciones esperadas de las líneas de cultivo, que determinaron las agrupaciones correspondientes, de forma que los centros de las filas se asociaron a una determinada agrupación. El

mejor agrupamiento (es decir, la detección de la mejor línea) fue obtenida por el algoritmo de optimización global DIRECT (DIviding RECTangles) (Jones et al., 1993). El método logró resultados aceptables desde el punto de vista de procesamiento en tiempo real.

2.4.3 Exploración de franjas horizontales

La idea principal consiste en dividir la imagen en bandas horizontales y posteriormente estimar puntos en cada una de ellas, los cuales definirán las líneas de cultivo. Sainz-Costa et al. (2011) desarrollaron un método basado en este enfoque para la proyección de líneas de cultivo utilizando una secuencia de video. Las imágenes fueron divididas en cuatro franjas horizontales, identificando clústeres de píxeles que pertenecen al cultivo. Las alineaciones de los centros de gravedad de los clústeres determinan las líneas rectas, permitiendo la asociación de una ecuación con cada línea de cultivo.

Conesa-Muñoz et al. (2011) y Bengochea-Guevara et al. (2012) presentaron un método que utilizó una cámara ubicada en posición prácticamente cenital (80°) en campos de maíz. En cada imagen obtuvieron dos líneas rectas, promediando agrupaciones de píxeles en la parte inferior y superior, con ello se determinó la posición relativa del vehículo con respecto a las líneas de cultivo, en términos de dirección y desplazamiento.

Jiang et al. (2015) diseñaron un algoritmo para diferentes plantíos (cereal, maíz y fréjol), incluso con alta densidad de malas hierbas. El método se basó en el concepto de multi-ROIs (pequeñas regiones de interés). Para ello dividieron la imagen en bandas horizontales y estimaron los puntos centrales en cada franja, los cuales determinan las líneas de cultivo. La detección de los puntos en la primera franja de exploración es un factor crucial para la estimación de los siguientes puntos. Si falla este paso, por la presencia de malas hierbas y discontinuidades en las líneas, el método fracasa. Los puntos considerados como ficticios fueron eliminados aplicando un algoritmo de clasificación y las líneas de cultivo, finalmente, quedaron detectadas por ajuste de mínimos cuadrados. El algoritmo fue probado en más de 300 imágenes adquiridas bajo diferentes condiciones naturales. El método logró una tasa de detección del 93%, requiriendo 61 ms en lo que respecta al tiempo de procesamiento para imágenes de dimensiones de 640×480 píxeles, lo que resultó adecuado para procesamiento en tiempo real.

2.4.4 Alineación de píxeles verdes

Estos métodos asumen que los píxeles que definen la línea de cultivo forman una alineación de píxeles verdes a lo largo de la línea esperada. Olsen (1995) desarrolló un método inspirado en esta técnica para el guiado automático de una podadora para el control mecánico de las malas hierbas en campos de cebada, usando una cámara de video en posición cenital con un filtro infrarrojo para diferenciar claramente entre las plantas y el suelo. Bajo esta geometría (cenital), la acumulación de los píxeles es alineada verticalmente. Siguiendo las columnas en el rectángulo (ROI), obtuvo una curva de sumas ajustando posteriormente una función sinusoidal por mínimos cuadrados, donde el máximo local proporciona la localización del centro de la fila.

En Romeo et al. (2012), las acumulaciones de píxeles verdes fueron detectadas explorando las líneas visuales en campos de maíz, bajo la proyección de perspectiva y considerando la convergencia en la imagen de líneas paralelas en el campo de cultivo. El método fue comparado favorablemente contra la TH y con suficiente robustez, incluso bajo las vibraciones y movimientos indeseados del tractor.

2.4.5 Punto de Fuga

Pla et al. (1997) propusieron un método para extraer información visual con la finalidad de guiar un vehículo en el campo. Las imágenes fueron segmentadas en regiones basadas en etiquetado y análisis espectral. Los esqueletos de las regiones fueron extraídos y los correspondientes puntos fueron enlazados e identificados como las rectas que definen las líneas de cultivo. Estas líneas convergen en el conocido punto de fuga existente en la proyección de perspectiva. En ciertos modos el concepto de punto de fuga fue también aplicado por Romeo et al. (2012) y Jiang et al. (2016), en este último trabajo combinado con la TH. Los distintos experimentos llevados a cabo sobre diferentes secuencias de imágenes mostraron que estos enfoques obtienen resultados satisfactorios.

2.4.6 Análisis de la frecuencia

Estos métodos asumen que las líneas rectas de cultivo son paralelas en la escena 3D y se proyectan en la imagen preservando la estructura bajo la proyección en perspectiva, por lo que despliegan características específicas en el dominio de la frecuencia. Motivados en esta idea, Bossu et al. (2009) distinguieron las líneas de cultivo aplicando la transformada de *wavelets*. Una función de onda madre fue elegida

con la frecuencia apropiada, según determinaron las filas de cultivo en la imagen. Compararon el rendimiento de cuatro familias de *wavelets*: *Daubechies*, *Meyer*, *Biorthogonal* y *Gabor*. La primera superó al resto en términos de exactitud y tiempo de procesamiento en imágenes reales y sintéticas. Hague y Tillett (2001) utilizaron un filtro de paso banda en el dominio de la frecuencia para extraer las líneas de cultivo de cereal, conociendo la geometría de la cámara y el espacio entre filas (220 mm). El seguimiento de la posición y orientación de las líneas fue realizado mediante el filtro extendido de Kalman. Las imágenes fueron capturadas a 8-bit en escala de grises (192×144) y tomadas desde un tractor con una video-cámara *CCD* ubicada a una altura de 1.2m e inclinada 45°, la cual fue sensible al infrarrojo cercano (*NIR*) y bloqueó la luz visible. El método fue probado, demostrando alta precisión, para guiar una azada mecánica, que navega a una velocidad de 1.6 m/s, en campos de trigo con presencia de sombras y moderado nivel de malas hierbas. Vioix et al. (2002) extrajeron información de la frecuencia aplicando filtros de Gabor bi-dimensionales. El algoritmo fue eficiente desde el punto de vista cuantitativo.

2.4.7 Análisis de agrupaciones de píxeles

La imagen es segmentada en regiones y los píxeles adyacentes son agrupados en lo que se conoce como *blobs* aplicando el criterio de similitud de los niveles de grises. Fontaine y Crowe (2006) consideraron agrupaciones con más de 200 píxeles, obteniendo el ángulo del eje principal y el centro de gravedad de cada agrupación para determinar la orientación y las líneas de cultivo, respectivamente.

2.4.8 Visión estereoscópica

Estos métodos generalmente usan dos cámaras separadas una cierta distancia para capturar dos imágenes, izquierda y derecha. Son útiles siempre y cuando las plantas de cultivo y en su caso las malas hierbas posean alturas suficientes con respecto al suelo para poder discriminar precisamente por las alturas (Rovira-Más et al., 2008; Romeo et al., 2012). Estos sistemas son más costosos, computacionalmente, debido al proceso de correspondencia involucrado.

En este contexto, Kise y Zhang (2008) y Kise et al. (2005) determinaron las localizaciones 3D pertenecientes a los objetos de interés en la escena, que son proyectados como mapas de elevación para medir la altura y volumen del cultivo, así como también para la detección de las líneas de cultivo usadas en el guiado de un

tractor. Rovira-Más et al. (2008) construyeron mapas 3D, combinando la información proporcionada por el sistema de visión estéreo, un sensor de localización y la unidad de medida inercial (*IMU, Inertial Measurement Unit*). Los resultados probaron que este enfoque puede ser usado para el monitoreo de los cultivos y la navegación autónoma.

2.4.9 Patrones regulares

Vidović et al. (2016) aplicaron un método basado en comparación de plantillas con programación dinámica (optimización) para la detección de líneas de cultivo rectas y curvas en diferentes cultivos (maíz, apio, patata, cebolla, girasol y fréjol) y etapas de crecimiento. Con este método se puede trabajar sin conocimiento previo del número de líneas a detectar y la geometría del campo. Sin embargo, se asume que todas las líneas del cultivo están igualmente espaciadas en el campo y en la imagen. Las imágenes originalmente capturadas fueron redimensionadas a 320×240 píxeles con la finalidad de reducir el tiempo de computación sin pérdida significativa de información. Una mayor resolución (p.ej. 640×480) incrementó considerablemente el tiempo de ejecución, incluso usando un lenguaje de programación compilado (p.ej. C++). Además, la eficiencia del procedimiento disminuyó en algunas líneas de cultivo localizadas en la parte superior de la imagen, debido a la proyección de perspectiva, ya que los patrones repetitivos se pierden aquí y también debido a la presencia de malas hierbas entre las líneas.

2.4.10 Comparación de técnicas para la detección de líneas de cultivo

La elección de una determinada técnica debe ser evaluada particularmente para el contexto de la aplicación, agrícola en el caso que nos ocupa, procurando atención a varios factores, tales como: número y tipo de líneas de cultivo (recta y/o curva) a detectar, espaciado entre líneas, la variabilidad de los datos de la imagen, presencia de ruido, niveles aceptables de precisión, tiempo de respuesta para aplicación en tiempo real, entre otros (Davies, 2009). En la Tabla 2.3 se presentan algunas ventajas y desventajas de los diferentes enfoques expuestos hasta aquí para la detección de líneas de cultivo (García-Santillán & Pajares, 2016).

Tras la revisión de los métodos expuestos hasta aquí en relación a la detección de líneas, se puede señalar que varios de ellos no resultan adecuados para resolver el problema de la detección de ambos tipos de líneas de cultivo, rectas y curvas, con espacios regulares e irregulares entre las líneas. Sin embargo, han proporcionado pistas

útiles y suficientes, las cuales han sido explotadas en la propuesta de dos nuevos procedimientos resultantes de esta investigación y están descritos en el capítulo tres. Entre los indicios más relevantes cabe señalar: a) *TH* aplicada en segmentos rectos para determinar puntos de inicio correspondientes a las filas de cultivo; b) *Regresión lineal* para el ajuste de polinomios (lineal o cuadrático) que definen las líneas de cultivo y c) *multi-ROIs* sobre las alineaciones de píxeles verdes y análisis de *blobs* para buscar puntos de referencia a lo largo de las líneas de cultivo.

Tabla 2.3 Comparativa de las técnicas utilizadas en la detección de líneas de cultivo.

Técnica	Ventajas	Desventajas
Transformada de Hough	<p>Permite detectar figuras inmersas en una imagen que puedan ser expresadas matemáticamente, como las líneas rectas de cultivo.</p> <p>Ha demostrado ser robusta frente al ruido, oclusiones y vacíos (calvas) en las hileras de cultivo.</p>	<p>La detección de líneas de cultivo se ve afectada por la densidad vegetal en un estado crecido.</p> <p>Su coste computacional puede incrementar, significativamente, en atención a la resolución de la imagen y del espacio acumulador. Sin embargo, pueden incorporarse algunas restricciones por conocimiento <i>a priori</i> del contexto de aplicación, para reducir la cantidad de cálculo y tiempo de cómputo requerido para trabajar en tiempo real.</p>
Regresión lineal	<p>Se obtienen resultados aceptables tanto en precisión como en tiempo de procesamiento, incluso para aplicaciones en tiempo real.</p> <p>Existen otras variantes a la técnica más usada (mínimos cuadrados) para el ajuste de rectas, que resultan ser más robustas frente a la alta dispersión de píxeles (como el estimador Theil-Sen).</p>	<p>Es sensible a la presencia de malas hierbas, ya que estos puntos aislados alteran el cálculo de los coeficientes de la línea recta. Por lo que el método es favorable especialmente con baja densidad de malas hierbas.</p>
Exploración de franjas horizontales	<p>Se puede alterar el número de franjas para estimar puntos de referencia que definirán las líneas de cultivo, incluso, aquellos que tengan curvatura.</p> <p>La idea resulta adecuada, tanto para imágenes en proyección cenital, como en perspectiva.</p>	<p>Se debe experimentar minuciosamente con el número de franjas horizontales en que se divide la imagen. Por ejemplo: 4, 8, 12 o más.</p>

Alineación de píxeles verdes	Se pueden incorporar algunas restricciones (como saltos, orientación) para limitar la búsqueda y conteo de los píxeles verdes con la finalidad de reducir el tiempo de procesamiento.	Su coste computacional puede incrementar significativamente dependiendo de la resolución de la imagen. Puede no resultar adecuado para cultivos con grandes discontinuidades en las hileras de cultivo.
Punto de Fuga	El punto de fuga se puede aproximar conociendo la geometría del sistema de visión, lo que permite validar las líneas rectas de cultivo detectadas.	El concepto de punto de fuga se aplica a líneas rectas de cultivo, no así en los sembríos curvos, debido a que no siempre convergen hacia un punto fijo, sino que depende de la curvatura de los surcos.
Análisis de la frecuencia	Las líneas de cultivo, paralelas en la escena 3D, despliegan características específicas en el dominio de la frecuencia que facilitan la localización de las hileras.	En un estado crecido de las plantas, el análisis textural espacial usando <i>wavelets</i> , no proporciona información suficiente para la discriminación de las texturas. En el dominio de la frecuencia, los cultivos espaciados irregularmente no despliegan un patrón de frecuencia, por lo que no es posible la detección de las líneas de cultivo.
Análisis de agrupaciones de píxeles (<i>blobs</i>)	Comúnmente utilizan procedimientos de análisis de formas (como la compacidad y esqueletización) y operaciones morfológicas (como la dilatación y erosión) que suelen tener un costo computacional aceptable.	Puede no ser adecuado para las imágenes con objetos complejos y fondos ruidosos. Las principales causas de error son la discontinuidad en el patrón lineal de las líneas, los espacios entre filas y la no uniformidad (rugosidad) en los bordes de la línea de cultivo. Las operaciones morfológicas son potentes pero limitadas debido a que son restringidas a operaciones locales careciendo de conocimiento global de la imagen.
Visión Estéreo	Proporcionan información suficiente para determinar la posición y orientación de los objetos en el espacio 3D.	Se usan en cultivos que tienen una cierta distancia del suelo y si las plantas de malas hierbas y cultivo difieren en altura. Cuando los objetos son vistos bajo la proyección en perspectiva, las imágenes están sujetas a distorsiones. Pueden resultar costosos computacionalmente por el proceso implícito de correspondencia.
Patrones regulares	El número de líneas a detectar y la geometría del campo no son requeridos <i>a priori</i> .	No resultan adecuados para líneas de cultivo espaciados irregularmente. El tiempo de ejecución aumenta considerablemente con el tamaño de la ROI (resolución).

CAPÍTULO 3

Detección de líneas de cultivo rectas y curvas

3.1 Introducción

Los sistemas de visión por computador a bordo de tractores autónomos son herramientas útiles para diversas tareas relacionadas con la agricultura de precisión, incluyendo la detección de líneas de cultivo en sembríos de fila ancha (Emmi et al., 2014a; RHEA, 2014), como es el caso del maíz. Esta tarea es importante para la aplicación tanto de tratamientos específicos (Gée et al., 2008; Montalvo et al., 2012a; Romeo et al., 2012; Guerrero et al., 2013) como para el guiado preciso cuando los sistemas de posicionamiento como el GPS (*Global Positioning System*) no proporcionan la resolución requerida. En efecto, la navegación de los tractores en el campo de cultivo se basa principalmente en el sistema GPS, y aunque esta tecnología proporciona una buena exactitud (Emmi et al. 2014a) para el guiado preciso del vehículo, cuando ocurren pequeñas desviaciones del orden de centímetros, la detección de líneas de cultivo es también crucial para la corrección (Kise & Zhang, 2008; Rovira-Más et al., 2003).

Los entornos agrícolas al aire libre están influenciados por las condiciones de iluminación no controladas (sombras o excesiva/pobre iluminación) afectando la calidad de la imagen; así como también, las discontinuidades presentes en las líneas de cultivo debido a la falta de germinación, defectos durante la siembra o debido a la aparición de plagas/enfermedades. La alta densidad de las malas hierbas, con una similar firma espectral que la del cultivo, puede aparecer en los espacios entre líneas de cultivo y en sus proximidades, produciendo líneas de cultivo con anchos falsos en la imagen proyectada y por lo tanto, líneas incorrectas durante la detección. Diferentes alturas y volúmenes de plantas, debido a las etapas de crecimiento, pueden también crear problemas severos. Líneas de cultivo curvas irregularmente espaciadas, movimientos del tractor en terrazas irregulares con pendientes o debido a desviaciones durante la navegación añaden grados de dificultad adicionales. Las líneas de cultivo con curvatura pueden ser comunes en algunos campos debido a la orografía del terreno, y éstas no solo aparecen en terrazas agrícolas, sino también en parcelas planas con una geometría irregular.

Se han propuesto diferentes enfoques basados en imágenes orientados a la detección e identificación de las líneas de cultivo tal y como se explicó en el capítulo

dos, entre ellos: transformada de Hough (TH), regresión lineal, exploración de franjas horizontales, punto de fuga, análisis de la frecuencia, análisis de regiones o *blobs*, visión estéreo o patrones regulares (Montalvo et al., 2012a, Vidović et al., 2016). Algunos de ellos combinan dos o más técnicas, y todas aplican cierto conocimiento *a priori* traducido como diferentes restricciones, tales como por ejemplo el número de líneas de cultivo a ser detectadas, el espaciado entre ellas, la geometría del sistema de visión, la posición y orientación de la cámara, los parámetros intrínsecos y extrínsecos, el punto de fuga en proyección de perspectiva.

De acuerdo a las técnicas y las consideraciones adversas mencionadas previamente, en este trabajo de investigación se presenta una nueva estrategia diseñada para la detección de líneas de cultivo rectas y curvas en sembríos de línea ancha (campos de maíz), incluso con líneas espaciadas irregularmente y bajo las diferentes condiciones ambientales señaladas. Esto constituye la principal contribución de esta investigación, logrando similar y en ocasiones mejor rendimiento que otros métodos existentes para la detección de líneas de cultivo rectas y curvas con espaciado regular, a la vez que obtiene notables mejoras en la detección de las líneas de cultivo espaciadas irregularmente, así como también con ambos tipos de líneas (rectas y curvas) coexistiendo en la misma imagen. La estrategia propuesta explota el rendimiento de algunos procedimientos existentes y los integra en una estrategia global para lograr un método válido para el máximo número de situaciones adversas, cuyos soportes de investigación se encuentran descritos en García-Santillán et al. (2017a, b). Las principales consideraciones al respecto fueron las siguientes:

- a) Una línea de cultivo, en la imagen, es una acumulación de píxeles verdes siguiendo una alineación específica (recta o curva).
- b) Se conoce la geometría del sistema de la cámara (monocular) y el número de líneas de cultivo. La geometría se refiere a la situación de la cámara en el tractor, junto con su orientación respecto de la observación sobre el suelo, incluyendo altura e inclinación respecto del suelo, así como la longitud focal del sistema óptico (Pajares et al., 2016). Éstos son los parámetros extrínsecos que sin duda pueden variar dependiendo del sistema de visión (sensor y sistema óptico) seleccionado.
- c) El uso de multi-ROIs limita el espacio de búsqueda dentro de la imagen. Bajo esta consideración se restringe el espacio de búsqueda de la TH, incrementando su eficacia.

- d) La regresión lineal se aplica para ajustar polinomios (lineales y cuadráticos) sobre las líneas de cultivo en la imagen, asumiendo incluso que ambos tipos de líneas de cultivo puede aparecer en la misma imagen, lo que conlleva una aportación de gran relevancia en el ámbito de la detección de líneas de cultivo. Además, la regresión lineal no necesita una estimación previa acerca de la localización de las filas de cultivo para el posterior ajuste de curvas, como en Guerrero et al. (2013).

De acuerdo con el planteamiento anterior, el capítulo se estructura considerando en primer lugar los aspectos relacionados con los materiales utilizados para lograr el objetivo propuesto (sección 3.2.1). Se describe el método desarrollado para su consecución (sección 3.2.2). Finalmente, en la sección 3.3 se analizan exhaustivamente los resultados experimentales obtenidos.

3.2 Materiales y métodos

3.2.1 Colección de imágenes

Las imágenes utilizadas en este estudio fueron obtenidas durante Febrero y Marzo de 2015 en un campo experimental de maíz ubicado en la estación de investigación San Francisco, Tulcán-Carchi, Ecuador, a 2787 m sobre el nivel del mar (Latitud 0.62° N; Longitud -77.75° W), cubriendo un área de dos hectáreas. El terreno es irregular con pendientes de hasta 12°. Todas las adquisiciones fueron espaciadas por seis días a lo largo de 40 días bajo diferentes condiciones de iluminación y etapas de crecimiento, tanto de las plantas de maíz como de las malas hierbas. La Fig. 3.1 muestra algunos ejemplos ilustrativos de las imágenes obtenidas en el campo. En (a) existe una baja presencia (densidad) de malas hierbas; en (b) aparecen diferentes sombras proyectadas en el suelo, incrementando el grado de dificultad para el procesamiento de las imágenes con respecto a la extracción del verdor; en (c) aparecen diferentes tamaños de plantas de maíz y discontinuidades en las líneas de cultivo, alcanzando longitudes de hasta 1.20 m de ausencia de plantas en la misma fila. La ausencia de plantas se debe a errores durante la siembra o tal vez debido a la falta de germinación de las semillas. Además, se muestran algunas imágenes adquiridas bajo diferentes condiciones de iluminación según el día. En (d) día claro, (e) nublado y (f) soleado. Las líneas de cultivo estaban espaciadas en promedio 0.85 m, con variaciones entre 0.75 m y 0.95 m, siendo la variabilidad mayor en el caso de las líneas curvadas.

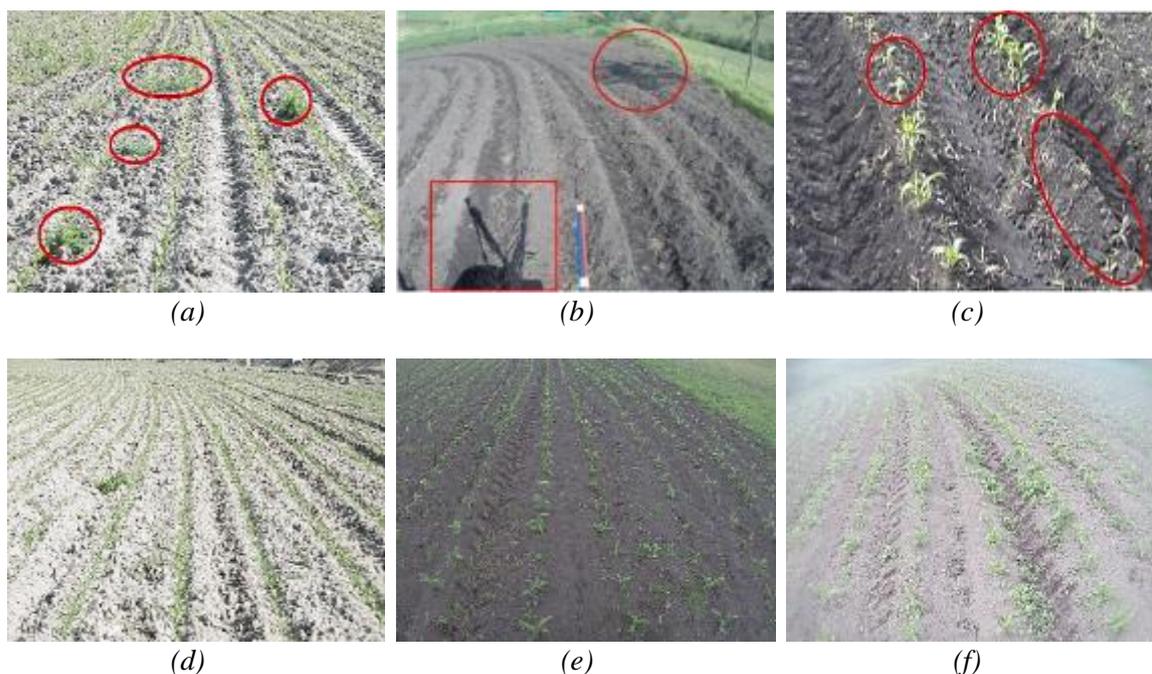


Fig. 3.1 Ejemplos ilustrativos de las imágenes obtenidas en el campo de cultivo; (a) con una densidad baja de malas hierbas; (b) presencia de sombras; (c) plantas con diferentes tamaños y discontinuidades en las líneas de cultivo. Imágenes adquiridas bajo diferentes condiciones de iluminación: (d) día claro; (e) oscuro; (f) soleado

Las imágenes fueron obtenidas con una cámara a color GoPro Hero 3+ Black Edition, modelo CHDHX-302 y manufacturada por Woodman Labs, Inc. (USA, California). Este dispositivo está equipado con un sensor de 1/2.3", tamaño de pixel 1.55 μm y longitud focal 3 mm. La cámara fue instalada en el frente de un tractor New Holland TD90 que se mueve, en lo que respecta a este estudio, a una velocidad promedio de 3 km/h (~ 0.83 m/s). El sistema de visión a bordo del tractor fue fijado a una altura de 2 m y con el eje óptico inclinado 45° respecto al suelo (ángulo de cabeceo, *pitch*) y sin desplazamiento lateral, es decir, con los ángulos de alabeo (*roll*) y guiñada (*yaw*), con un valor de 0° . Esta disposición (pose) junto con la longitud focal y la resolución del sensor permiten determinar la correspondencia entre las distancias/áreas de la escena 3D y los píxeles proyectados en la imagen, aplicando una simple transformación entre los sistemas de coordenadas (Pajares et al. 2016).

Las imágenes digitales fueron capturadas bajo la proyección de perspectiva y almacenadas con 24-bits por píxel, y por tanto con 8 bits por cada canal espectral R, G y B, con una resolución de 3000×2250 píxeles (7 Mpx) en el espacio de color RGB en formato JPG. Sin embargo, solo resulta de interés un área reducida en el suelo (*Region of Interest*, ROI) para aplicar los tratamientos selectivos o como referencia para el

guiado del tractor. El tamaño y localización de la ROI deben ser especificadas considerando: (i) el número de líneas de cultivo a ser detectadas y (ii) que la ROI sea proyectada con suficiente resolución (en píxeles) para identificar las plantas verdes sin ambigüedad (cultivo/malas hierbas) y también con suficientes puntos para estimar las ecuaciones que definen las líneas de cultivo.

En el enfoque propuesto, se seleccionaron cuatro líneas de cultivo para su detección, el cual coincide con el número utilizado en el proyecto RHEA (2014) y reportado por Emmi et al. (2014a), debido a que en este caso los implementos tenían cuatro parejas de quemadores, cada pareja actuando sobre una línea de cultivo. Sin embargo, el método puede ser fácilmente adaptado para detectar cualquier número de líneas de cultivo con la correspondiente configuración de la cámara. Considerando las cuatro líneas de cultivo separadas 0.85 m, el ancho total de la ROI fue 3.4 m, la cual se fijó para comenzar a 3 m adelante del eje vertical virtual que atraviesa el centro del plano de la imagen en la cámara (Fig. 2.6) para evitar que otros elementos en el frente del tractor sean proyectados en la imagen. La longitud de la ROI fue fijada en 5 m para proporcionar suficiente resolución y número de puntos, como se indicó previamente. La ROI en la escena 3D (campo de maíz) se proyecta sobre la imagen (bajo proyección de perspectiva) con una resolución de 2000×650 píxeles (ancho \times largo), la cual representa aproximadamente el 20% de la imagen original y está localizada siempre en la misma posición dentro de la imagen.

La Fig. 3.2(a) muestra un ejemplo de la ROI enmarcada en un rectángulo. Considerando los 5 m de largo de la ROI y la velocidad promedio de navegación del tractor de 0.83 m/s, el vehículo necesita alrededor de 6 s para atravesar dicha distancia antes de adquirir una nueva imagen con una nueva ROI. El tiempo de procesamiento de la imagen más el tiempo empleado para activar los implementos, cuando se requiera, debe ser inferior a 6 s para ser considerado como procesamiento en tiempo real.

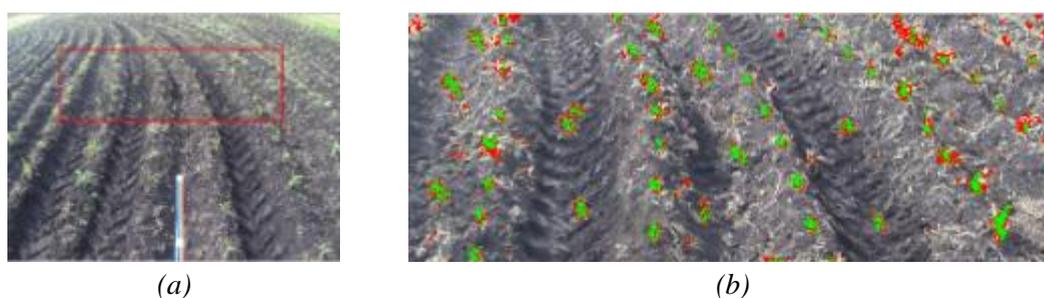


Fig. 3.2 (a) Localización de la ROI en la imagen original RGB como un rectángulo (2000×650 píxeles); (b) identificación del suelo (píxeles oscuros), malas hierbas y cultivo (píxeles rojos y verdes) dentro de la ROI.

Las imágenes fueron procesadas utilizando Matlab (MathWorks, 2015), versión 8.5 (R2015a), usando un procesador Intel Core i7 2.0 GHz, 8 GB RAM y sistema operativo Windows 8.1 Pro (64-bits). Los algoritmos propuestos fueron desarrollados utilizando la interfaz gráfica de usuario GUIDE (*Graphical User Interface Development Environment*) incorporado en Matlab.

3.2.2 Arquitectura lógica del método de visión

La estrategia propuesta fue diseñada considerando tres fases principales: (i) segmentación, (ii) identificación de puntos de inicio y (iii) detección de líneas de cultivo. La Fig. 3.3 muestra la estructura completa, incluyendo el diagrama de flujo. A continuación se describen cada una de las fases mencionadas con sus correspondientes métodos de procesamiento. En la descripción de los mismos se toma como base una imagen representativa del conjunto de imágenes disponibles, para ilustrar los aspectos relevantes involucrados en cada uno de los procesos. Conviene reseñar en este sentido, que el comportamiento de los métodos desarrollados es similar al que se muestra a lo largo del presente capítulo sobre el conjunto total de imágenes analizadas.

3.2.2.1 Segmentación

Para detectar líneas curvas en la imagen procedente del campo, resulta crucial identificar las plantas del cultivo con la máxima precisión posible. La precisión del 93% obtenida por Montalvo et al. (2013a) para dicha identificación se establece como un límite inferior a considerar. Así, para conseguir una mejora en este sentido es necesario obtener una tasa de detección por encima de este valor para distinguir el cultivo de las malas hierbas que tienen firmas espectrales similares, como se ha indicado reiteradamente. Respecto de la detección de las líneas curvas es necesario tener en cuenta ciertas consideraciones adicionales. Esto obedece a que no existe información a priori o restricciones geométricas aplicables para estimar las posiciones de las líneas de cultivo curvas, a diferencia de los métodos diseñados para la detección de líneas rectas de cultivo. Además, las discontinuidades presentes en las líneas de cultivo, junto con la distribución aleatoria de las malas hierbas, refuerzan la necesidad de lograr el máximo nivel de discriminación en lo que respecta a los cultivos mediante la aplicación de técnicas de segmentación. Al respecto, la doble umbralización propuesta por Montalvo et al. (2013a), ha mejorado el rendimiento en la detección frente a otras estrategias existentes, incluyendo el aprendizaje supervisado (Guerrero et al., 2012). En efecto, la

doble umbralización es dinámicamente autoajustable, sin aprendizaje, a las variables condiciones ambientales comunes en las tareas agrícolas al aire libre. Como se ha indicado en el capítulo dos, se trata de métodos de detección automática de umbrales basados en el análisis de los modos de los histogramas de intensidad.

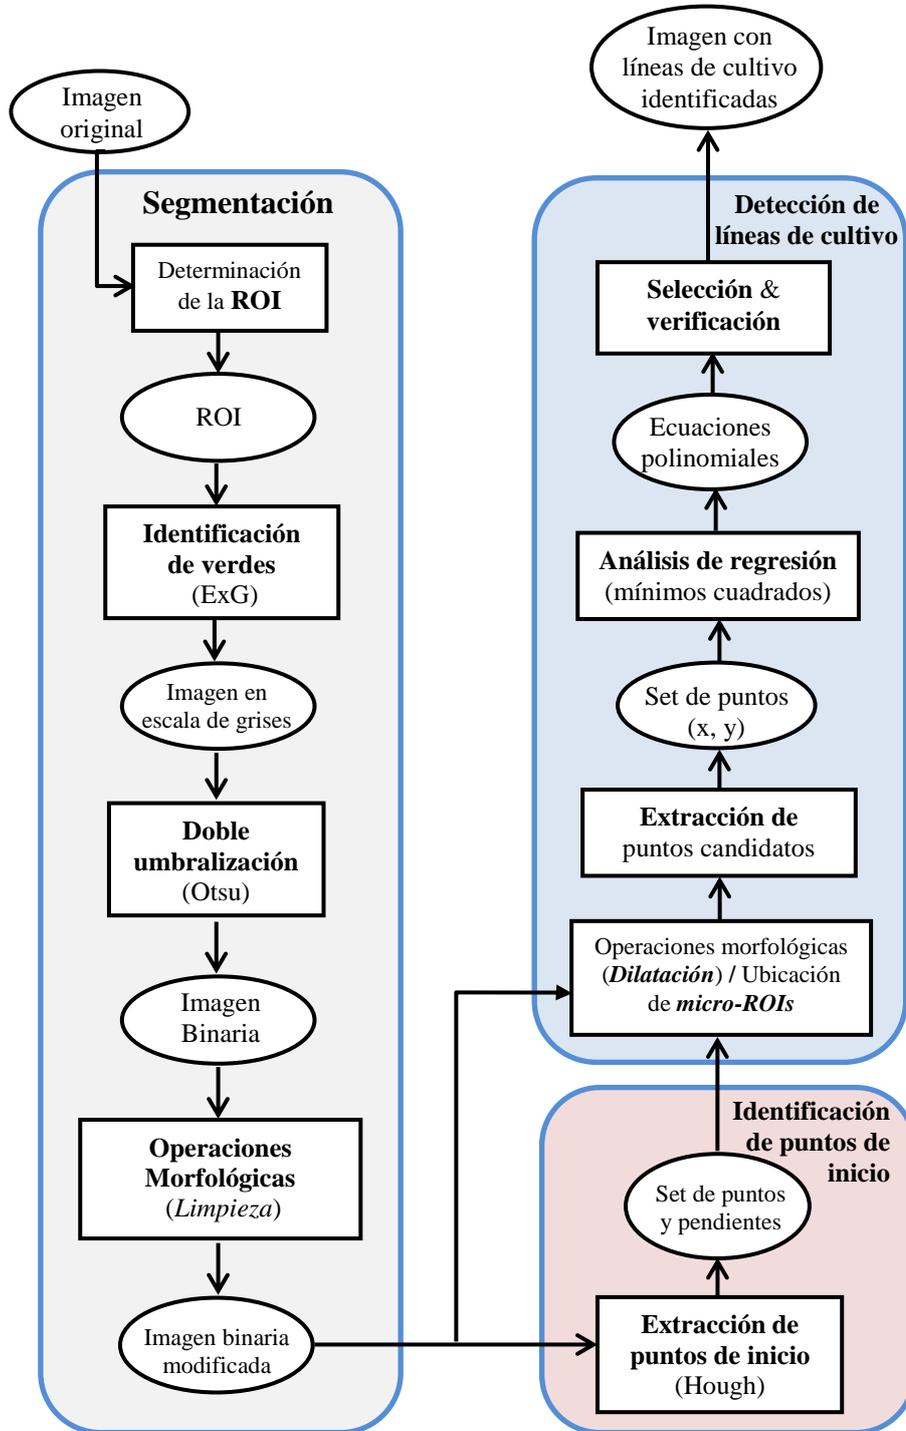


Fig. 3.3 Arquitectura lógica del método de visión por computador

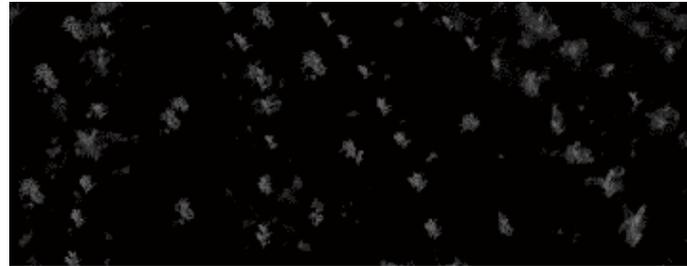
Además, en el campo experimental existen malas hierbas invasoras (por ejemplo *Brassica campestris*, *Pennisetum clandestinum*, *Rumex crispus*, *Calendula arvensis*), incluyendo algunas especies con tonos verde-rojizos (como *Polygonum nepalense*). La doble umbralización resultó adecuada para diferenciar cultivo y malas hierbas en las imágenes utilizadas en los experimentos. Bajo estas consideraciones, la fase de segmentación fue diseñada con cuatro procesos:

- a) *Determinación de la ROI*, como se especificó previamente. La Fig. 3.2(a) muestra una ROI enmarcada en el rectángulo que la delimita, junto con su expansión en (b).
- b) *Identificación de la vegetación*, el índice de vegetación *ExG* (Woebbecke et al., 1995) se eligió por su rendimiento. En este sentido se consideró el trabajo llevado a cabo con diferentes índices en Guijarro et al. (2011) donde se combinan varios índices, sin aparentes mejoras con respecto a la utilización de *ExG*. La Fig. 3.4(a) muestra la imagen resultante después de aplicar *ExG* sobre la ROI (Fig. 3.2b).
- c) *Doble umbralización*, basada en el método de Otsu (Otsu, 1979), donde la primera umbralización discrimina vegetación/suelo, y la segunda, cultivo/malas hierbas. La Fig. 3.2(b) muestra las malas hierbas y el cultivo en la ROI y la Fig. 3.4(b) la imagen binaria resultante de la umbralización y una vez que las malas hierbas ya han sido identificadas. Sin embargo, algunas malas hierbas pueden todavía permanecer debido a la alta similitud que el cultivo en lo que a la firma espectral se refiere.
- d) *Operaciones morfológicas*, se aplicó una operación de apertura (*opening*) (Onyango & Marchant, 2003) seguida de un filtrado basado en la eliminación de píxeles aislados aplicando un criterio que tiene en cuenta la mayoría de valores binarios sobre una vecindad de tamaño 3×3 píxeles, de suerte que si el píxel central difiere en más de cinco de los de la vecindad, a aquel se le asigna el valor mayoritario de los vecinos. El objetivo final es eliminar rodales pequeños y píxeles espurios sobre la imagen binaria; la Fig. 3.4(c) muestra la imagen resultante. Para la apertura, fue suficiente la utilización de un elemento estructural en forma de diamante con una distancia de 2 píxeles desde el origen a los puntos extremos.

3.2.2.2 Identificación de puntos de inicio

Dada una ROI, el problema que se plantea es determinar dónde comenzar la búsqueda de las líneas de cultivo, esto es la identificación de los puntos de inicio. Con tal propósito, se han aplicado tanto el concepto de ROI como la TH para determinar

puntos significantes en la base de la ROI, Fig. 3.5, los cuales, como se ha indicado, determinan los puntos de inicio para las líneas de cultivo. La TH se seleccionó debido a que se trata de una técnica robusta y con buenos comportamientos en presencia de ruido o cuando existen partes ocultas o incompletas de los objetos (Cuevas et al., 2010).



(a)



(b)



(c)

Fig. 3.4 (a) imagen en escala de grises después de aplicar *ExG* a la ROI; (b) imagen binaria después de aplicar la doble umbralización basada en Otsu; (c) imagen binaria después de aplicar las operaciones morfológicas (apertura y filtro de mayoría)

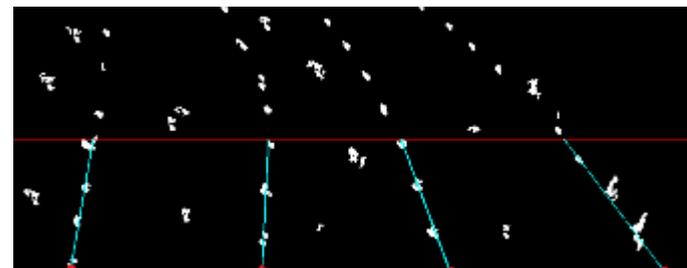


Fig. 3.5 Localización de los puntos de inicio en la franja inferior de la ROI (hasta la mitad: línea horizontal). Cada punto de inicio se compone de un punto de cruce (círculo rojo) en la base de la ROI y la pendiente de la recta (inclinada)

Dada la imagen binaria, obtenida, según se describe en la fase previa (Fig. 3.4c), conteniendo los píxeles blancos que pertenecen al cultivo y ciertas malas hierbas (que no fueron discriminadas por la similitud de su firma espectral con respecto al cultivo). El proceso de identificación de los cuatro puntos de inicio para buscar las líneas de cultivo es como sigue:

- a) La ROI se divide en dos franjas horizontales o sub-ROIs de igual tamaño (superior e inferior), Fig. 3.5. La idea que subyace es que las líneas curvas y rectas en la franja inferior puedan ser aproximadas por segmentos lineales.
- b) La TH se aplica en la franja inferior para identificar alineaciones de píxeles blancos en la imagen binaria que representan los cuatro segmentos lineales. Se utiliza la representación polar (Gonzalez & Woods, 2010) ($\rho = x \cos \theta + y \sin \theta$), donde ρ es la distancia de la línea recta al origen y θ es el ángulo que forma la normal con el eje- x en representación cartesiana, con ejes de coordenadas x e y . Para convertir los parámetros de Hough (ρ , θ) al espacio de parámetros de la imagen con pendiente (m) e intercepto (b) en el espacio cartesiano, se aplican las siguientes ecuaciones de transformación:

$$m = -\frac{\cos \theta}{\sin \theta}, \quad b = \frac{\rho}{\sin \theta} \quad (3.1)$$

- c) Dado el número de líneas a identificar, en nuestro caso cuatro, cuatro son también los picos a identificar en el acumulador generado a partir del espacio polar de Hough, los cuales determinan cuatro parámetros m y b asociados con cuatro líneas rectas, verificando que cruzan los límites superior e inferior de la franja inferior (Fig. 3.5). Las cuatro líneas deben contener diferencias en ρ superiores a 300 píxeles. Este valor fue obtenido considerando que la ROI tiene 2000 píxeles de ancho con 500 píxeles en promedio de separación entre líneas de cultivo. De esta forma se admite una desviación de 200 píxeles sobre los 500 citados, representando un margen de tolerancia cercano al 40% de la distancia en píxeles entre las líneas, el cual constituye un valor de referencia cuando un número diferente de líneas de cultivo debe ser identificado. En cualquier caso, en este contexto se aplica un conocimiento *a priori* para restringir el ángulo θ al rango $[-45^\circ, 45^\circ]$, esto se establece sobre la base de la configuración del sistema de visión sobre el tractor, las líneas de cultivo deben seguir una cierta orientación, que en ningún caso debe superar los límites establecidos, así por ejemplo una línea jamás podría derivarse hasta conseguir un ángulo de 90° . El

acumulador de la TH fue diseñado con resoluciones de 1 píxel y 1° respectivamente en coordenadas polares, que proporciona precisiones suficientes en las aplicaciones agrícolas. Los puntos de intersección entre las líneas rectas detectadas con el borde inferior en la sub-ROI determinan los cuatro puntos de inicio localizados en la base de la sub-ROI en coordenadas (x, y) de la imagen. La Fig. 3.5 muestra los cuatro puntos de inicio y los cuatro segmentos lineales (*líneas de referencia*). La pendiente (m) de cada línea indica la dirección para explorar las plantas dentro de la franja inferior de la ROI. Sin embargo, una alta presencia de malas hierbas y discontinuidades en las líneas de cultivo pueden causar errores en la detección de los puntos de inicio. De esta manera, si el número de puntos de inicio detectados es menor que cuatro, la imagen se rechaza, procediéndose en este caso a la captura de una nueva imagen y su posterior procesamiento.

3.2.2.3 Detección de líneas de cultivo

Las líneas de cultivo rectas y curvas son detectadas según los siguientes pasos: (i) extracción de puntos candidatos a partir de las líneas de referencia (identificados con la TH); (ii) análisis de regresión para ajustar las ecuaciones polinómicas (rectas/cuadráticas); y (iii) selección y verificación final de las líneas de cultivo. En esta investigación, el problema de la extracción de puntos candidatos se propuso desde dos enfoques diferentes: (i) basado en la *acumulación de píxeles verdes*; cuyos resultados fueron presentados en García-Santillán et al. (2017a); (ii) basado en el concepto de *micro-ROIs*, planteado en García-Santillán et al. (2017b). Ambos enfoques constituyen la base fundamental de la investigación planteada en sendas referencias. A continuación se describen los dos enfoques mencionados.

A.1) Extracción de puntos candidatos basado en la acumulación de píxeles verdes

Tras la obtención de la imagen binaria, Fig. 3.4(c), se aplicó una operación morfológica de dilatación adicional para expandir las plantas segmentadas (cultivo y malas hierbas). Con tal propósito se utilizó una línea horizontal de 20 píxeles de longitud (parámetro $w = 20$) como elemento estructural. La dilatación puede llenar vacíos en la dirección horizontal y las plantas aparecen con mayor densidad en relación a la masa verde que representan. El tamaño de 20 píxeles supone una expansión de 35 mm en las plantas ubicadas en la base de la ROI (2000 píxeles en 3.4 m) de la escena

3D en el campo (no en la ROI proyectada), el cual es un valor adecuado para el conjunto de imágenes utilizadas en los experimentos. La Fig. 3.6(a) muestra el resultado obtenido después de aplicar la dilatación sobre la imagen de la Fig. 3.4(c). Dependiendo del estado de crecimiento de las plantas, este valor puede ser disminuido o aumentado cuando la densidad de las malas hierbas sea alta o baja, respectivamente. En cualquier caso, la magnitud de los conceptos alto y bajo debe establecerse en función de cada contexto agrícola en el momento de aplicación del método para extraer las líneas.

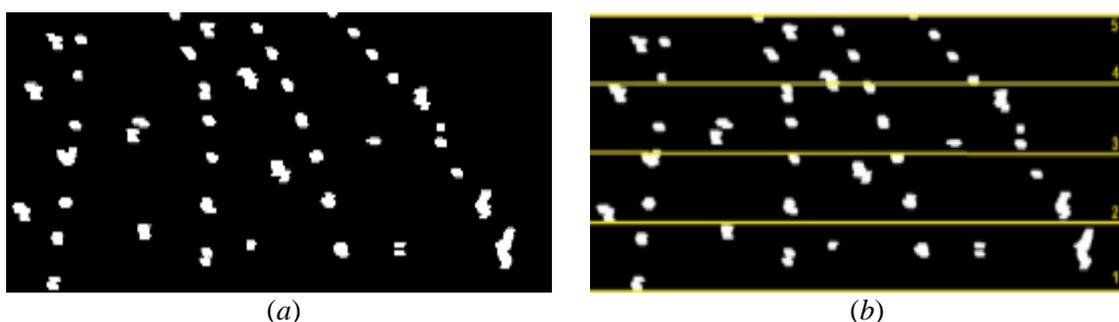


Fig. 3.6 (a) Imagen binaria después de aplicar la operación morfológica de dilatación a la Fig. 3.4a utilizando una línea horizontal de 20 píxeles como elemento estructurante. (b) La ROI es dividida en cuatro sub-franjas horizontales de igual tamaño. Estas sub-franjas producen cinco líneas horizontales (incluyendo los bordes superior e inferior de la ROI) etiquetadas del 1-5 desde abajo hacia arriba en la ROI

La ROI en la imagen dilatada se divide en cuatro sub-franjas horizontales de igual tamaño, obteniendo cinco líneas (incluyendo los bordes superior e inferior de la ROI). La Fig. 3.6(b) muestra las cinco líneas horizontales etiquetadas del 1 al 5 desde abajo hacia arriba en la ROI. Este número de líneas fue establecido después de un procedimiento de ensayo y error para el conjunto de imágenes utilizadas para la experimentación.

Las líneas de cultivo se extraen secuencialmente de izquierda a derecha (etiquetadas del 1 al 4). Para cada línea de cultivo, se obtiene un conjunto de cinco puntos distribuidos a lo largo de las alineaciones potenciales, que no son otras que las propias líneas de cultivo. Estos puntos están ubicados sobre las líneas horizontales etiquetadas del 1 al 5. Los puntos 1 al 3, dentro de la franja inferior de la ROI (Fig. 3.7), se obtienen calculando las intersecciones entre las líneas rectas de referencia (Fig. 3.5) y las líneas horizontales (etiquetadas del 1 al 3) que dividen la ROI (Fig. 3.6b).

Los dos puntos restantes en la franja superior de la ROI se obtienen como sigue a continuación:

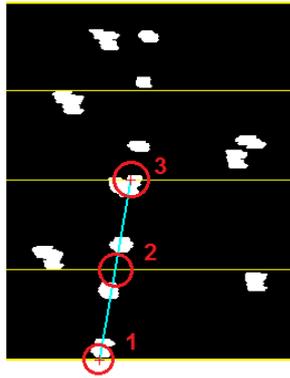


Fig. 3.7 Parte de la ROI mostrando la primera línea de cultivo. Los puntos 1-3 se obtienen calculando la intersección entre la línea de referencia (inclinada) y las líneas horizontales (etiquetadas del 1-3) respectivamente

- 1) El punto *B* localizado en el borde superior de la ROI (línea horizontal número 5) se obtiene extendiendo la línea de referencia (puntos 1, 2 y 3), Fig. 3.8.

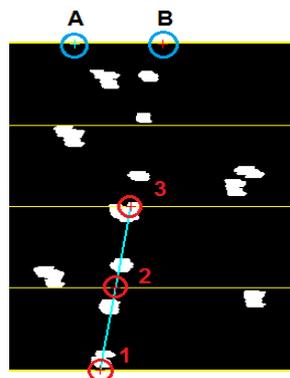


Fig. 3.8 Parte de la ROI mostrando la primera línea de cultivo. El punto *B* ubicado en el borde superior de la ROI (línea horizontal #5) se obtiene extendiendo la línea de referencia (puntos 1, 2 y 3). El punto *A* se obtiene desplazando *B* hacia la izquierda de la imagen, un número de píxeles (200 píxeles), a lo largo de eje-*x*. Los cuatro puntos *A*, 3, 2 and *I* son utilizados para el ajuste de una parábola por mínimos cuadrados

- 2) El punto *A*, también ubicado en la línea número 5, Fig. 3.8, se obtiene desplazando el punto *B* hacia la izquierda de la imagen, un cierto número de píxeles, a lo largo del eje-*x* horizontal. En este caso, el valor fue establecido en 200 píxeles por experimentación y corresponde, en promedio, a 0.67 m en la escena 3D (campo de maíz), que representa el 80% del espacio entre líneas de cultivo (0.85 m).
- 3) Desde el punto *A* hasta *B* hacer (ciclo externo):
 - a) Se ajusta una parábola por mínimos cuadrados utilizando los cuatro puntos: *A*, 3, 2, *I* (Figs. 3.8 y 3.9).

- b) El punto C sobre la línea horizontal número 4 se obtiene por la intersección entre la parábola ajustada previamente y la línea número 4, Fig. 3.9.
- c) El punto D ubicado en la línea número 4 se obtiene añadiendo un umbral a la coordenada- x del punto C (Fig. 3.9). Este valor fue asignado tomando como referencia la tercera parte del desplazamiento entre B y A , es decir, 66 píxeles que corresponde, en promedio, a 0.16 m en la escena 3D del campo de maíz en esta parte de la ROI.

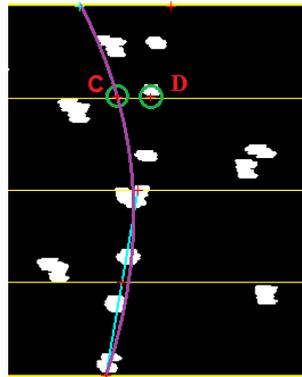


Fig. 3.9 Parte de la ROI mostrando la primera línea de cultivo. El punto C se obtiene por la intersección entre la parábola (ajustada por mínimos cuadrados usando los puntos A , 3 , 2 , 1) y la línea horizontal #4. El punto D ubicado en la línea horizontal line #4 se obtiene por añadir un umbral (66 píxeles) a la coordenada- x del punto C

Desde el punto C hasta D hacer (ciclo interno):

- d) Se ajusta una parábola (segmento dibujado en la franja superior de la ROI, Fig. 3.10a) por mínimos cuadrados utilizando cinco puntos: A , C , 3 , 2 , 1 . Se obtiene el número de píxeles blancos a lo largo del segmento curvado $\overline{AC3}$ y se almacenan los puntos A y C .

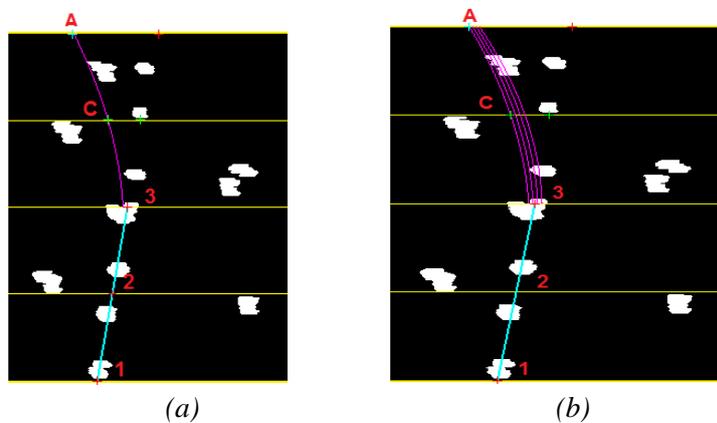


Fig. 3.10 Parte de la ROI mostrando la primera línea de cultivo. (a) Una parábola (dibujada en la franja superior de la ROI) ajustada por mínimos cuadrados utilizando cinco puntos: A , C , 3 , 2 , 1 . (b) Cuatro parábolas ajustadas. El punto C incrementa en cada iteración

- e) Se incrementa la coordenada- x del punto C en un valor de 20 píxeles. Este umbral coincide con la longitud del elemento estructural horizontal (parámetro w) utilizado durante la operación de dilatación en el proceso que se refleja como ejemplo en la Fig. 3.6(a).
- f) Se repiten los pasos (d) y (e) hasta que el ciclo interno finaliza. Este bucle se ejecuta cuatro veces como consecuencia del número de líneas a utilizar, produciendo cuatro parábolas como se muestra en la Fig. 10(b), las cuales se estiman utilizando los cinco puntos (A , C , 3, 2, 1). Las parábolas aproximadas no tienen por qué pasar exactamente por dichos puntos.
- g) Se incrementa la coordenada- x del punto A por un umbral de 20 píxeles como en el caso anterior, relacionado con el parámetro w .
- h) Se repiten los pasos de (a) a (g) hasta que el ciclo externo finaliza. Este bucle se ejecuta 10 veces, identificándose los puntos A y C (dos cuadrados en la Fig. 3.11a) en la franja superior de la ROI (líneas números 5 y 4 respectivamente), donde el segmento curvo $\overline{AC3}$ se identifica por la máxima acumulación de píxeles blancos. Durante la fase de experimentación se determinó que un número de 50 píxeles blancos resulta ser la cantidad mínima a ser considerada como un segmento válido que pertenece a una línea de cultivo. De lo contrario, el segmento se supone que procede de una discontinuidad grande y la imagen se rechaza en consecuencia, entonces se procede a la captura de una nueva imagen y su correspondiente procesamiento. Con este proceso se identifica un conjunto de cinco puntos significativos (etiquetados del 1-5 en la Fig. 3.11b) distribuidos a lo largo de la línea de cultivo, que son almacenados para su uso posterior.

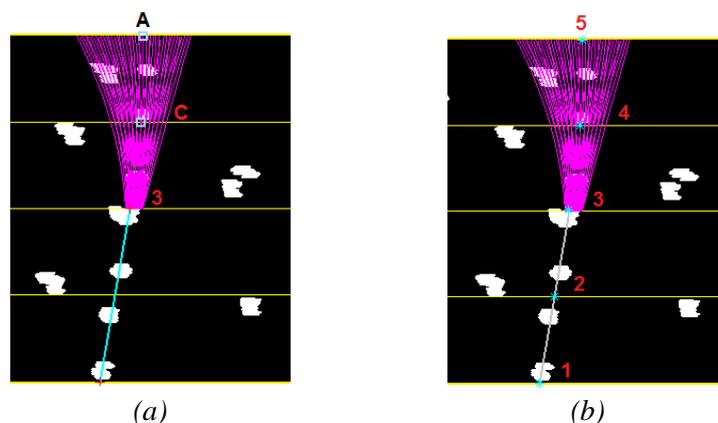


Fig. 3.11 Parte de la ROI mostrando la primera línea de cultivo. (a) Dos puntos A y C (cuadrados) identificados en la franja superior de la ROI. (b) Un conjunto de cinco puntos significativos (asteriscos etiquetados del 1-5) distribuidos a lo largo de la línea de cultivo

El procedimiento completo (pasos 1-3h) se repite para el resto de puntos de inicio disponibles, obteniéndose los resultados que se muestran en la Fig. 3.12. Los conjuntos de puntos obtenidos constituyen la entrada para el próximo proceso de ajuste de curvas utilizando mínimos cuadrados.

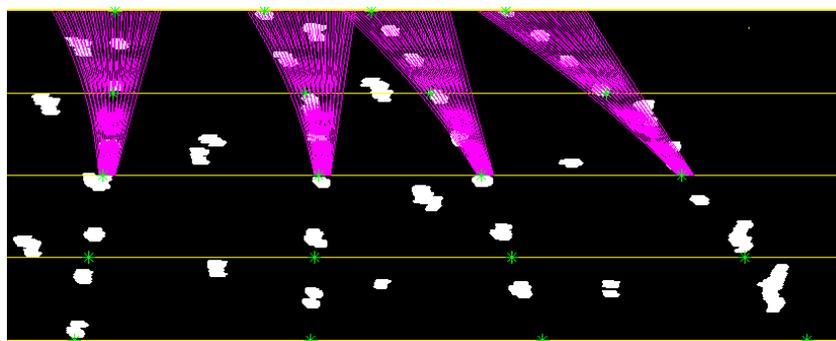


Fig. 3.12 Un conjunto de cinco puntos significativos (asteriscos verdes) distribuidos a lo largo de cada línea de cultivo dentro de la ROI

A.2) Extracción de puntos candidatos basado en micro-ROIs

Después de obtener una imagen binaria más limpia, Fig. 3.4(c), la ROI se divide en 12 subfranjas horizontales de igual longitud. Este número fue establecido tras diferentes pruebas de ensayo y error con el conjunto de imágenes utilizadas para la experimentación. La Fig. 3.13 muestra las líneas sólidas (rojo) que dividen horizontalmente la ROI. Así, las franjas inferior y superior de la ROI contienen cuatro y ocho subfranjas respectivamente. El número diferente de subfranjas fue establecido sobre la base de que las líneas curvadas aparecen más pronunciadas en la parte superior, lo que permite capturar esta variabilidad (curvatura) con suficiente garantía. La línea punteada (amarillo) indica la línea central de la ROI. El hecho de que la curvatura aparezca más pronunciada en la parte superior se debe a la resolución de la imagen bajo proyección de perspectiva, dado que cuanto más alejadas del sistema de visión se sitúan las zonas en la escena 3D, menor número de píxeles se necesita para representar la misma longitud de línea que cuando la zona se sitúa más próxima al sistema de visión.

Las líneas de cultivo se extraen secuencialmente de izquierda a derecha (etiquetadas del 1-4). Cada alineación se detecta explorando las subfranjas verticalmente, basándose en el concepto de micro-ROIs, comenzando desde el punto de inicio asociado (Fig. 3.5) y con la pendiente de la línea recta estimada, que se utiliza como guía (dirección).

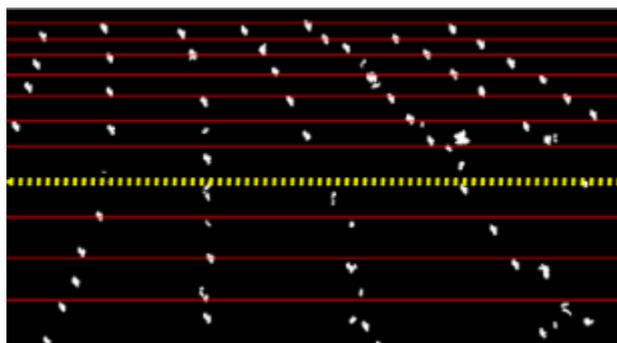


Fig. 3.13 División de la ROI en dos franjas horizontales de igual longitud (por la línea punteada amarilla): superior e inferior. La franja inferior se divide en cuatro sub-franjas (líneas sólidas rojas) y la franja superior en ocho sub-franjas.

Una micro-ROI determina una pequeña región rectangular (ventana). La altura de cada micro-ROI es la misma que la de la sub-franja correspondiente, mientras que el ancho varía en cada sub-franja, siendo inicialmente fijado a 150 píxeles, disminuyendo gradualmente a razón del 5% a medida que se asciende por las sub-franjas. El valor inicial se determinó suponiendo que 150 píxeles corresponden a 0.28 m en el campo de maíz con 0.85 m de espaciado entre las líneas de cultivo. El tamaño y la reducción progresiva garantizan que las diferentes líneas de cultivo sean totalmente cubiertas, dada la disminución de la resolución en píxeles como consecuencia de la proyección de perspectiva. El objetivo de cada micro-ROI consiste en englobar el máximo número de plantas de cultivo (maíz), dejando mayoritariamente fuera de la micro-ROI las malas hierbas que son localizadas en el espaciado entre las líneas. Así, cada micro-ROI se definió mediante cuatro parámetros [x , y , $width$, $height$], donde el punto (x , y) representa la esquina superior izquierda. Los parámetros y , $width$, $height$ son conocidos *a priori*, mientras que x es desconocido y se obtiene dinámicamente para cada sub-franja. El procedimiento para la estimación de x es como sigue:

- 1) Se ubica la primera micro-ROI con su base centrada en el primer punto de inicio (Fig. 3.14a y b, cruz roja) y se calcula el centro geométrico (\bar{x} , \bar{y}) de la micro-ROI como se indica (Pajares & de la Cruz, 2008):

$$x_c = \frac{1}{A} \sum_i x_i; \quad y_c = \frac{1}{A} \sum_i y_i \quad (3.2)$$

donde x_i y y_i representan los píxeles blancos que pertenecen a las plantas segmentadas dentro de la micro-ROI; A es el número de píxeles blancos. Esta expresión minimiza los efectos de los píxeles aislados (malas hierbas), Fig. 3.15(a). El centroide así obtenido es $P_n(x_c, y_c)$ (cruz verde).

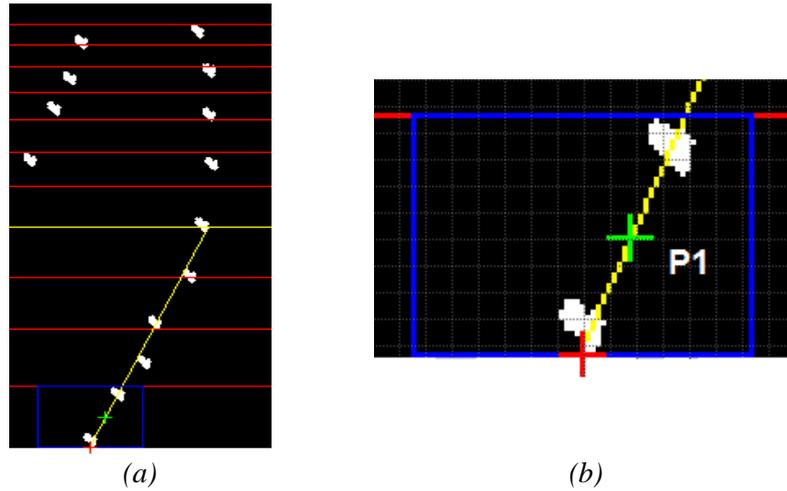


Fig. 3.14 Ubicación de las micro-ROIs (rectángulo azul) a lo largo de la primera línea de cultivo. (a) Primera micro-ROI ubicada en la primera subfranja; (b) micro-ROI aumentada, donde la cruz roja es el centro inferior de la micro-ROI y la cruz verde es el punto P_1 (centroide) calculado y almacenado.

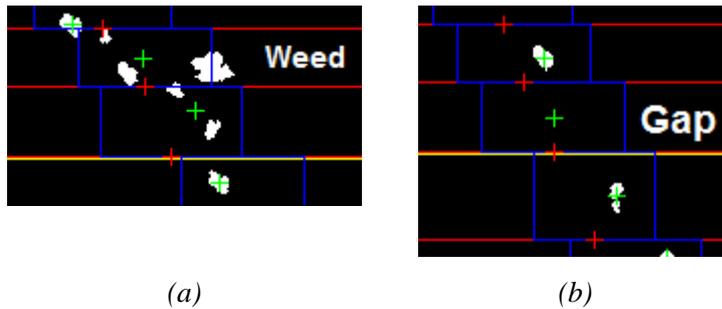


Fig. 3.15 Ejemplos de casos especiales. (a) Presencia de malas hierbas dentro de la micro-ROI; (b) Ausencia de objetos etiquetados (discontinuidad) dentro de la micro-ROI. Por lo tanto, la cruz verde es el centroide de la micro-ROI.

- 2) Si la micro-ROI no contiene píxeles blancos, se asume que se trata de una discontinuidad (vacío) y el punto $P_n(x_c, y_c)$ resulta ser exactamente el centroide de la micro-ROI como se muestra en la Fig. 3.15(b). En el método planteado se permiten tres vacíos consecutivos en la misma línea de cultivo como máximo, es decir, aproximadamente 1.20 m de discontinuidad consecutiva considerando las dimensiones correspondientes de la ROI en el campo. Un número mayor de vacíos consecutivos, que suponen longitudes superiores a los 1.20 m son firmes candidatos a generar un fallo en la detección, principalmente en las líneas con curvatura.
- 3) Siguiendo la línea de referencia estimada con la TH, asociada a la primera micro-ROI, se colocan tres micro-ROIs adicionales con sus bases centradas en los puntos de intersección entre la línea de referencia (TH) y los bordes inferiores de las subfranjias, Fig. 3.16(a) y (b).

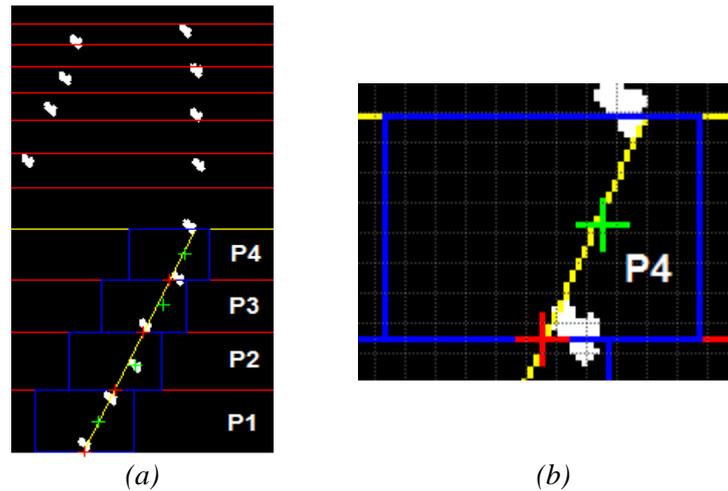


Fig. 3.16 Ubicación de las micro-ROIs (rectángulos azules) a lo largo de la primera línea de cultivo. (a) Cuarta micro-ROI colocada en la cuarta subfranja; (b) micro-ROI aumentada, donde la cruz roja está en el centro inferior de la micro-ROI y la cruz verde es el punto P_4 (centroide) calculado y almacenado.

- 4) El proceso esbozado en los pasos 1 a 3 se repite para el resto de puntos de inicio, obteniendo cuatro alineaciones de micro-ROIs en la franja inferior de la ROI con los correspondientes centroides (P_n) con $n = 1, \dots, 4$, cada alineación es asociada con una línea de cultivo candidata a ser detectada.

La franja superior en la ROI, que contiene ocho sub-franjas, se explora colocando ocho micro-ROIs en cada línea de cultivo esperada. Cada micro-ROI se coloca centrada sobre el punto de intersección entre el borde inferior de la correspondiente sub-franja y la línea recta estimada con los cuatro centroides previamente calculados, es decir, con los puntos basados en el historial que definen la tendencia de las líneas de cultivo. La línea recta se ajusta por mínimos cuadrados con los últimos cuatro centroides.

- 5) La quinta micro-ROI se coloca, Fig. 3.17(a), considerando los últimos cuatro centroides (P_1, P_2, P_3, P_4), a partir de los cuales se obtiene la correspondiente pendiente $m_{1,2,3,4}$. El punto de intersección (cruz roja en la Fig. 3.17b) en la siguiente sub-franja se obtiene utilizando el último centroide P_4 y la pendiente $m_{1,2,3,4}$.
- 6) El centroide P_5 (cruz verde) se calcula dentro de esta micro-ROI utilizando la Ec. (3.2).

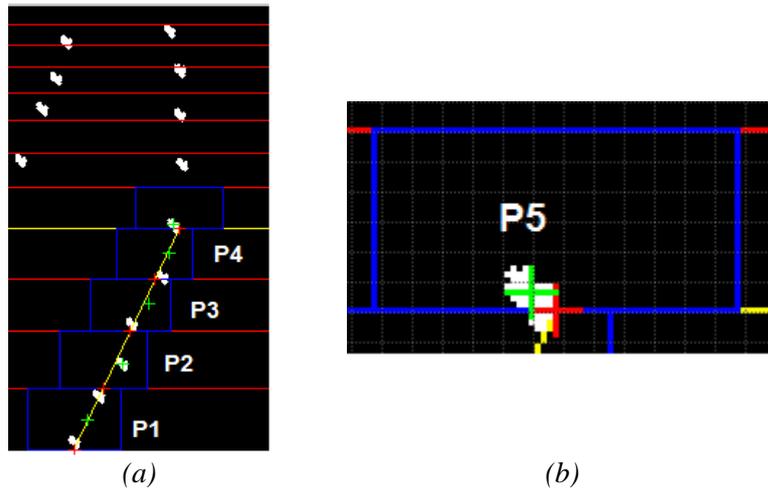


Fig. 3.17 Ubicación de las micro-ROIs (rectángulos azules) a lo largo de la primera línea de cultivo. (a) Quinta micro-ROI colocada en la quinta subfranja; (b) micro-ROI aumentada, donde la cruz roja está en el centro inferior de la micro-ROI y la cruz verde es el punto P_5 (centroide) calculado y almacenado.

7) Los pasos 5 y 6 se aplican para el resto de micro-ROIs dentro de la franja superior de la ROI para las ocho sub-franjas asociadas a cada línea de cultivo esperada, Fig. 3.18(a). Por ejemplo, si se considera el centroide P_{12} , la línea se ajustada considerando los cuatro centroides previos (P_8, P_9, P_{10}, P_{11}) con la pendiente $m_{8,9,10,11}$. Así, el punto de intersección (cruz roja en la Fig. 3.18b) en la siguiente sub-franja se obtiene utilizando el centroide anterior P_{11} con la pendiente $m_{8,9,10,11}$. El centroide P_{12} (cruz verde) se obtiene finalmente mediante el mismo procedimiento descrito previamente.

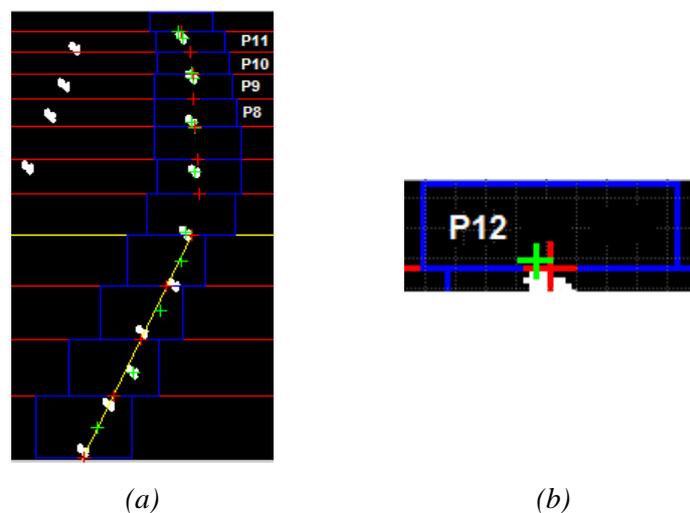


Fig. 3.18 Ubicación de las micro-ROIs (rectángulos azules) a lo largo de la primera línea de cultivo. (a) Doceava micro-ROI colocada en la doceava subfranja; (b) micro-ROI aumentada, donde la cruz roja está en el centro inferior de la micro-ROI y la cruz verde es el punto P_{12} (centroide) calculado y almacenado

- 8) Una vez que las doce sub-franjas son procesadas, se obtiene un conjunto de 12 puntos distribuidos a lo largo de la primera línea de cultivo, objeto de detección.

El procedimiento completo (pasos del 1-8) se repite para el resto de puntos de inicio disponibles. La Fig. 3.19 muestra el resultado de este proceso sobre las cuatro líneas. Los conjuntos de puntos así obtenidos constituyen la entrada para el próximo proceso de ajuste de curvas por mínimos cuadrados.

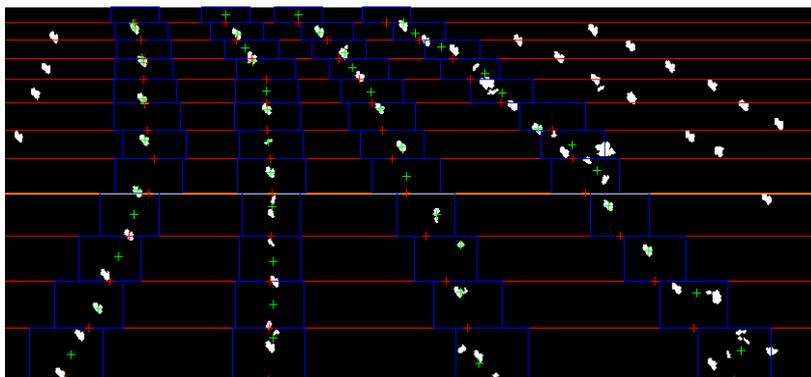


Fig. 3.19 Ubicación de las micro-ROIs (rectángulos azules) a lo largo de todas las líneas de cultivo que cruzan los bordes superior e inferior de la ROI.

B) Análisis de regresión

Una vez obtenido el conjunto de puntos significativos, a lo largo de cada línea de cultivo (asteriscos en la Figs. 3.12 y cruces verdes en la Fig. 3.19) según el proceso anterior, se ajustan los polinomios de grado uno (línea recta) y dos (curva cuadrática) utilizando la técnica de mínimos cuadrados. La parábola definida por estos puntos significativos se ajusta a las líneas de cultivo en las imágenes probadas. Para el enfoque basado en la *acumulación de píxeles verdes* (Fig. 3.12), se determinó que cinco puntos resultan suficientes para definir una curva que se ajusta adecuadamente a la curvatura de las líneas de cultivo, mientras que para el enfoque basado en *micro-ROIs* (Fig. 3.19), doce puntos resultaron ser los considerados como convenientes. Para las líneas rectas, los coeficientes a estimar son la pendiente (m) y el intercepto (b); para el polinomio cuadrático, los coeficientes a estimar en este caso son a , b y c , Ec. 3.3.

$$y = mx + b; \quad y = ax^2 + bx + c \quad (3.3)$$

Las Figs. 3.20(a) y (b) muestran las gráficas de los dos polinomios ajustados (recta y cuadrática) a cada línea de cultivo dentro de la ROI, en este ejemplo utilizando el método de acumulación de píxeles verdes descrito anteriormente. En (a) los polinomios son dibujados sobre la imagen binaria y en (b) en la imagen a color.

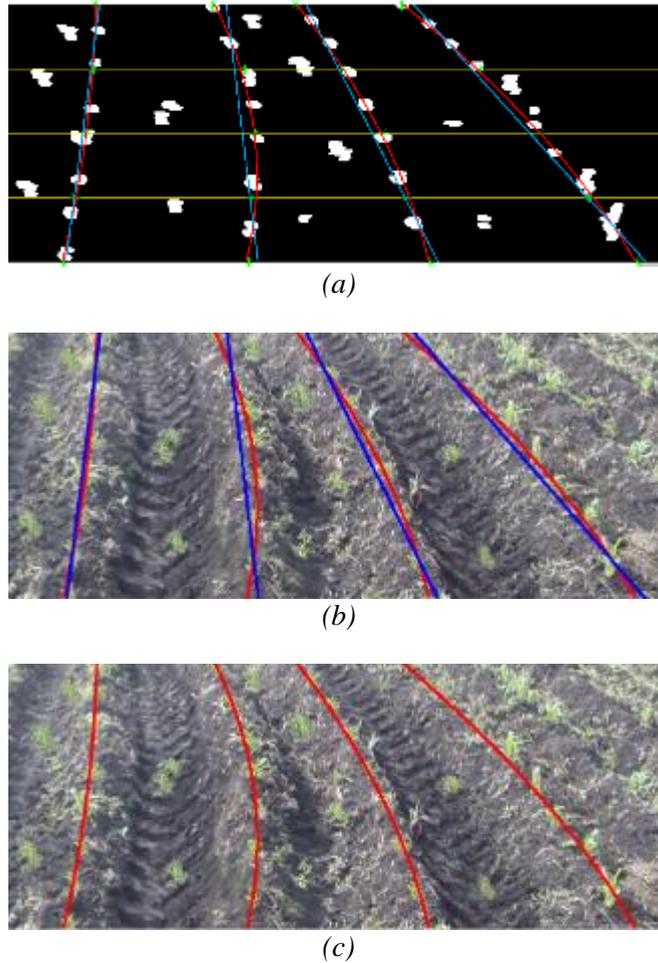


Fig. 3.20 Gráficas de los dos polinomios ajustados (recta y cuadrática) a cada línea de cultivo dentro de la ROI. (a) Polinomios dibujados sobre la imagen binaria; (b) polinomios trazados en la imagen a color; (c) líneas de cultivo detectadas que se ajustan mejor en la ROI

Mínimos cuadrados es una técnica de ajuste de líneas para obtener una solución de un sistema de ecuaciones sobre-determinado, es decir, conteniendo un número mayor de ecuaciones que de incógnitas. El método encuentra la solución minimizando la suma de los errores cuadráticos entre el modelo y los datos. La Ec. (3.4) define el esquema de minimización (De la Fuente & Trespaderne, 2012):

$$\min_Q \sum_{i=1}^h \varepsilon_i^2(Q, Z) \tag{3.4}$$

donde Q es el vector de parámetros a estimar, como se definen en la Ec. (3.3) para líneas rectas y polinomios cuadráticos, Z es un vector construido a partir de los datos medidos, es decir, los centroides para el enfoque de micro-ROIs (Fig. 3.19) o puntos significativos para la técnica de acumulación de píxeles verdes (Fig. 3.12), y $\varepsilon_i(Q, Z)$,

$i = 1, \dots, h$ un conjunto de h ecuaciones que modelan los errores cometidos cuando se utiliza el vector de parámetros Q como una solución.

La técnica de mínimos cuadrados también proporciona la norma de residuos, la cual es una medida de la calidad del ajuste. La norma de residuos, Ec. 3.5, se define como la diferencia entre los valores experimentales y los predichos por el modelo.

$$R = \sqrt{\sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (3.5)$$

donde n es el número de puntos, x los valores experimentales y \hat{x} los predichos por el modelo. Cuanto menor es R , mejor es el ajuste.

C) Selección y verificación final de las líneas de cultivo

Este proceso se realiza en dos pasos: (i) la selección de las líneas de cultivo y (ii) la verificación de las líneas seleccionadas. En el primer paso, se selecciona el polinomio (recta o cuadrática) que mejor se ajusta a cada línea de cultivo, según el valor mínimo de la norma de residuos (R). La Fig. 3.20(c) muestra las cuatro líneas de cultivo seleccionadas a partir de la Fig. 3.20(a).

En el segundo paso, se realiza una validación de los polinomios seleccionados. En este sentido son dos los casos a verificar: (i) la separación entre las líneas de cultivo, y (ii) la orientación de dichas líneas. En el primer caso, se determina que dos líneas consecutivas deben mantener una distancia conocida de separación en la parte inferior de la ROI. Una distancia mayor expresa alguna anomalía. Tal vez debido a que las semillas sembradas en los surcos no germinaron completamente. La Fig. 3.21(a) muestra la distancia entre dos líneas de cultivo en la parte inferior de la ROI. La regla de verificación se expresa como sigue: si la distancia es mayor que un umbral, la imagen se rechaza, de lo contrario se acepta. En este estudio, el umbral se estableció por experimentación en 600 píxeles.

En el segundo caso, dos líneas detectadas no deberían intersectarse dentro de la ROI o cuando se extienden por prolongación fuera de la parte inferior de la ROI. La Fig. 3.21(b) muestra dos líneas intersectándose en un punto dentro de la ROI. Esta situación aparece debido a la alta densidad de malas hierbas. El punto de intersección (X_{cross}, Y_{cross}) se obtiene igualando las ecuaciones de ambas líneas rectas y resolviendo el sistema de ecuaciones resultante en este caso. La regla de verificación se establece

como sigue: si la coordenada-y (Y_{cross}) es menor o igual a cero, la imagen se acepta, de lo contrario se rechaza.

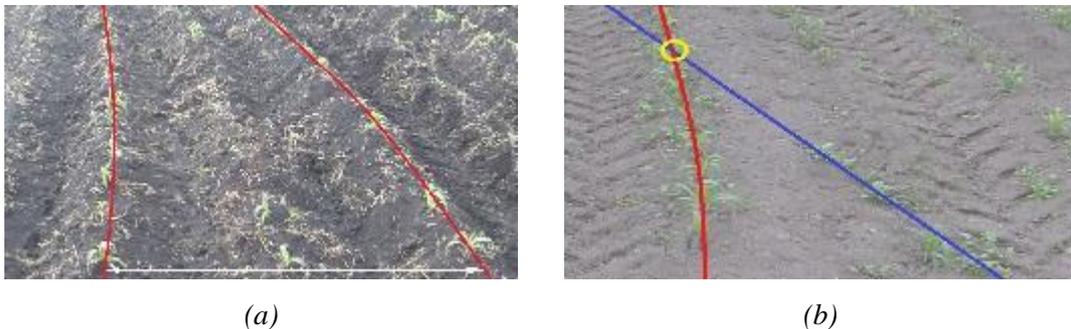


Fig. 3.21 Proceso de verificación para las líneas de cultivo detectadas; (a) las líneas están demasiado separadas debido a discontinuidades grandes; (b) las líneas se intersectan dentro de la ROI por el alto nivel de malas hierbas. En ambos casos, la imagen se rechaza.

En general, si se presenta alguna de las anomalías descritas, la imagen se rechaza, de lo contrario se acepta. Como resultado final, los dos métodos propuestos detectan cuatro líneas de cultivo rectas y curvas, las cuales se modelan matemáticamente. Como se indicó previamente, este número es suficiente para el guiado automático de tractores y es también conveniente para destruir las malas hierbas que están localizadas en los espacios inter-líneas, siguiendo las ideas del proyecto RHEA (2014). En cualquier caso, la adaptación de los procedimientos para detectar un número mayor de líneas es trivial con la única incorporación de este número en los procesos que lo requieren.

D) Curvatura de las líneas de cultivo

Respecto a la concavidad (izquierda/derecha) de las líneas de cultivo, los métodos fueron diseñados para líneas con la concavidad orientada hacia la izquierda, Fig. 3.20 (c). Esto es útil cuando el tractor se mueve hacia adelante y la concavidad de las líneas se orienta hacia la izquierda. Sin embargo, cuando el tractor llega al final de la parcela y comienza su regreso, la concavidad de las líneas será orientada hacia la derecha. En este caso, los métodos trabajan como sigue:

- a. Se aplica un proceso de reflexión especular vertical a la ROI con las líneas orientadas hacia la derecha (Fig. 3.22a), obteniendo una nueva ROI con la curvatura orientada hacia la izquierda (Fig. 3.22b). Es decir, la última columna de la ROI se convierte en la primera, la penúltima columna en la segunda, la antepenúltima columna en la tercera y así sucesivamente.

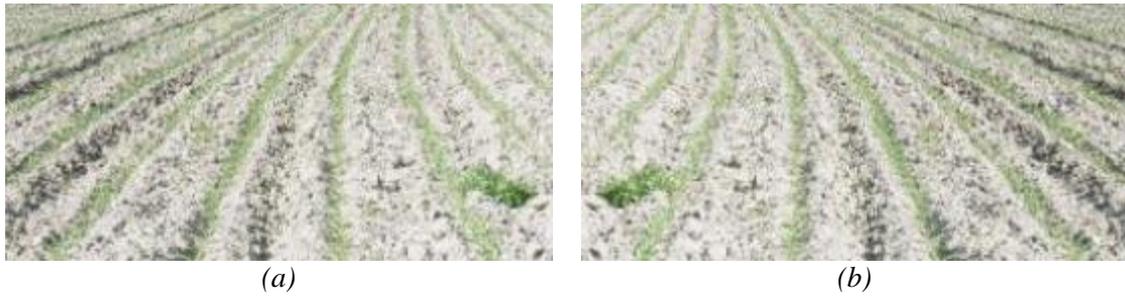


Fig. 3.22 (a) Ejemplo de ROI con filas de cultivo orientadas hacia la derecha; (b) reflexión especular vertical con líneas orientadas hacia la izquierda

- b. Se detectan las líneas de cultivo orientadas hacia la izquierda utilizando cualquiera de los dos métodos expuestos previamente, obteniendo cinco (Fig. 3.12) o doce puntos (Fig. 3.19) para cada línea de cultivo, según el método elegido.
- c. Se aplica una operación de traslación horizontal a cada punto sobre las líneas de cultivo utilizando la Ec. 3.6, obteniendo cinco/doce nuevos puntos para cada línea.

$$P(i, j) \xrightarrow[\text{traslación}]{} \hat{P}(i, \text{columns} - j + 1) \quad (3.6)$$

donde el valor *columns* representa el número de columnas de la ROI (*columns*=2000).

- d. Una curva recta o cuadrática se ajusta por mínimos cuadrados (Ec. 3.4) utilizando los nuevos puntos trasladados (\hat{P}) para cada línea de cultivo. Las curvas resultantes tienen la orientación hacia la derecha como se esperaba.

3.2.3 Densidad de las malas hierbas

Respecto a los niveles de infestación, los métodos propuestos fueron diseñados para un bajo nivel de cobertura de malas hierbas, según la escala de clasificación propuesta por Maltsev (1962, p. 272). El porcentaje de cobertura de maleza se obtuvo aplicando el método del cuadrante como sigue:

$$\% \text{ cobertura de malas hierbas} = \frac{A}{B} * 100 \quad (3.7)$$

donde *A* representa el área cubierta por las malas hierbas y *B* es el área muestreada, es decir, $0.5\text{m} \times 0.5\text{m} = 0.25 \text{ m}^2$.

3.2.4 Batería de imágenes (ground truth)

El rendimiento de los métodos propuestos, en términos de precisión, fue comparado frente a un conjunto de imágenes que constituyen lo que se conoce como *ground truth*, las cuales fueron creadas manualmente como sigue. Un experto, basado

en la observación visual seleccionó manualmente, al menos, cinco puntos situados sobre la línea de cultivo en la correspondiente imagen de prueba. Las coordenadas de estos puntos son relativas a la esquina superior izquierda de la imagen. La selección se realizó considerando que cada punto debe estar tan cerca, como sea posible, al lugar donde el tallo de la planta emerge del suelo. El mismo procedimiento manual se realizó para las cuatro líneas de cultivo que atraviesan los bordes superior e inferior de la ROI. El ajuste se realizó mediante una aplicación desarrollada en Matlab, utilizando la *toolbox* específica para ajuste de curvas (*curve fitting toolbox*), de esta forma se realizó el ajuste automático de una curva cuadrática pasando por estos puntos. Los puntos seleccionados para la estimación de las líneas de cultivo deben estar suficientemente espaciados, tratando de cubrir toda la línea que se está tratando de ajustar, para asegurar el mínimo error. A veces, las hojas de las plantas obstruyen el punto ideal a seleccionar de forma manual, especialmente cuando la altura de la planta es relativamente significativa. En tales casos, el experto sitúa el punto, con la máxima precisión posible, observando la proyección desde la escena 3D a la imagen 2D y la alineación de píxeles en la línea de cultivo.

En total se seleccionaron aleatoriamente 920 imágenes para la creación del *ground truth* y por tanto las pruebas, conteniendo plantas con diferentes etapas de crecimiento (bajo, medio y alta cobertura de plantas, hasta 40 días). Las imágenes de prueba se clasificaron en tres conjuntos: Set-1 con 120 imágenes conteniendo solo líneas rectas de cultivo, Set-2 con 300 imágenes con líneas igualmente espaciadas y Set-3 con 500 imágenes con líneas irregularmente espaciadas. La Fig. 3.23 muestra ejemplos ilustrativos de la batería de imágenes para cada conjunto de imágenes de prueba: Set-1 (a)-(c); Set-2 (d)-(f); y Set-3 (g)-(j).

3.3 Resultados y discusión

Para la evaluación de resultados se consideraron imágenes con diferentes niveles de infestación de malas hierbas y discontinuidades en las líneas de cultivo en los conjuntos de imágenes (Sets 1-3). En el primer caso, respecto a la densidad de malas hierbas, los métodos propuestos fueron probados con un nivel bajo de cobertura, es decir, hasta el 5% de acuerdo a la escala de clasificación propuesta por Maltsev (1962, p.272).

Un nivel mayor de malas hierbas (> 5%) podría causar una detección incorrecta de las líneas de cultivo o desviaciones con respecto a los surcos esperados. Como se

mencionó previamente, cuando una detección es incorrecta, la imagen se rechaza, como ocurre en el caso de la imagen mostrada en la Fig. 3.21 (b). El nivel de infestación de malas hierbas bajo, medio y alto significa menos del 5%, entre el 5% y el 12%, y entre el 12% y 25%, respectivamente. Densidades de malas hierbas superiores al 25% conduce a fallos en la detección con porcentajes de error que alcanzan y en ocasiones superan el 50%. El valor del 5% establecido como límite inferior deriva de la escala de valoración propuesta Maltsev (1962, p. 272).-

La cobertura depende del grado de infestación y también del estado de crecimiento de las plantas, donde las hojas de las malas hierbas y el cultivo (maíz) invaden el espacio inter-líneas, a veces con superposición entre cultivo y malas hierbas. En promedio, una baja cobertura corresponde a los cultivos con alturas inferiores a 100 mm, una cobertura media entre 100 y 200 mm y alta entre 200 y 300 mm, correspondiendo en este último caso hasta 40 días de crecimiento. Alturas de cultivo superior a 300 mm pueden ser dañados cuando el tractor navega a través del campo con los implementos en la parte trasera (Gonzalez-de-Santos et al., 2016).

En el segundo caso, respecto de las discontinuidades de las líneas de cultivo se han estudiado diferentes niveles de discontinuidad, a saber: nivel bajo hasta 0.40 m de longitud, medio hasta 0.80 m y alto hasta 1.20 m. Discontinuidades con longitudes superiores a 1.20 m en la misma línea de cultivo no fueron consideradas, ya que el porcentaje de fallo en estos casos supera el 50% con la geometría del sistema de visión y las especificaciones utilizadas en el experimento, donde la ROI representó $3.4 \text{ m} \times 5 \text{ m}$ (ancho \times largo).

En ambos casos, discontinuidades y alta cobertura de malas hierbas afectan significativamente el rendimiento de los métodos propuestos en relación a las líneas de cultivo rectas y curvas, especialmente en las últimas.

Además, el radio mínimo de curvatura de las líneas de cultivo probadas en el campo experimental fue de 19 m. Este valor se obtuvo a través de mediciones topográficas. Valores más pequeños causa problemas en la navegación del tractor y aumenta el riesgo de dañar el cultivo.

3.3.1 Análisis comparativo y medidas de rendimiento

De aquí en adelante, los métodos propuestos para la detección de líneas de cultivo curvas y rectas se denotan con la nomenclatura y acrónimos utilizados en los trabajos originales, más concretamente por DAGP (*Detection by Accumulation of Green*

Pixels) para el procedimiento basado en la acumulación de píxeles verdes (García-Santillán, 2017a), y DBMR (*Detection Based on Micro-ROIs*) para el basado en micro-ROIs (García-Santillán, 2017b). Los rendimientos de los métodos se analizaron mediante un análisis de naturaleza estadística. Los procedimientos existentes en la literatura utilizados para la comparación fueron los siguientes: (i) Transformada de Hough estándar (TH) propuesto por Hough (1962), el cual, como se mencionó en el capítulo dos, ha sido ampliamente utilizado para la detección de líneas rectas de cultivo. Con tal propósito se aplicaron restricciones concretas para mejorar su rendimiento, tales como: número de líneas a detectar igual a cuatro, el ángulo de inclinación en el espacio transformado de Hough se restringió al rango -45° y 45° , la resolución y el ángulo de variación también en el espacio de Hough se fijaron a 1 pixel y 1° , respectivamente; (ii) regresión lineal basado en el estimador Theil-Shen (LTS) propuesto por Guerrero et al. (2013) para ajustar las líneas de cultivo; (iii) regresión lineal basado en mínimos cuadrados (LRQ) propuesto por Montalvo et al. (2012a), el cual utilizó plantillas para restringir las áreas de búsqueda de las líneas de cultivo donde se espera se sitúen dichas líneas; (iv) detección de líneas de cultivo (CRD) propuesto por Romeo et al. (2012), basado en orientación proporcionada por el punto de fuga, consecuencia de la proyección de perspectiva y la acumulación máxima de píxeles verdes segmentados a lo largo de alineaciones rectas; (v) correspondencia de plantillas seguida por minimización de una función de energía global (TMGEM), propuesta por Vidović et al. (2016), el cual detecta patrones regulares y utiliza métodos basados en programación dinámica para determinar un modelo óptimo que defina las líneas de cultivo. Los métodos TH, LTS, LRQ y CRD fueron diseñados para detectar exclusivamente líneas rectas de cultivo, mientras que TMGEM se diseñó para la detección de ambos tipos de líneas, es decir, curvas y rectas.

Una medida referida como CRDA (*Crop Row Detection Accuracy*), planteada en Vidović et al. (2016), se utilizó para evaluar el rendimiento de los métodos, la cual fue calculada mediante la coincidencia entre las coordenadas horizontales (x_i) de cada línea de cultivo obtenida por cada método bajo evaluación y los valores correspondientes del *ground truth* (\hat{x}_i) de acuerdo con la puntuación de coincidencia (*matching score*) definida por la Ec. (3.8).

$$matching_score(\hat{x}, x, s) = \max\left(1 - \left(\frac{\hat{x} - x}{0.1 * s}\right)^2, 0\right) \quad (3.8)$$

donde s es el espacio inter-líneas en píxeles para cada fila de la imagen.

A partir de la ecuación anterior, se calcula el promedio de las puntuaciones de coincidencia para todas las líneas de cultivo de la imagen, cuyo valor se circunscribe al rango [0, 1] y se obtiene por la Ec. (3.9). Valores cercanos a 1 determinan las mejores puntuaciones desde el punto de vista de efectividad de los métodos.

$$CRDA = \frac{1}{N * M} \sum_{i=1}^M \sum_{j=1}^N matching_score(\hat{x}_{i,j}, x_{i,j}, \hat{s}_i) \quad (3.9)$$

donde N es el número de líneas de cultivo a detectar ($N = 4$ en el caso que nos ocupa) y M es el número de filas de la imagen ($M = 650$ usado en los experimentos).

La medida CRDA se utilizó para la evaluación de líneas de cultivo rectas (Set-1) y curvas espaciadas regularmente (Set-2). Una ligera variante de CRDA se propuso en este estudio y se utilizó para la evaluación en líneas de cultivo curvas espaciadas irregularmente (Set-3). Esta nueva métrica se identifica como CRDA*, el cual utiliza $max(s)$ en lugar del valor s en la Ec. (3.8). Esta puntuación de coincidencia modificada puede también utilizarse para los otros sets de prueba (1-2). No obstante, esto implicaría una operación extra innecesaria (max), incrementando ligeramente el tiempo de procesamiento. En la secuencia de imágenes mostradas en la figura 3.23 se muestran diversos ejemplos con los correspondientes valores CRDA y CRDA*.

3.3.2 Evaluación de los métodos propuestos

El rendimiento de los métodos propuestos DAGP y DBMR para la detección de líneas de cultivo rectas y curvas fue evaluado mediante tres tipos de pruebas (Tests 1-3). CRDA se utilizó como la medida de rendimiento para los Tests 1 y 2, mientras que CRDA* se utilizó para el Test 3. En el Test 1, los métodos DAGP y DBMR se compararon frente a TH, LTS, LRQ y CRD sobre las imágenes del Set-1. En el Test 2, los métodos se compararon frente a TMGEM sobre el Set-2 y en el Test 3, fueron comparados frente a TMGEM en el Set-3. TH, CDR, DAGP y DBMR se implementaron en Matlab, mientras que LTS, LRQ y TMGEM en C++. Los métodos LTS y LRQ fueron implementados en un sistema de tiempo real en el marco del proyecto RHEA (2014), mientras que los otros procedimientos, incluyendo DAGP y DBMR, fueron procesados en una PC (*off-line*). A continuación, las pruebas (Tests 1-3) son detalladas.



(a) $CRDA_{(DBMR)} = 0.893$; $CRDA_{(DAGP)} = 0.908$



(b) $CRDA_{(DBMR)} = 0.908$; $CRDA_{(DAGP)} = 0.913$



(c) $CRDA_{(DBMR)} = 0.929$; $CRDA_{(DAGP)} = 0.934$



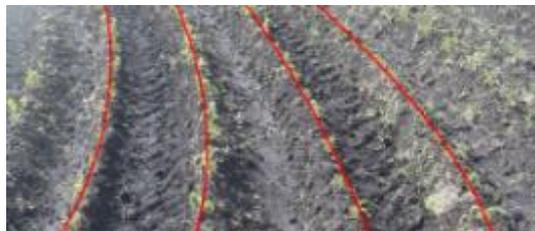
(d) $CRDA_{(DBMR)} = 0.898$; $CRDA_{(DAGP)} = 0.867$



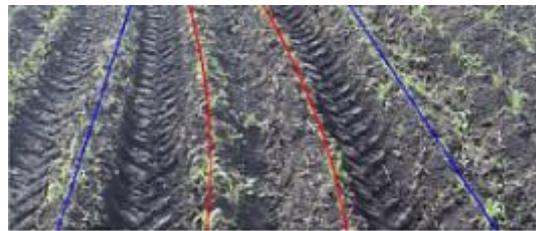
(e) $CRDA_{(DBMR)} = 0.907$; $CRDA_{(DAGP)} = 0.886$



(f) $CRDA_{(DBMR)} = 0.884$; $CRDA_{(DAGP)} = 0.828$



(g) $CRDA^*_{(DBMR)} = 0.859$; $CRDA^*_{(DAGP)} = 0.842$



(h) $CRDA^*_{(DBMR)} = 0.842$; $CRDA^*_{(DAGP)} = 0.823$



(i) $CRDA^*_{(DBMR)} = 0.889$; $CRDA^*_{(DAGP)} = 0.871$



(j) $CRDA^*_{(DBMR)} = 0.761$; $CRDA^*_{(DAGP)} = 0.754$

Fig. 3.23 Ejemplos de la ROI para cada conjunto de imágenes de prueba junto con la métrica CRDA que mide las diferencias de píxeles entre las filas de cultivo estimadas y esperadas, considerando el espaciado regular inter-líneas, y el modificado CRDA* que considera el máximo espaciado inter-líneas debido a la variabilidad en la separación. El método DBMR se basa en micro-ROIs, mientras que DAGP se fundamenta en la acumulación de píxeles verdes. En (a-c) las imágenes pertenecen al Set-1 conteniendo sólo líneas rectas de cultivo; en (d-f) al Set-2 con líneas espaciadas regularmente y en (g-j) al Set-3 con líneas espaciadas irregularmente.

En relación al Test 1, los valores de CRDA (promedio, asimetría, curtosis y ranking) para el Set-1 se presentan en la Tabla 3.1. Respecto a la asimetría, todos los datos aparecen sesgados a la izquierda debido a sus valores negativos; DBMR obtiene el valor de asimetría menos negativo, produciendo la mejor simetría en la distribución de datos, es decir, más concentrados alrededor del valor medio. Respecto a la curtosis, la cola más corta en la distribución se obtiene también con DBMR. Esto significa que con un buen ajuste se minimiza la presencia de puntos aislados (*outliers*), aunque éste logra la tercera posición en el ranking con respecto a los valores promedio. Por otra parte, DBMR supera a TH y LTS en los valores promedio. LRQ y CRD obtienen valores promedio en el mismo orden de magnitud que DBMR, pero con peores simetrías y un gran número de valores atípicos. TH obtiene simetrías aceptables y un número de puntos aislados similares a los de DBMR, pero con peor valor promedio. Esto significa que el método propuesto DBMR resulta acorde con los métodos que han sido ya suficientemente probados (LRQ y CRD) respecto de los valores promedio, mejorando la distribución de los datos en lo que respecta a la asimetría y curtosis. Por otra parte, el rendimiento de DAGP para los valores promedio es superior a TH, pero ligeramente inferior a los otros métodos, incluyendo el DBMR. Los métodos LRQ y CRD obtienen valores promedio en el mismo orden de magnitud que DAGP, pero con peores simetrías y un mayor número de valores atípicos. Esto significa que el método propuesto DAGP también está acorde a los mencionados métodos LRQ y CRD para los valores promedio, pero superando en la distribución de datos en relación a la asimetría y curtosis. Sin embargo, DAGP ofrece un rendimiento ligeramente menor que DBMR, considerando las métricas referidas en la Tabla 3.1.

Tabla 3.1 CRDA (*Crop Row Detection Accuracy*) para las pruebas realizadas en líneas rectas de cultivo. Los valores de CRDA varían entre 0 y 1, donde una puntuación más alta expresa un mejor rendimiento.

CRDA	SET-1					
	HT	LTS	LRQ	CRD	DAGP	DBMR
Promedio	0.834	0.921	0.929	0.935	0.918	0.928
Asimetría	-0.686	-1.108	-2.233	-1.866	-1.091	-0.591
Curtosis	2.293	4.205	4.567	5.258	4.491	2.012
Ranking (con promedio)	6	4	2	1	5	3

En relación al Test 2, los valores de CRDA para el Set-2 se muestran en la Tabla 3.2. Como en el test previo, todos los datos aparecen sesgados hacia la izquierda

(valores negativos). DBMR supera a TMGEM y DAGP con el valor promedio más alto y el valor de simetría menos negativo (mejor simetría) y mínimo número de puntos aislados. DAGP es ligeramente inferior a TMGEM en las métricas de comparación para este conjunto de imágenes.

Tabla 3.2 CRDA para las pruebas realizadas en líneas de cultivo curvas espaciadas regularmente

CRDA	SET-2		
	TMGEM	DAGP	DBMR
Promedio	0.871	0.863	0.903
Asimetría	-0.911	-2.064	-0.769
Curtosis	4.141	4.311	3.410
Ranking (con promedio)	2	3	1

En relación al Test 3, los valores de CRDA* para el Set-3 se muestran en la Tabla 3.3. De nuevo, DBMR supera a TMGEM y DAGP en promedio, asimetría y curtosis. DAGP supera notablemente a TMGEM en los valores promedio (ranking) para este conjunto de imágenes.

Tabla 3.3 CRDA* (ligera variante de CRDA) para las pruebas realizadas en líneas de cultivo espaciadas irregularmente

CRDA*	SET-3		
	TMGEM	DAGP	DBMR
Promedio	0.548	0.856	0.863
Asimetría	-1.154	-1.867	-0.911
Curtosis	4.499	4.467	3.712
Ranking (con promedio)	3	2	1

En general, a partir de las tres pruebas (Tests 1-3), se puede observar que DBMR y DAGP obtienen resultados ciertamente favorables, alcanzando similar o mejor rendimiento que otras estrategias existentes para la detección de líneas de cultivo rectas y curvas con espaciado regular, pero logrando claras mejoras en campos que contienen surcos espaciados irregularmente. Además, DBMR y DAGP pueden detectar líneas de cultivo rectas y curvas coexistiendo en la misma imagen, a diferencia de los otros métodos TH, CRD, LTS, LRQ y TMGEM. Por lo tanto, se puede concluir que los métodos propuestos (DBMR y DAGP) son moderadamente insensibles a la curvatura de las líneas de cultivo y pueden detectar ambos tipos de líneas (rectas y curvas) espaciadas de forma regular e irregular con precisión suficiente e incluso alta en campos de maíz,

utilizando un sistema de visión convenientemente posicionado a bordo de un tractor con conocimiento *a priori* sobre la orientación de la curvatura (hacia la izquierda o hacia la derecha) de las líneas de cultivo. La Fig. 3.23(a)-(j) muestra ejemplos ilustrativos que representan 10 imágenes de las 920 disponibles (Sets 1-3). Las líneas de cultivo localizadas en la ROI se muestran junto con los valores CRDA y CRDA* para ambos métodos propuestos DBMR y DAGP, de acuerdo a los parámetros intrínsecos y extrínsecos del sistema de visión. La alta cobertura de plantas afecta significativamente el rendimiento (obteniendo peores resultados, cuantificado alrededor del 12%) de los métodos propuestos sobre las líneas de cultivo curvas y rectas, principalmente en el primer grupo, como se muestra en la Fig. 3.23(j), donde las hojas de las plantas se diseminan e invaden los espacios entre las líneas de cultivo, a veces con solapamiento entre malas hierbas y cultivos.

Como se indicó anteriormente, los métodos TMGEM, DAGP y DBMR pueden detectar ambos tipos de líneas, curvas y rectas, a diferencia de los otros métodos TH, CRD, LTS y LRQ, que solamente pueden detectar líneas rectas. TMGEM trabaja sin conocimiento *a priori* respecto al número de líneas de cultivo y geometría del campo, a diferencia del resto de métodos. Sin embargo, TMGEM asume que todas las líneas de cultivo están espaciadas regularmente en el campo y en la imagen, a diferencia de DAGP y DBMR, que también trabajan sobre líneas espaciadas irregularmente. CRD usa el concepto de punto de fuga para limitar posibles líneas rectas de cultivo, si bien esto no se aplica en DBMR y DAGP, ya que dependen del grado de curvatura de los surcos y cuyo caso las líneas curvadas pueden no converger o de hecho no convergen hacia el punto de fuga en la imagen.

El costo computacional ha sido también analizado. Las Tablas 3.4 y 3.5 muestran los tiempos de procesamiento promediados en porcentaje (%) y milisegundos (ms) para los métodos completos, así como también, distinguiendo entre los diferentes módulos para los tres conjuntos de imágenes probadas.

Tabla 3.4 Tiempo de ejecución (promedio) en porcentaje (%) y milisegundos (ms) para cada módulo del método DBMR (*Detection Based on Micro-ROIs*)

	Módulos	Porcentaje (%)	Test-1 (ms)	Test-2 (ms)	Test-3 (ms)
1	Segmentación	41.7	239	255	265
2	Identificación de puntos de inicio	8.8	50	54	57
3	Detección de líneas de cultivo	49.6	284	304	315
	TOTAL	100	573	612	637

DBMR se ejecuta en 573, 612 y 637 ms para cada conjunto de imágenes (Set 1-3) respectivamente. El módulo de segmentación consume el 41.7% del tiempo total, la identificación de puntos de inicio el 8.8% y la detección de las líneas de cultivo el 49.6%. DAGP se ejecuta en 692, 712 y 721 ms para cada conjunto de imágenes (Set 1-3) respectivamente. El módulo de segmentación consume el 43.6% del tiempo total, la identificación de puntos de inicio el 7.5% y la detección de las líneas de cultivo el 49%.

Tabla 3.5 Tiempo de ejecución (promedio) en porcentaje (%) y milisegundos (ms) para cada módulo del método DAGP (*Accumulation of Green Pixels*).

	Módulos	Porcentaje (%)	Test-1 (ms)	Test-2 (ms)	Test-3 (ms)
1	Segmentación	43.6	301	310	314
2	Identificación de puntos de inicio	7.5	52	53	54
3	Detección de líneas de cultivo	49.0	339	349	353
	TOTAL	100	692	712	721

Considerando que en general, los vehículos agrícolas, durante la realización de las tareas en el campo, trabajan a velocidades que oscilan entre 3 y 6 km h⁻¹, esto significa que en el peor caso (6 km h⁻¹), para atravesar los 5 m de la ROI (largo) el vehículo necesita 3 s, que es muy superior a los 637 o 721 ms (en los peores casos de los métodos propuestos) requeridos para el procesamiento de la imagen. Las pruebas se llevaron a cabo con las imágenes previamente almacenadas y luego procesadas *off-line*, es decir no en tiempo real, pero considerando todas las restricciones requeridas para tiempo real. En este sentido, durante el procesamiento en tiempo real, el tiempo requerido para capturar la imagen se debe añadir al valor previo.

Adicionalmente, se debe considerar que el tiempo de ejecución fue medido en la interfaz gráfica de Matlab (*GUIDE*) que es un lenguaje de programación interpretado. Este tiempo puede disminuir significativamente, si el método se implementa en un lenguaje de programación compilado (como C++) y se ejecuta en una plataforma y sistema operativo de tiempo real, por ejemplo *LabView* y *CRio* como en el proyecto RHEA (2014). Bajo esta implementación, el tiempo de procesamiento podría reducirse alrededor del 40%, como se reportó en RHEA, mejorando considerablemente el tiempo de ejecución, lo cual puede ser útil para aplicaciones de tiempo real, siendo un tema identificado para una investigación futura.

La Tabla 3.6 muestra los tiempos de procesamiento promediados en milisegundos (ms) para TMGEM, DAGP y DBMR. Los métodos DBMR y DAGP

lograron mejores rendimientos que TMGEM. El procedimiento TMGEM trabaja sobre una pequeña ROI redimensionada a 320×240 píxeles para reducir el tiempo de computación requerido sin aparente pérdida de información significativa. Una resolución de imagen superior en píxeles (640×480) incrementa considerablemente el tiempo de ejecución (4527 ms), incluso usando el lenguaje de programación compilado C++. Por el contrario, DAGP y DBMR se aplicaron en ROIs grandes (2000×650) píxeles, la cual es suficiente para capturar la curvatura de las líneas de cultivo.

Tabla 3.6 Tiempo de ejecución (promedio) en milisegundos (ms), tamaño de la ROI y lenguaje de programación para los métodos TMGEM, DAGP y DBMR para detectar líneas de cultivo curvas y rectas

Método	Tiempo de procesamiento	Tamaño de la ROI (ancho \times largo)	Lenguaje de programación
TMGEM	1749	320×240	C++
	4527	640×480	
DAGP	721	2000×650	Matlab
DBMR	637	2000×650	Matlab

3.3.3 Impacto de la curvatura

El rendimiento de los métodos propuestos fue también evaluado para detectar líneas de cultivo orientadas hacia la derecha (Fig. 3.22a) y fue probado en 80 imágenes adicionales conteniendo líneas rectas y curvas. El resultado obtenido fue similar al ya presentado en las Tablas 3.2 y 3.3. El tiempo de ejecución extra requerido para el proceso de reflexión especular vertical y las operaciones de traslación fue inferior a 20 ms, es decir, el tiempo adicional es irrelevante y fácilmente asumible por los métodos.

La Tabla 3.7 muestra el rango de los coeficientes de mayor grado para ambos tipos de líneas. Esto significa que las líneas de cultivo analizadas se limitan a un grupo de líneas rectas y curvas, definidas por los parámetros del modelo matemático, Ec. (3.3); es decir, líneas rectas con la pendiente (m) y cuadráticas con el coeficiente de curvatura (a). Gracias a este estudio, se han identificado los límites de estos parámetros para cada tipo de línea. Esto permite verificar la existencia de una importante mejora durante el proceso de prueba, de particular relevancia cuando las líneas de cultivo deben ser aceptadas o rechazadas dependiendo de los valores calculados para los coeficientes (m , a) quedando dentro o fuera de estos rangos. Además, en las líneas curvadas, el máximo valor para el coeficiente $a = 0.0015$ (ver Tabla 3.7) representa una curvatura con un radio de 19 m en las imágenes utilizadas para la prueba, tal y como se explicó

previamente. Un valor negativo indica una línea con orientación hacia la izquierda y uno positivo hacia la derecha.

Tabla 3.7 Rango de valores permitidos para los coeficientes de grado superior para cada tipo de línea de cultivo (rectas y curvas) orientadas hacia la izquierda y derecha

Tipo de línea	Modelo matemático	Coefficiente de grado mayor	Orientación	Rango de valores permitidos
Recta	$y = mx + b$	m	Izquierda/Derecha	[-1 a 1]
Cuadrática	$y = ax^2 + bx + c$	a	Izquierda	[-0.0015 a 0]
			Derecha	[0 a 0.0015]

3.3.4 Consideraciones adicionales

Desde el punto de vista de la implementación, cabe todavía señalar algunas consideraciones adicionales. Respecto a las limitaciones del DBMR y DAGP, se deben considerar cinco restricciones cuando se plantee su aplicación: (i) el número de líneas de cultivo a detectar, debido a que solo se permite este número de alineaciones; (ii) la concavidad de las líneas de cultivo (bien izquierda o bien derecha) se debe conocer *a priori*; (iii) los parámetros intrínsecos y extrínsecos del sistema de visión, que hace referencia a la posición de la cámara y el sistema óptico; (iv) la altura del cultivo entre 100 y 300 mm, de manera que las hojas no cubran el suelo y las alineaciones de las líneas de cultivo se puedan distinguir del suelo con cierta relevancia; y (v) la orientación de la concavidad de las líneas de cultivo no se puede detectar con los métodos propuestos; por lo que en su caso se requiere de un conocimiento *a priori*, considerando la dirección de navegación del tractor combinado con la configuración del GPS.

La robustez de los métodos DBMR y DAGP se complementan mediante dos procedimientos: (i) selección y verificación de líneas, donde se pueden asumir varias anomalías, incluyendo el número de líneas de cultivo detectadas (Fig. 3.20c), la separación de las líneas de cultivo (entre 75 y 95 mm, Fig. 3.21a) y su intersección (Fig. 3.21b), debido a la presencia significativa de discontinuidades (≤ 1.20 m) y malas hierbas ($\leq 5\%$); (ii) controlando las orientaciones y coeficiente para cada tipo de línea (m , a). Como se describió en el análisis de resultados de la Tabla 3.7, valores fuera de estos límites podrían causar defectos durante la detección de las líneas de cultivo.

CAPÍTULO 4

Discriminación de cultivo y malas hierbas

4.1 Introducción

Como se ha indicado en el capítulo uno, los sistemas de visión por computador resultan de interés para la automatización de tareas (García-Santillán & Caranqui, 2014), incluyendo aquellas específicas en agricultura. No obstante, no están exentos de las dificultades mencionadas en el citado capítulo, relativas a las condiciones adversas de entornos de exterior o los distintos estados de crecimiento y densidad de las plantas en los campos de cultivo.

De acuerdo con dichas consideraciones, en este capítulo se describe el diseño de una nueva estrategia, basada en los sistemas de visión por computador, para la discriminación de cultivo/malas hierbas en sembríos de línea ancha (maíz) en etapas iniciales de crecimiento (hasta 40 días), enfocándose en las malas hierbas entremezcladas y solapadas con el cultivo en los espacios intra-línea, aplicando un criterio de similitud basado en la distancia de Mahalanobis, derivado de un clasificador *Bayesiano*. Esto representa la principal contribución de investigación en este estudio. El método propuesto se diseñó para tratar con las condiciones ambientales adversas antes mencionadas, enfocándose en el rendimiento en términos de precisión y eficiencia, medido a través del análisis de la matriz de confusión y el coeficiente *Kappa*.

Las imágenes fueron adquiridas bajo la proyección en perspectiva con una cámara instalada a bordo de un tractor. El procesamiento de imágenes consta de tres fases secuenciales: (i) segmentación, (ii) entrenamiento y (iii) pruebas. Las tres fases se ejecutan en línea (*online*) para cada imagen, donde el entrenamiento es específico de cada imagen individualmente, sin necesidad de un entrenamiento previo (*offline*), a diferencia de lo que ocurre en los enfoques basados en aprendizaje automático, principalmente supervisado. Esto representa la segunda contribución en la investigación. El método identifica separadamente las malas hierbas localizadas en ambos espacios inter e intra-línea.

La estrategia propuesta explota el rendimiento parcial de algunos procedimientos existentes en la literatura y referenciados en el capítulo dos, basados en imágenes, e integra en una estrategia global para la discriminación de cultivo/malas hierbas con la máxima precisión posible.

4.2 Materiales y métodos

4.2.1 Colección de imágenes

Las imágenes utilizadas para este estudio pertenecen a cultivos de maíz y fueron capturadas con una cámara a color Panasonic DMC-SZ8, instalada en la parte frontal de un tractor, en un campo de maíz localizado al sur de Madrid-España en la ribera del río Manzanares. Un conjunto de 500 imágenes se adquirieron durante Abril y Mayo de 2013 y 2014. Las adquisiciones fueron espaciadas 5-6 días durante un período de 40 días, es decir, las imágenes se obtuvieron bajo diferentes condiciones de iluminación y etapas de crecimiento (plantas de maíz y malas hierbas). Además, un grupo adicional de imágenes de similares condiciones se utilizó en la experimentación. Estas imágenes fueron adquiridas en Ecuador y se describieron en el capítulo tres. La Fig. 4.1 muestra tres ejemplos ilustrativos de las imágenes capturadas en el campo. En (a) se presenta una imagen obtenida en un día soleado con alta densidad de malas hierbas; (b) en un día nublado con un nivel medio de malas hierbas y (c) en un día intermedio con baja densidad de malas hierbas.

Las imágenes digitales fueron capturadas bajo la proyección en perspectiva y almacenadas como imágenes a color de 24-bit en el espacio de color RGB, formato JPEG con una resolución de 1920×1080 píxeles. Los ángulos de inclinación (*pitch*) de la cámara variaron entre 20° y 30° y las alturas, desde el suelo a la cámara, entre 1.50 y 2.30 m con el objetivo de enfocar la región de interés (ROI), donde se aplican los tratamientos específicos. La longitud focal del sistema óptico fue fijada a 9 mm. El tamaño y localización de la ROI se especificó considerando (i) el número de líneas de cultivo a detectar y (ii) que la ROI proyectada en la imagen contenga suficiente resolución (en píxeles) para discriminar las plantas verdes (cultivo y malas hierbas) del suelo (Romeo et al., 2013b). En el enfoque propuesto, se seleccionaron cuatro líneas de cultivo para la detección, el cual es el número utilizado en el proyecto RHEA (2014) y reportado por Emmi et al. (2014b) como se ha indicado previamente. Considerando las cuatro líneas de cultivo y el espaciado inter-líneas de 0.75 m, el ancho total de la ROI fue de 3 m. Esta área comienza a 3 m con respecto a un eje vertical virtual que atraviesa el centro del plano de la imagen en la cámara (Fig. 2.6). Esta configuración evita que los elementos delante del tractor sean proyectados en la imagen. La longitud de la ROI se fijó en 4 m, ya que proporciona suficiente resolución de imagen como se explicó anteriormente.



(a)



(b)



(c)

Fig. 4.1 Ilustraciones de imágenes procesadas por el método bajo diferentes condiciones de iluminación, densidad de malas hierbas y tamaños de plantas de maíz; (a) día soleado con un alto nivel de malas hierbas; (b) día nublado con densidad media de malas hierbas y (c) día intermedio con baja presión de malas hierbas.

El área 3D en el campo resultó en una resolución de imagen de 1500×600 píxeles (ancho \times largo), que representa aproximadamente el 43% de la imagen original y siempre está localizada en la misma posición dentro de la imagen. La Fig. 4.2(a) muestra la ROI encerrada en un rectángulo. Sin embargo, el método se puede adaptar fácilmente para detectar un número diferente de líneas de cultivo con la correspondiente configuración de la cámara.

Las imágenes fueron procesadas utilizando el software Matlab de MathWorks (2015), versión 8.5 (R2015a), en un procesador Intel Core i7 2.0 GHz, 8GB RAM y sistema operativo Windows 8.1 Pro (64-bits). El algoritmo propuesto se desarrolló utilizando la interfaz gráfica de usuario (*GUIDE*) incorporado en Matlab.



(a)



(b)

Fig. 4.2 (a) Delimitación de la ROI (en rectángulo) en la imagen original RGB; (b) ROI con cuatro líneas de cultivo detectadas utilizando el método propuesto por García-Santillán et al. (2017b).

4.2.2 Arquitectura del método de visión

Como se ha indicado previamente, el método propuesto consta de tres fases secuenciales: (i) segmentación, (ii) entrenamiento y (iii) pruebas. La Fig. 4.3 muestra la estructura completa, incluyendo el diagrama de flujo. Las fases del proceso se ejecutan secuencialmente en línea (*online*), de manera que los datos de entrada son adquiridos y procesados inmediatamente para cada imagen de entrada.

Este procedimiento fue diseñado para ejecutarse como una etapa posterior al proceso de detección de líneas de cultivo, es decir, una vez que cada línea de cultivo ha sido identificada y modelada matemáticamente por sus correspondientes ecuaciones como una línea recta ($y = mx + b$) o cuadrática ($y = ax^2 + bx + c$) dentro de la ROI.

En cada ecuación de una línea recta, los coeficientes estimados m y b son la pendiente y el intercepto, respectivamente, mientras que en una cuadrática son a , b y c . La Fig. 4.2(b) muestra la ROI con cuatro líneas de cultivo detectadas (líneas rojas) utilizando el método existente propuesto por García-Santillán et al. (2017b) descrito en el capítulo tres con los resultados mostrados. Como viene siendo habitual a lo largo de esta investigación, las líneas de cultivo fueron cuatro las cuales atraviesan los bordes tanto superior como inferior de la ROI. Este número es suficiente para el guiado automático de vehículos y la identificación de malas hierbas, como se justificó en el proyecto RHEA (2014).

El método propuesto se diseñó teniendo en cuenta conocimiento *a priori* acerca de la detección de líneas de cultivo, descritas anteriormente en el capítulo tres, y otras consideraciones acerca de la discriminación entre cultivo/malas hierbas, adquiridas durante trabajos y experiencias previas (Guerrero et al., 2012; Montalvo et al., 2012b; Montalvo et al., 2013a), los cuales se resumen como sigue:

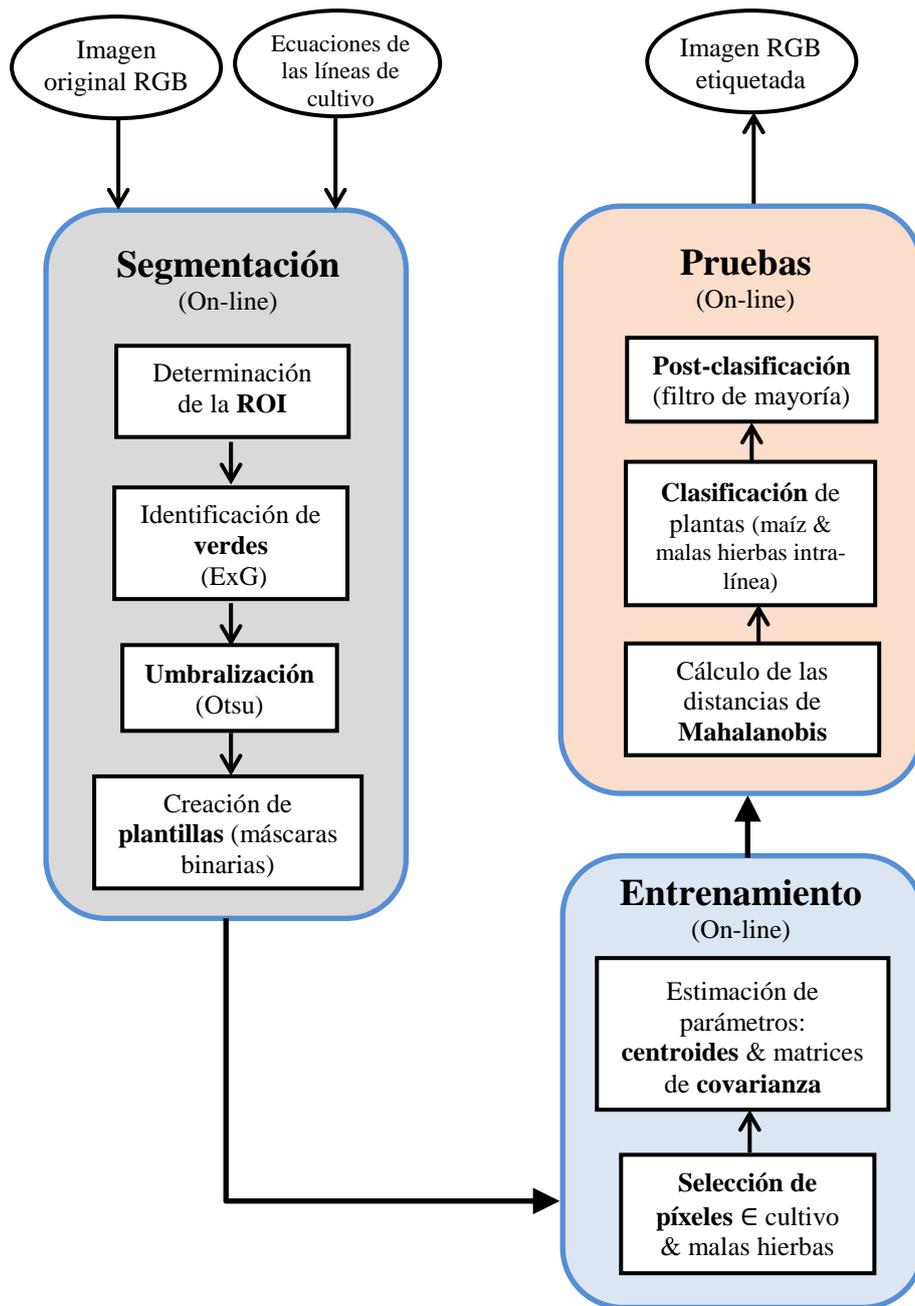


Fig. 4.3 Arquitectura del método de visión propuesto

- Los cultivos y malas hierbas despliegan un alto grado de similitud en sus firmas espectrales (similares colores verdes), pero todavía con suficientes diferencias para la separación, basado en la segmentación de imágenes.
- Durante el tiempo de tratamiento del cultivo de maíz (en etapas tempranas de crecimiento), las malas hierbas aparecen en rodales aislados con respecto al cultivo y distribuidos irregularmente en el campo con diferentes densidades en los espacios inter- e intra-línea.

Las fases principales del método propuesto son detalladas a continuación.

4.2.2.1 Segmentación

La discriminación, con la máxima precisión posible, entre cultivos y malas hierbas con similares firmas espectrales es crucial para los tratamientos específicos en la Agricultura de Precisión. Al respecto, el enfoque automático basado en Otsu, utilizado en Montalvo et al. (2013a), referenciado en el capítulo dos, aplicando una doble umbralización ha mostrado su eficacia en cuanto al rendimiento se refiere frente a otras estrategias existentes, que incluye al aprendizaje supervisado como SVM (*Support Vector Machines*) (Guerrero et al., 2012). Los métodos supervisados requieren un entrenamiento exhaustivo, a diferencia de la umbralización que tiene la habilidad de auto ajustarse a las condiciones ambientales cambiantes, comunes en la agricultura al aire libre. Bajo estas consideraciones, la fase de segmentación se diseñó con cuatro procesos secuenciales: (a) determinación de la ROI; (b) identificación de verdes; (c) umbralización y (d) creación de plantillas. El proceso de segmentación produce dos imágenes binarias llamadas máscaras (o plantillas) para limitar los píxeles que pertenecen a los cultivos y malas hierbas, respectivamente.

a) Determinación de la ROI

Definida tal y como se ha indicado previamente. La Fig. 4.2(a) muestra una ROI encerrada en el rectángulo.

b) Identificación de verdes

El índice de vegetación *ExG* (Woebbecke et al., 1995) fue seleccionado debido a su buen comportamiento, verificando esta circunstancia tras un estudio exhaustivo con diferentes índices (Guijarro et al., 2011). Este comportamiento también se ha verificado durante la aplicación de los métodos descritos en el capítulo tres. La Fig. 4.4(a) muestra

la imagen resultante en escala de grises después de aplicar *ExG* a la ROI original (RGB).

c) *Umbralización*

Dada la imagen en escala de grises obtenida por la aplicación de *ExG*, se realiza una única umbralización para separar las plantas verdes (cultivos y malas hierbas) del suelo. El proceso de umbralización se basó en el método de Otsu (1979) debido a su buen comportamiento en diferentes escenarios, incluyendo naturalmente los entornos agrícolas (Guijarro et al., 2015; Montalvo et al., 2016). La Fig. 4.4(b) muestra la ROI como una imagen binaria, conteniendo píxeles blancos para las plantas verdes (cultivos/malas hierbas) y píxeles negros para el suelo.

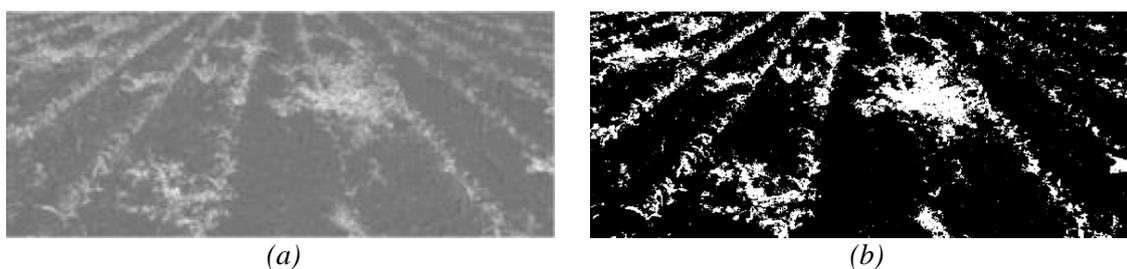


Fig. 4.4 (a) Imagen en escala de grises después de aplicar *ExG*; (b) imagen binaria después de aplicar la umbralización basada en Otsu (1979).

d) *Creación de plantillas*

Tomando como referencia las ecuaciones que modelan las líneas de cultivo (Fig. 4.2b), etiquetadas de izquierda a derecha como L1, L2, L3 y L4 respectivamente, se establecen márgenes de igual tamaño para cada línea de cultivo a lo largo de la misma. La Fig. 4.5 muestra las líneas de cultivo estimadas (en rojo) con los márgenes respectivos (en amarillo).

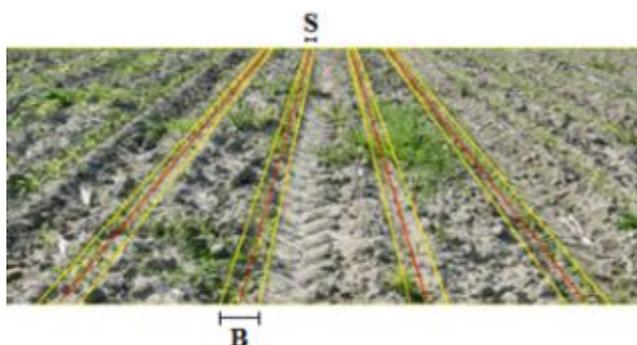


Fig. 4.5 Ilustración de la ROI con cuatro líneas de cultivo estimadas (en rojo) con los márgenes respectivos (en amarillo).

Cada margen tiene un ancho (B) en la base de la ROI, el cual disminuye una cierta cantidad (l) según se asciende por las líneas de cultivo hacia la parte superior de la ROI. Se calcula como sigue:

$$l = \frac{B - S}{A} \quad (4.1)$$

donde B es el ancho en la base de la ROI, S el ancho en la parte superior de la ROI y A la altura de la ROI, todas en términos de píxeles. Los parámetros B y S son establecidos de acuerdo a la etapa de crecimiento del cultivo. En este estudio, B se estableció por experimentación entre 100 y 160 píxeles, que representan entre 15 y 25 cm respectivamente; mientras que S se fijó en el 30% de los valores previos, de acuerdo a la configuración geométrica utilizada en el sistema de visión.

Una vez establecidos los márgenes (Fig. 4.5), se crean dos imágenes binarias (máscaras). La primera máscara contiene píxeles blancos ubicados dentro de los cuatro márgenes (espacio intra-línea), Fig. 4.6(a). La segunda máscara es complementaria a la primera y contiene píxeles blancos ubicados fuera de los márgenes, es decir, en los espacios inter-líneas, Fig. 4.6(b).



Fig. 4.6 Imágenes binarias (máscaras); (a) máscara conteniendo cuatro márgenes (intra-línea); (b) máscara conteniendo cinco espacios inter-líneas.

La idea de aplicar máscaras binarias para limitar los píxeles que pertenecen al cultivo fue aplicada por Montalvo (2012a), donde las máscaras se construyen de forma manual, siendo estáticas, en un proceso fuera de línea, aplicando conocimiento *a priori* acerca de la configuración de la cámara y la geometría del sistema de visión. Por el contrario, en el método propuesto, las máscaras se construyen dinámicamente para cada imagen, en un proceso en línea, lo que representa una contribución relevante en esta investigación. De esta forma, una vez localizadas las líneas de cultivo y establecidos los márgenes indicados, las máscaras quedan definidas exactamente por los límites que definen los márgenes.

4.2.2.2 Entrenamiento

Con las dos mascararas binarias obtenidas en la fase previa (Figs. 4.6a, b), se llevan a cabo dos procesos (en línea) para seleccionar los píxeles que pertenecen a las dos clases (cultivos/malas hierbas). Sin pérdida de generalidad, se asume que los valores espectrales de las imágenes de las muestras en ambas clases se pueden modelar mediante sendas funciones de densidad de probabilidad Gaussianas (Duda et al., 2001), las cuales quedan definidas por dos parámetros cada una, es decir, promedio o centroide y matriz de covarianza. Estos parámetros deben estimarse, mediante un proceso de selección previa de las muestras, como se describe a continuación:

a) Selección de muestras de píxeles para las clases cultivo/malas hierbas

Se asume que la mayoría de los píxeles que pertenecen a las malas hierbas están localizados en el espacio inter-líneas y la mayoría de los píxeles que pertenecen al cultivo están en el espacio intra-línea. Así, se realiza una operación lógica *AND* entre la imagen binaria que contiene la vegetación (Fig. 4.4b) con cada una de las máscaras binarias (Figs. 4.6a, b), identificando las muestras para cada clase (malas hierbas/cultivo) como se muestran en las Figs. 4.7(a) y (b) respectivamente. Los píxeles blancos en las imágenes binarias resultantes proporcionan las localizaciones de los píxeles en la ROI original que contienen los valores espectrales RGB, los cuales son las muestras $x \in R^3$ para la estimación de los parámetros buscados (centroide y matriz de covarianza).

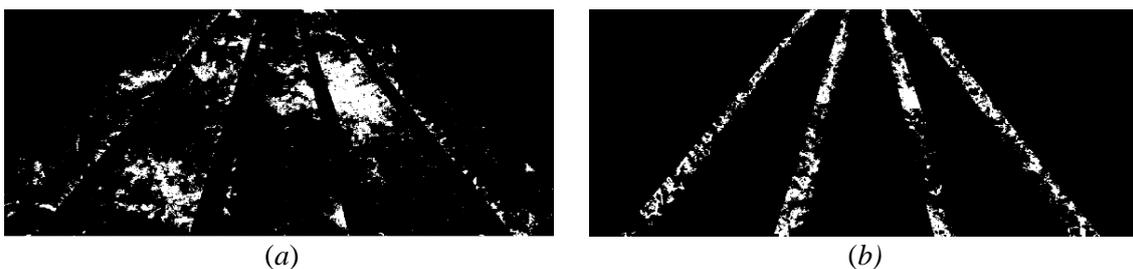


Fig. 4.7 (a) Píxeles que representan la clase de malas hierbas inter-líneas; (b) píxeles que pertenecen a la clase cultivo, los cuales serán refinados posteriormente para la discriminación entre plantas de maíz y malas hierbas intra-fila.

b) Estimación de parámetros: centroides y matrices de covarianza

El centroide se define como el vector que contiene el promedio para cada componente espectral R, G, B y se define como sigue:

$$\mu = (\bar{R}, \bar{G}, \bar{B})$$

$$\bar{R} = \frac{1}{n} \sum_{i=1}^n R_i, \quad \bar{G} = \frac{1}{n} \sum_{i=1}^n G_i, \quad \bar{B} = \frac{1}{n} \sum_{i=1}^n B_i, \quad (4.2)$$

donde R_i, G_i, B_i son los componentes espectrales rojo, verde y azul respectivamente para un píxel dado perteneciente a la clase y n es el número de píxeles de la clase.

La matriz de covarianza es una matriz cuadrada y simétrica (3×3) que contiene las varianzas y covarianzas asociadas con los tres componentes espectrales. Los elementos de la diagonal principal de la matriz contienen las varianzas de los componentes $\mathbf{x} = (R, G, B)$, mientras que los elementos fuera de la diagonal contienen las covarianzas entre todos los posibles pares de variables. La covarianza entre dos variables se define como sigue:

$$\text{Cov}(X, Y) = \left(\frac{1}{n} \sum_{i=1}^n X_i Y_i \right) - \bar{X} \bar{Y}, \quad \forall (X, Y) \in RGB \quad (4.3)$$

donde (X, Y) representa un par de variables de los componentes espectrales (R, G, B) ; \bar{X}, \bar{Y} los respectivos promedios obtenidos por la Ec. (4.2) y n el número de píxeles de la clase.

La estimación de los centroides y matrices de covarianzas para las clases cultivo y malas hierbas se realiza como sigue:

- a) Se seleccionan los píxeles RGB considerando la ROI que representa la clase de malas hierbas inter-líneas, Fig. 4.7(a), calculando así el centroide $\bar{W} = (\bar{R}_w, \bar{G}_w, \bar{B}_w)$ y la matriz de covarianza utilizando las Ecs. (4.2) y (4.3) respectivamente. En la Fig. 4.8(a) se muestra la distribución de los píxeles RGB en el espacio R^3 que pertenece a las malas hierbas inter-líneas con su respectivo centroide.

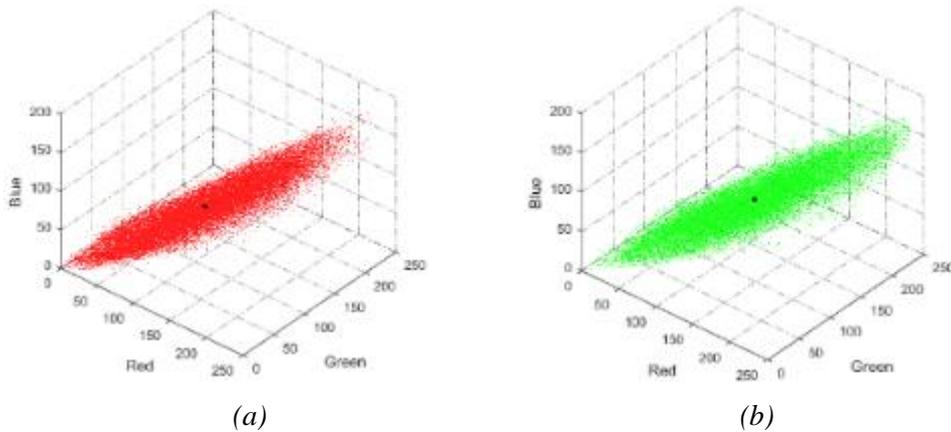


Fig. 4.8 Distribución de los píxeles RGB en el espacio R^3 con el respectivo centroide; (a) clase de malas hierbas inter-líneas; (b) clase cultivo.

- b) Se seleccionan los píxeles *RGB* utilizando la ROI que representan la clase cultivo, Fig. 4.7(b), y luego se calculan el centroide $\bar{C} = (\bar{R}_c, \bar{G}_c, \bar{B}_c)$ y la matriz de covarianza como antes. En la Fig. 4.8(b) se muestra la distribución de los píxeles *RGB* en el espacio tridimensional (\mathcal{R}^3) que pertenece al cultivo con su respectivo centroide.

Se puede observar en las Figs. 4.8(a) y (b) que existe un solapamiento entre las clases cultivo y malas hierbas, debido a la alta similitud en las firmas espectrales (colores verdes), pero todavía con diferencias suficientes para su separación, lo que constituye una parte esencial del proceso de detección.

4.2.2.3 Pruebas

Dados los centroides y matrices de covarianza para cada clase (cultivo y malas hierbas) obtenidas en la fase previa, se procede a la discriminación entre el cultivo y malas hierbas intra-línea que aún no han sido identificadas en la Fig. 4.7b. Los procesos se sintetizan en los siguientes tres pasos: (a) cálculo de la distancia de Mahalanobis, (b) clasificación de plantas y (c) post-clasificación.

a) *Cálculo de la distancia de Mahalanobis*

Mahalanobis (1936) propuso una distancia entre un conjunto de puntos y el centro de gravedad de un espacio multivariado (media general). Esta métrica permite clasificar las observaciones en grupos predefinidos (malas hierbas/cultivo) a través de una medida de similitud espectral considerando la correlación entre las variables (*R*, *G*, *B*) que definen las componentes espectrales. La elección de la distancia de Mahalanobis en este trabajo, en lugar de otras medidas tal como por ejemplo la Euclidiana, se justifica por el hecho de que la distribución de las muestras en las clases que representan el cultivo y malas hierbas se ubican geoméricamente como agrupaciones elipsoidales en lugar de esferas (Fig. 4.8). De este modo, a través de la matriz de covarianza se captura la información relativa a la dispersión de las muestras en los elipsoides. Las variables *R*, *G*, *B* no son estadísticamente independientes, sino más bien manifiestan un cierto grado de correlación. La distancia de Mahalanobis al cuadrado se define en la Ec. (4.4), donde $\mathbf{x} \in \mathcal{R}^3$ representa el vector con los valores espectrales de los píxeles *RGB* de cada clase (cultivo/malas hierbas), $\boldsymbol{\mu}$ el centroide y Cov_x la matriz de covarianza definidas por la Ecs. (4.2) y (4.3) respectivamente.

$$D_M^2 = (\mathbf{x} - \boldsymbol{\mu})^T \text{Cov}_x^{-1} (\mathbf{x} - \boldsymbol{\mu}) \quad (4.4)$$

Por otro lado, la distancia Euclidiana al cuadrado se define como sigue:

$$D_E^2 = (R_i - \bar{R})^2 + (G_i - \bar{G})^2 + (B_i - \bar{B})^2 \quad (4.5)$$

donde (R_i, G_i, B_i) representan las componentes espectrales de los píxeles y $(\bar{R}, \bar{G}, \bar{B})$ los valores promedios obtenidos por la Ec. (4.2) para un conjunto de n píxeles.

La memoria y los requisitos de tiempo para calcular las distancias de Mahalanobis incrementan cuadráticamente. Sin embargo, como en este estudio solo se trata con las variables de los componentes espectrales (R, G, B) , el coste computacional puede ser asumido como se explica más adelante.

Las distancias de Mahalanobis para cada clase (cultivo/malas hierbas) se obtienen utilizando la Ec. (4.4) como sigue:

$$\begin{aligned} D_w &= D_M^2(w, \bar{W}), \quad \forall w \in \text{clase de malas hierbas} \\ D_c &= D_M^2(c, \bar{C}), \quad \forall c \in \text{clase cultivo} \end{aligned} \quad (4.6)$$

donde w, c representan los píxeles que pertenecen a las clases de malas hierbas y cultivo respectivamente, \bar{W} y \bar{C} los centroides obtenidos por la Ec. (4.2). Las distancias calculadas (D_w y D_c) se utilizan en la siguiente fase para la discriminación de plantas verdes en el espacio intra-línea, es decir, cultivos y malas hierbas (ambos entremezclados y solapados).

b) Clasificación de plantas

Una vez obtenidas las correspondientes distancias de Mahalanobis para cada clase (D_w y D_c) según la Ec. (4.6), se realiza una clasificación de los píxeles de la clase cultivo (Figs. 4.7b y 4.8b) con la finalidad de discriminar las plantas de cultivo (maíz) y las malas hierbas en el espacio intra-línea, que aún quedan dentro de los surcos como se indicó previamente. Así, la distancia de Mahalanobis se utiliza como medida de similitud (Rodríguez & Sossa, 2011) y la regla de decisión se define como sigue:

$$\begin{aligned} &Si (D_c \leq D_w) \text{ entonces} \\ &\quad \text{Píxel} \in \text{cultivo} \\ &\text{de lo contrario} \\ &\quad \text{Píxel} \in \text{malas hierbas intra-línea} \end{aligned} \quad (4.7)$$

En este punto, se identifican tres grupos de píxeles: cultivo (maíz) y malas hierbas inter- e intra-línea.

c) *Post-clasificación*

Con la finalidad de mejorar los resultados de la clasificación previa, se aplica una etapa de refinamiento a las imágenes binarias resultantes, utilizando un filtrado morfológico de mayoría con una vecindad de 7×7 . El efecto de variar el tamaño para 3×3 y 5×5 fue también estudiado. El filtrado permite homogenizar la imagen resultante, eliminando píxeles espurios que usualmente ocurren en la clasificación de imágenes agrícolas. El filtro asigna el píxel central a la categoría con la mayoría de valores en la vecindad.

La Fig. 4.9 muestra la clasificación y refinamiento de los píxeles que pertenecen a la clase cultivo (Fig. 4.7b) con la aplicación del mencionado filtro de mayoría 7×7 . En (a) malas hierbas intra-línea y (b) en cultivo refinado (solo plantas de maíz).

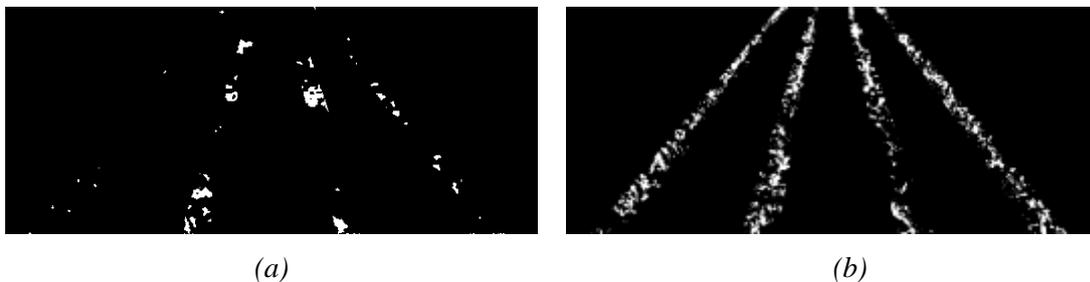


Fig. 4.9 Clasificación y refinamiento de píxeles que pertenecen a la clase cultivo (Fig. 4.7b) aplicando filtrado de mayoría con tamaño 7×7 ; (a) malas hierbas intra-línea; (b) cultivo refinado (solo plantas de maíz).

Como se indicó previamente, se identifican tres conjuntos de píxeles como (i) cultivo (Fig. 4.9b); (ii) malas hierbas inter-líneas (Fig. 4.7a); y (iii) malas hierbas intra-líneas (Fig. 4.9a). La Fig. 4.10 muestra las clases de píxeles etiquetadas con diferentes colores, en (a) utilizando la distancia de Mahalanobis y (b) la distancia Euclidiana. El cultivo (maíz) se etiqueta en azul, las malas hierbas intra-línea en rojo y las inter-líneas en amarillo. Las principales diferencias se muestran en círculos.

4.3 Resultados y discusión

Con la finalidad de evaluar cuantitativamente la validez de la estrategia propuesta, se seleccionaron aleatoriamente 50 imágenes con diferentes densidades de malas hierbas. La muestra corresponde al 10% de las adquiridas, las cuales fueron visualmente analizadas por un experto para identificar las plantas de cultivo y malas hierbas. La observación visual se realizó para cada imagen guiada por la imagen segmentada a través del enfoque propuesto en este capítulo. El experto concentró su

mayor esfuerzo en identificar las plantas de maíz y ambos tipos de malas hierbas inter- e intra-línea. Las malas hierbas intra-línea son difíciles de identificar debido a que generalmente se entremezclan y solapan con el cultivo (maíz) dentro de las líneas de cultivo.

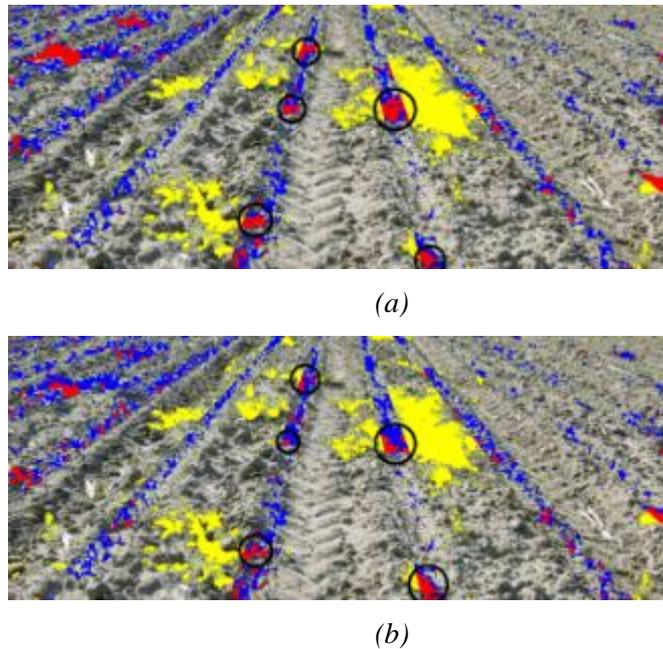


Fig. 4.10 Identificación de cultivo/malas hierbas aplicando (a) la distancia de Mahalanobis y (b) la distancia Euclidiana. Las plantas de maíz aparecen en azul, las malas hierbas intra-línea en rojo e inter-líneas en amarillo. Las principales diferencias se muestran en círculos.

Las imágenes *RGB* fueron manualmente etiquetadas, generando una nueva imagen *RGB* segmentada, constituyendo el *ground-truth* utilizado para las distintas pruebas. Siguiendo la idea de Montalvo et al. (2016) para facilitar la creación del *ground-truth* y el proceso de verificación, cada ROI (1500×600 píxeles) se dividió en 20 sub-imágenes de igual tamaño (300×150) como se muestra en la Fig. 4.11.

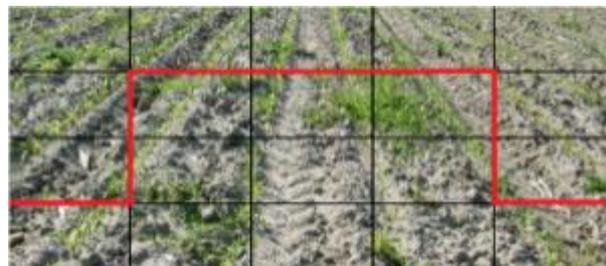


Fig. 4.11 División de la ROI (1500×600 píxeles) en 20 sub-imágenes de igual tamaño (300×150). El área limitada (en rojo) es utilizado para crear el *ground-truth*, es decir, 11 sub-imágenes por cada ROI.

El área delimitada (en rojo) se utilizó para generar el *ground-truth*, es decir, 11 sub-imágenes por cada ROI, las cuales facilitan la inspección visual del experto. De esta forma se crearon un total de 550 sub-imágenes, conformando la base de datos del *ground-truth*. La Fig. 4.12 ilustra un ejemplo ilustrativo de una de las imágenes perteneciente al *ground-truth*. En (a) una sub-imagen *RGB*; (b) sub-imagen manualmente etiquetada por el experto utilizando tres colores: cultivo en azul, malas hierbas inter-líneas en amarillo e intra-línea en rojo. Se puede observar, que incluso para un experto, es difícil distinguir los píxeles que pertenecen al cultivo y las malas hierbas intra-línea.

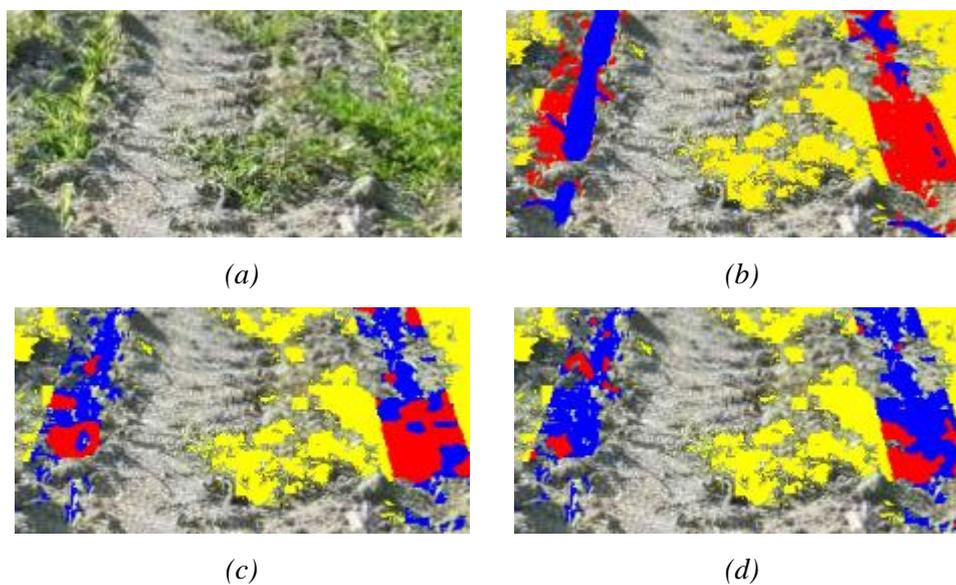


Fig. 4.12 Ejemplos del *ground-truth*; (a) sub-imagen *RGB*; (b) sub-imagen manualmente etiquetada por un experto utilizando tres colores: malas hierbas inter-líneas en amarillo, intra-línea en rojo y cultivo en azul. Clasificación automática de la sub-imagen aplicando dos medidas de similitud: (c) la distancia de Mahalanobis y (d) la distancia Euclidiana.

La evaluación de la clasificación se realizó analizando la matriz de confusión y calculando la tasa de exactitud y el coeficiente Kappa (Bossu et al., 2009; Castillejo-González et al. 2009). La tasa de exactitud es la proporción entre el número de píxeles clasificados correctamente y el número total de píxeles, la cual se define como sigue:

$$exactitud = \frac{TP + TN}{TP + FP + TN + FN} \quad (4.8)$$

Los símbolos *T* y *F* significan verdadero y falso respectivamente, *P* y *N* significan positivos y negativos. Así, *TP* y *TN* son verdaderos positivos y verdaderos negativos respectivamente; *FP* y *FN* son falsos positivos y falsos negativos respectivamente.

El coeficiente Kappa (*k*) indica si los resultados obtenidos en la matriz de

confusión son significativamente mejor que los producidos en una clasificación al azar (Congalton, 1991). Este valor se sitúa en el rango [0, 1], de suerte que el valor uno representa el mejor resultado.

En promedio, se obtuvo una tasa de exactitud de 90.1% aplicando la distancia de Mahalanobis con filtrado de mayoría de tamaño 7×7 en las imágenes probadas (Tabla 4.1). Utilizando los tamaños de filtro de 5×5 y 3×3 se obtuvieron los valores de 85.92% y 82.23% respectivamente.

Tabla 4.1 Exactitud promedio (%) y coeficiente Kappa (*k*) para los clasificadores de Mahalanobis y Euclidiano.

Clasificador	Filtro	Exactitud (%)	Kappa (<i>k</i>)
Mahalanobis	7x7	90.1	0.76
	5x5	85.92	0.69
	3x3	82.23	0.61
Euclidiana	7x7	83.91	0.63
	5x5	80.78	0.57
	3x3	75.80	0.49

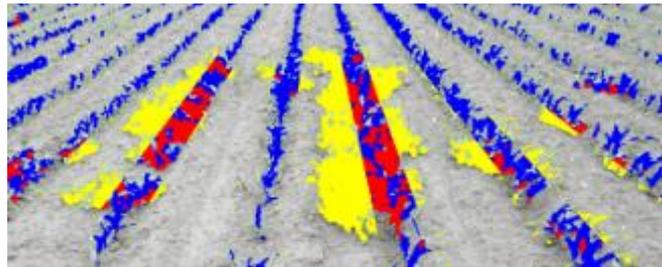
En promedio, los coeficientes Kappa (*k*) para la distancia de Mahalanobis con filtrado de mayoría para los tamaños 7×7, 5×5 y 3×3 fueron 0.76, 0.69 y 0.61 respectivamente. Todos los valores de los coeficientes estimados poseen un grado de acuerdo considerable, según la escala propuesta por Landis y Koch (1977) en la Tabla 4.2.

Tabla 4.2 Grado de acuerdo asociado con el estadístico Kappa (Landis & Koch, 1977).

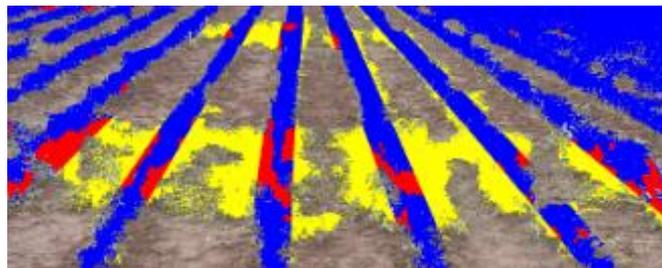
Estadístico Kappa	Grado de acuerdo
< 0.00	Pobre
0.00 – 0.20	Leve
0.21 – 0.40	Aceptable
0.41 – 0.60	Moderado
0.61 – 0.80	Considerable
0.81 – 1.00	Casi perfecto

El filtrado con tamaño 7×7 superó los resultados en ambas medidas: exactitud (90.1%) y coeficiente Kappa (*k* = 0.76). Esto se debe a que se generan regiones compactas más significativas, que facilitan la cuantificación de las malas hierbas para la aplicación de tratamientos selectivos. La Fig. 4.13 muestra tres imágenes de ejemplo

con la identificación del cultivo/malas hierbas utilizando la distancia de Mahalanobis y filtrado de mayoría con tamaño 7×7 a partir de las imágenes de la Fig. 4.1. El método de clasificación propuesto con vecindad de 7×7 manifiesta un buen comportamiento, satisfaciendo los requerimientos de valores comúnmente aceptados, es decir, superior al 85% en la exactitud (Foody, 2002) y mayor a 0.70 en el coeficiente Kappa (Montserud & Leamans, 1992).



(a)



(b)



(c)

Fig. 4.13 Ejemplos de imágenes con la identificación del cultivo/malas hierbas utilizando la distancia de Mahalanobis y filtrado de mayoría con tamaño 7×7 a partir de las imágenes de la Fig. 4.1. Plantas de cultivo están etiquetadas en azul, malas hierbas intra-línea en rojo e inter-líneas en amarillo.

El paso de refinamiento utilizando el filtrado de mayoría mejoró significativamente la exactitud de la clasificación inicial en las imágenes probadas. En promedio, se consiguió una mejora cercana al 10% con respecto a los resultados obtenidos sin su aplicación. La explicación se encuentra en la disminución de píxeles clasificados incorrectamente (falsos negativos) que pertenecen a los bordes de las hojas

de maíz y las áreas sombreadas, las cuales son típicas en los entornos agrícolas y en particular en los campos de maíz donde se manifiestan claramente estos fenómenos. La Fig. 4.14 muestra un ejemplo de clasificación. En (a) una sub-imagen *RGB*; (b) y (c) sin y con refinamiento, respectivamente.

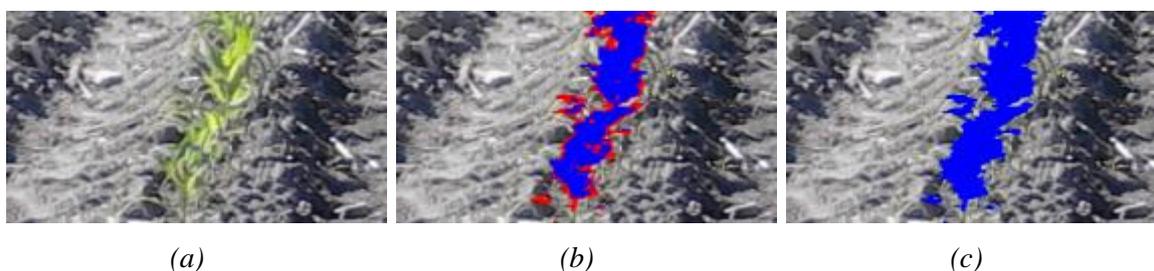


Fig. 4.14 Ejemplos de clasificaciones; (a) sub-imagen *RGB*; (b) y (c) sin y con refinamiento, respectivamente.

El método propuesto utilizando la distancia de Mahalanobis se comparó con el mismo método utilizando la distancia Euclidiana, Figs. 4.10 y 4.12 (c, d). Los resultados relativos a la tasa de exactitud en las imágenes probadas se muestran en la Tabla 4.1. En promedio se obtuvieron tasas del 83.91%, 80.78% y 75.80% aplicando la distancia Euclidiana con filtrado de mayoría y tamaños de ventana de vecindad 7×7 , 5×5 y 3×3 respectivamente. El resultado del filtrado para tamaño 7×7 también superó los resultados con respecto a las otras dos vecindades de menor tamaño, al igual que sucedió con la distancia de Mahalanobis. Los valores del coeficiente Kappa (k) con filtrado de mayoría para tamaños 7×7 , 5×5 y 3×3 fueron 0.63, 0.57 y 0.49 respectivamente. Estos tres valores no satisfacen los valores comúnmente aceptados respecto a la exactitud ($\geq 85\%$) y coeficiente Kappa (≥ 0.70), a diferencia del clasificador de Mahalanobis con tamaño 7×7 .

A partir de los resultados mostrados en la Tabla 4.1, se deduce que la aplicación de la distancia de Mahalanobis superó a la utilización de la Euclidiana. Este hallazgo está en concordancia con los resultados reportados por Castillejo-González et al. (2009) y se explica por el hecho de que las componentes espectrales correspondientes a las clases del cultivo y malas hierbas se distribuyen geoméricamente en agrupaciones elipsoidales (Fig. 8), siendo además que las componentes espectrales *R*, *G*, *B* de los píxeles que pertenecen a la vegetación poseen un cierto grado de correlación. La distancia de Mahalanobis toma en cuenta este hecho.

De aquí en adelante, el método propuesto para la discriminación de

cultivo/malas hierbas se denota por ODMD (*Online discrimination by Mahalanobis distance*). Su rendimiento fue también comparado con tres métodos existentes: (i) SVM (*Support Vector Machines*) propuesto por Guerrero et al. (2012); (ii) AES propuesto por Montalvo et al. (2013a) aplicando una doble umbralización y operaciones morfológicas; y (iii) LVQ propuesto por Montalvo et al. (2012b) usando una doble umbralización y LVQ (*Learning Vector Quantization*). Todos los métodos fueron implementados en Matlab. La Tabla 4.3 muestra los porcentajes de aciertos (exactitud) obtenidos por los métodos mencionados en las imágenes probadas. A partir de estos resultados, se puede observar que ODMD (90.1%) supera a LVQ, tiene un valor similar a SVM y es ligeramente inferior a AES. Además, ODMD posee dos ventajas importantes frente a los tres enfoques existentes: (i) la fase de entrenamiento se realiza en línea (Fig. 4.7a, b), a diferencia de los métodos SVM, AES, y LVQ donde se requiere un entrenamiento exhaustivo previo a la toma de decisión durante la clasificación; (ii) la fase de pruebas identifica separadamente ambos tipos de malas hierbas: inter- e intra-línea (Fig. 4.10a).

Tabla 4.3 Porcentaje promedio de aciertos obtenidos por los métodos SVM, LVQ, AES y ODMD (*Online discrimination by Mahalanobis distance*)

% Aciertos	SVM	LVQ	AES	ODMD
Promedio	90.3	89.2	91.9	90.1
Ranking	2	4	1	3

El coste computacional del clasificador basado en la distancia de Mahalanobis fue también cuantificado. La Tabla 4.4 muestra el tiempo promedio de procesamiento en porcentaje (%) y milisegundos (ms) para cada módulo del ODMD (segmentación, entrenamiento y pruebas). El tiempo de ejecución para el proceso completo fue de 280 ms. El módulo de segmentación consume el 43.5% del tiempo total, el de entrenamiento 15.4% y el de pruebas 41.0%. El enfoque de Mahalanobis resultó ser, en promedio, un 12% más costoso computacionalmente que el Euclidiano. Esto se debe a las operaciones matemáticas extras requeridas para calcular las matrices de covarianza (Ecs. 4.3 y 4.4).

Respecto al tiempo de procesamiento, en el proyecto RHEA (2014) se estableció que el tractor navegue a una velocidad de 6 Km/h como máximo, por lo que cada imagen debe ser procesada con tiempos inferiores a 1.8 s. Así, el enfoque propuesto (ODMD), incluyendo el proceso previo de detección de líneas de cultivo, estaría por debajo del tiempo de procesamiento requerido.

Tabla 4.4 Tiempo promedio de procesamiento en porcentaje (%) y milisegundos (ms) para cada módulo del ODMD.

Módulos	Mahalanobis		Euclidiano	
	%	(ms)	%	(ms)
1 Segmentación	43.5	122	48.8	122
2 Entrenamiento	15.4	43	12.8	32
3 Pruebas	41.0	115	38.4	96
TOTAL	100.0	280	100.0	250

Finalmente, respecto a las limitaciones del método ODMD, se deben considerar dos restricciones para su aplicación: (i) el método requiere previamente del proceso de detección de líneas de cultivo y (ii) la aplicación en etapas iniciales de crecimiento (hasta 40 días), de lo contrario, las hojas de maíz se extienden más allá de los márgenes del cultivo, lo cual puede ser identificado incorrectamente como malas hierbas interlíneas, disminuyendo el rendimiento del método.

CAPÍTULO 5

Conclusiones y trabajo futuro

5.1 Conclusiones

Respecto a los sistemas de visión por computador:

Los sistemas de visión por computador instalados a bordo de vehículos agrícolas (autónomos o para asistencia) resultan útiles y relevantes para la realización de diferentes tareas en agricultura, particularmente en agricultura de precisión. La elección apropiada de estos sistemas constituye una garantía adicional para realizar tareas exitosas en los entornos agrícolas. Tres asuntos se deben considerar de forma especial con tal propósito: (i) selección de la banda espectral, para identificar elementos significativos (plantas, suelo, hojas, enfermedades, plagas); (ii) sensor de imagen y sistema óptico, para mapear la escena 3D en imágenes 2D con suficiente calidad, evitando o eliminando efectos indeseados (tal como el *vignetting*), y (iii) geometría del sistema, para proyectar áreas específicas 3D con suficiente resolución en la imagen 2D y que permita discriminar los objetos principalmente cultivos y malas hierbas.

En agricultura de precisión, dos tareas son comunes y de gran notabilidad en el campo: (i) la discriminación entre cultivo y malas hierbas y (ii) la detección de líneas de cultivo. La primera es útil para la cuantificación de las malas hierbas y la aplicación de tratamientos selectivos con la cantidad de productos o intensidad requerida. La segunda para el guiado autónomo de vehículos agrícolas, la eliminación de las malas hierbas existentes entre las líneas de cultivo, y el análisis del suelo o cultivo utilizando sensores adicionales. Estos problemas pueden abordarse mediante el uso y procesamiento de imágenes provenientes de cultivos en etapas iniciales de crecimiento, bajo la proyección cenital y en perspectiva, principalmente. Las imágenes son adquiridas mediante un sistema de visión a color o en escala de grises provenientes del espectro visible e infrarrojo cercano (*NIR*) respectivamente, las cuales se obtienen mayoritariamente en el modelo de color *RGB* y en menor medida en otros como el *HSI* y *YUV*, que en cualquier caso requieren las transformaciones pertinentes entre espacios de color.

Los métodos existentes en la literatura abordan adecuadamente la detección de líneas rectas de cultivo, aun bajo consideraciones de procesamiento en tiempo real, si bien de forma limitada en presencia de líneas curvadas, que están presentes en ciertas regiones con terrazas o parcelas con forma irregular. La elección de una determinada

técnica se debe evaluar para el contexto de aplicación, con sus bondades y limitaciones, y prestando especial atención a otros factores, tales como niveles aceptables de precisión, aplicación en tiempo real, entornos no controlados de iluminación (que son los existentes en campos de cultivo), número de líneas de cultivo a detectar, espaciado entre las líneas, disponibilidad de ejemplos para el entrenamiento y/o pruebas, entre otros.

En los trabajos existentes para la identificación del cultivo y malas hierbas, existe una cierta tendencia por discriminar, en una primera etapa, la vegetación y el suelo, y en una segunda etapa, el cultivo y las malas hierbas una vez que las plantas han sido segmentadas del suelo, basándose mayoritariamente en el color y en menor medida en el análisis de otras características relevantes como la textura y forma de la hoja o planta. Algunas fuentes de error en esta tarea provienen de la alta similitud en la firma espectral entre cultivo y malas hierbas, sobreexposición de la cámara, no uniformidad en los bordes de las líneas de cultivo y estado de crecimiento de las plantas. Estos factores afectan directamente a los resultados en términos de precisión y tiempo de respuesta.

En relación a la detección de líneas de cultivo:

En esta investigación se proponen dos nuevos métodos de visión por computador para la detección de líneas de cultivo rectas y curvas en campos de maíz basados en (i) la acumulación de píxeles verdes (DAGP) y (ii) el concepto de micro-ROIs (DBMR) para etapas iniciales de crecimiento de cultivos y malas hierbas, es decir, hasta 40 días, donde las hojas no ocluyen el suelo y las alineaciones de las líneas de cultivo puedan distinguirse del suelo. Los métodos constan de tres fases secuenciales: segmentación, identificación de puntos de inicio y detección de líneas de cultivo. DAGP y DBMR logran un similar o mejor rendimiento que otras estrategias existentes para la detección de líneas de cultivo espaciadas regularmente, y superan notablemente a cualquier de ellas en campos con surcos espaciados irregularmente. Los procedimientos pueden también detectar líneas de cultivo rectas y curvas coexistiendo en la misma imagen. La detección de las líneas curvas con las irregularidades mencionadas constituye un aporte fundamental a la investigación.

Los métodos propuestos son robustos bajo condiciones de iluminación no controlados (día soleado, oscuro y claro, Fig. 3.1 d-f) utilizando una cámara instalada en el frente de un tractor en proyección en perspectiva. DAGP y DBMR trabajan

satisfactoriamente con plantas bajo diferentes etapas de crecimiento (cobertura), incluyendo malas hierbas distribuidas irregularmente entre las líneas de cultivo, así como también con líneas incompletas (Figs. 3.1c y 3.23). Las líneas de cultivo rectas y curvas se modelan matemáticamente por medio de sus respectivas ecuaciones para cada tipo de línea. La métrica CRDA (*Crop Row Detection Accuracy*) se utiliza para la evaluación. Valores cercanos a la unidad indican el mejor rendimiento. DAGP y DBMR trabajan apropiadamente sobre líneas rectas de cultivo ($CRDA_{(DBMR)} > 0.92$ y $CRDA_{(DAGP)} > 0.91$ según la Tabla 3.1), líneas de cultivo espaciadas regularmente ($CRDA_{(DBMR)} > 0.90$ y $CRDA_{(DAGP)} > 0.86$ en la Tabla 3.2) y líneas de cultivo espaciadas irregularmente ($CRDA^*_{(DBMR)} > 0.86$ y $CRDA^*_{(DAGP)} > 0.85$ en la Tabla 3.3) con la concavidad orientada hacia la izquierda o derecha (no simultáneamente, Fig. 3.22), y con tiempos de procesamiento aceptables (≤ 637 ms para DBMR y ≤ 721 ms para DAGP en la Tabla 3.6).

Referente a la discriminación de cultivo y malas hierbas:

Se propone un nuevo método de visión por computador (ODMD) para la discriminación del cultivo y las malas hierbas a partir del proceso de detección de líneas de cultivo, utilizando imágenes adquiridas sobre campos de maíz en etapas iniciales de crecimiento (como en el caso anterior hasta 40 días), a través de una cámara a color instalada en la parte frontal de un tractor bajo la proyección en perspectiva. El método se basa en la utilización de la distancia de Mahalanobis como medida de similitud espectral y consta de tres fases secuenciales: segmentación, entrenamiento y pruebas, Fig. 4.3. Si bien, en lo que respecta al entrenamiento éste se lleva a cabo en cada imagen sin necesidad de realizar entrenamientos al modo de los métodos de clasificación clásicos.

El procedimiento propuesto es adecuado bajo diferentes condiciones de iluminación y densidades de malas hierbas (Fig. 4.1), las cuales aparecen distribuidas irregularmente en el campo, identificando claramente los cultivos y dos formas de ubicación de malas hierbas inter- e intra-línea (Fig. 4.13).

El enfoque de la distancia de Mahalanobis supera al Euclidiano (Fig. 4.10) con un ligero tiempo extra de procesamiento. El filtrado de mayoría con tamaño 7×7 trabaja apropiadamente, obteniendo resultados satisfactorios con una exactitud del 90.1% y un coeficiente Kappa de 0.76 (Tabla 4.1), cumpliendo los requerimientos de valores comúnmente aceptados (Tabla 4.2). El rendimiento del método propuesto está en

concordancia con los tres procedimientos indicados en la Tabla 4.3, con resultados aceptables y tiempos de procesamiento inferiores a 280 ms (Tabla 4.4).

5.2 Trabajo futuro

En cuanto a la detección de líneas de cultivo:

Aún son posibles algunas mejoras, que se resumen como sigue: (i) la identificación de puntos de inicio, que representa un paso crucial dentro del proceso de localización de líneas de cultivo; (ii) la detección de líneas curvadas orientadas hacia la izquierda o derecha, sin el conocimiento *a priori* de la orientación; (iii) la cuantificación de la densidad de malas hierbas en el espacio inter-líneas, siguiendo las ideas propuestas en el proyecto RHEA (2014); (iv) la implementación de los métodos propuestos utilizando un lenguaje de programación compilado y una plataforma y sistema operativo en tiempo real. Además, considerando que los procedimientos trabajan en cada imagen sin dependencia de las imágenes anteriores ya procesadas, se podría explotar el hecho de que dos imágenes consecutivas, que pertenecen a dos ROIs contiguas, contienen líneas de cultivo con similar orientación. Así que, (v) una vez que las cuatro líneas de cultivo se han detectado en una imagen, esta información se utilice para guiar la detección de las líneas de cultivo en la próxima imagen, bajo la presunción de una mínima variación. Finalmente, otro tema a considerar en este apartado es (vi) el uso de la información proporcionada por el GPS, como en el proyecto RHEA, donde la imagen a procesar sea capturada después de que el tractor haya recorrido el largo de la ROI (5 m) basándose en las coordenadas GPS.

Respecto a la discriminación de cultivo y malas hierbas:

Se debe considerar que el tiempo de ejecución fue medido en Matlab utilizando un lenguaje de programación interpretado. El tiempo puede disminuir significativamente implementando el ODMD en un lenguaje de programación compilado (por ejemplo C++) y ejecutándose en una plataforma y sistema operativo de tiempo real, por ejemplo *LabView* y *CRio* como en el proyecto RHEA (2014). Bajo esta implementación el tiempo de procesamiento podría reducirse cerca del 40%, como se reportó en RHEA, mejorando considerablemente el rendimiento del método, lo que entraría dentro de los parámetros manejados en aplicaciones de tiempo real. Además, se sugiere la identificación de varias especies de plantas a través del análisis de otras

características como la textura y la forma de la hoja o de la planta; así como también el desarrollo de algoritmos paralelos aprovechando las ventajas que ofrece el paralelismo en las arquitecturas con varios núcleos y subprocesos.

Referencias

- Ahmed, F., Al-Mamun, H.A., Bari, A.H., Hossain, E., Kwan, P. (2012). Classification of crops and weeds from digital images: a support vector machine approach. *Crop Protection*, 40, 98–104.
- Astrand, B., Baerveldt, A. J. (2005). A vision based row-following system for agricultural field machinery. *Mechatronics*, 15(2), 251-269.
- Bakker, T., Wouters, H., van Asselt, K., Bontsema, J., Tang, L., Müller, J., et al. (2008). A vision based row detection system for sugar beet. *Computers and Electronics in Agriculture*, 60, 87–95.
- Bakker, T., van Asselt, K., Bontsema, J., Muller, J., van Straten, G. (2011). Autonomous navigation using a robot platform in a sugar beet field. *Biosystems Engineering*, 109(4), 357-368.
- Ballard, D. H. (1981). Generalizing the Hough transform to detect arbitrary shapes. *Pattern Recognition*, 13(2), 111-122.
- Barnard, S., Fishler, M. (1982). Computational stereo. *ACM Computing Surveys (CSUR)*, 14(4), 553–572.
- Barreda, J., Ruíz, A., Ribeiro, A. (2009). *Seguimiento visual de líneas de cultivo (visual tracking of crop rows)*. Thesis Master, Universidad de Murcia, Spain. Disponible en línea: <https://digitum.um.es/xmlui/bitstream/10201/22175/1/myPFC.pdf> (accedido el 12 de Enero 2017)
- Bengochea-Guevara, J. M., Conesa-Muñoz, J., Ribeiro, Á. (2012). *Developing a small autonomous robot for crop inspection*. Proc. Technology, Automation and Precision Farming. International Conference of Agricultural Engineering-CIGR-AgEng 2012: Agriculture and Engineering for a Healthier Life.
- Billingsley, J., Schoenfish, M. (1997). The successful development of a vision guidance system for agriculture. *Computers and Electronics in Agriculture*, 16(2), 147-163.
- Bockaert, V. (2002). Sensor sizes. *Digital Photography Review*. Disponible en línea: <https://www.dpreview.com/articles/8095816568/sensorsizes> (accedido el 26 de Enero 2017).
- Bossu, J., Gée, Ch., Jones, G., y Truchetet, F. (2009). Wavelet transform to discriminate between crop and weed in perspective agronomic images. *Computers and Electronics in Agriculture*, 65, 133–143.
- Brosnan, T., Sun, D.-W. (2002). Inspection and grading of agricultural and food products by computer vision systems -a review. *Computers and Electronics in Agriculture*, 36(2), 193-213.
- Burgos-Artizzu, X.P., Ribeiro, A., Tellaeché, A., Pajares, G., Fernández-Quintanilla, C. (2009). Improving weed pressure assessment using digital images from an experience-based reasoning approach. *Computers and Electronics in Agriculture*, 65, 176–185.
- 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.
- Camargo-Neto, J. (2004). *A Combined Statistical-Soft Computing Approach for Classification and Mapping Weed Species in Minimum Tillage Systems*. University of Nebraska, Lincoln, NE.
- Cambridge in Colour. (2017). Disponible en línea: <http://www.cambridgeincolour.com/tutorials/camera-exposure.htm> (accedido el 26 de Enero 2017).

- Campos, Y., Sossa, H., Pajares, G. (2016). Spatio-temporal analysis for obstacle detection in agricultural videos. *Applied Soft Computing*, 45, 86–97.
- Castillejo-González, I.L., López-Granados, F., García-Ferrer, A., Peña-Barragán, J.M., Jurado-Expósito, M., Sánchez De La Orden, M. & González De Audicana, M. (2009). Object and pixel-based classification for mapping crops and their agri-environmental associated measures in QuickBird images. *Computers and Electronics in Agriculture*, 68, 207-215.
- 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, 195–207.
- Chou, J.J., Chen, C.P., Yeh, J.T. (2007). Crop identification with wavelet packet analysis and weighted Bayesian distance. *Computers and Electronics in Agriculture*, 57 (1), 88–98.
- Congalton, R.G. (1991). A review of assessing the accuracy of classification of remotely sensed data. *Remote Sensing of Environment*, 37, 35-46.
- Conesa-Muñoz, J., Gottschalk, R., Burgos-Artizzu, X., Ribeiro, A. (2011). *Método de detección visual de líneas de cultivo para el control en dirección de vehículos agrícolas (Visual detection method of crop rows for controlling agricultural vehicles)*. Proc. Conferencia de la Asociación Española para la Inteligencia Artificial (CAEPIA 2011). Computer Vision in Natural Environments: agriculture and forestry (CVNE). , Universidad de la Laguna (Tenerife), Spain. 10 pages.
- Conesa-Muñoz, J., 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.
- Cuevas, E., Zaldívar, D., Pérez, M. (2010). *Procesamiento digital de imágenes con Matlab y Simulink (Digital image processing with Matlab and Simulink)*. Ra-Ma Editorial, Madrid, Spain.
- Davies, E. R. (2004). *Machine Vision: Theory, Algorithms, Practicalities*. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA.
- Davies, E. (2009). The application of machine vision to food and agriculture: a review. *The Imaging Science Journal*, 57(4), 197-217.
- De la Fuente, E., Trespaderne, F. (2012). *Visión artificial industrial: Procesamiento de imágenes para inspección automática y robótica (Industrial Machine Vision: Image Processing for automatic inspection and robotic)*. Secretariado de publicaciones e intercambio editorial, Universidad de Valladolid. Valladolid, Spain.
- Duda, R. O., Hart, P. E. (1972). Use of the Hough transformation to detect lines and curves in pictures. *Magazine Communications of the ACM*, 15(1), 11-15.
- Duda, R.O., Hart, P.E., Stork, D.G. (2001). *Pattern Classification*. John Wiley & Sons, New York.
- Edmund of Optics (2017). Optical Filters. Disponible en línea: <https://www.edmundoptics.com/resources/application-notes/optics/optical-filters/#guide> (accedido el 15 de Febrero 2017).
- Emmi, L., Gonzalez-de-Soto, M., Pajares, G., Gonzalez-de-Santos, P. (2014a). Integrating Sensory/Actuation Systems in Agricultural Vehicles. *Sensors*, 14, 4014-4049.
- Emmi, L., Gonzalez-de-Soto, M., Pajares, G., Gonzalez-de-Santos, P. (2014b). New Trends in Robotics for Agriculture: Integration and Assessment of a Real Fleet of Robots. *The Scientific World Journal*, vol. 2014, Article ID 404059, 21 pages.
- Farooque, A.A., Chang, Y.K., Zaman, Q.U., Groulx, D., Schumann, A.W., Esau, T.J. (2012).

- Performance evaluation of multiple ground based sensors mounted on a commercial wild blueberry harvester to sense plant height, fruit yield and topographic features in real-time. *Computers and Electronics in Agriculture*, 84, 85–91.
- Foody, G.M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1), 185-201.
- Fontaine, V., Crowe, T. (2006). Development of line-detection algorithms for local positioning in densely seeded crops. *Canadian Biosystems Engineering*, 48, 19-29.
- García-Santillán, I., Caranqui, V. (2014). La Visión artificial y los campos de aplicación. *Tierra Infinita*, Nº 4, pp. 142-150. ISSN 1390-6836.
- García-Santillán, I., Pajares, G. (2016). Detección automática de líneas de cultivo: estado del arte y futuras perspectivas. En F. Rivas, S. Arciniegas, & C. P. U. Andes (Ed.), *Avances y aplicaciones de sistemas inteligentes y nuevas tecnologías* (pp. 381-398). Mérida, Venezuela: Gráficas el Portatítulo. Disponible en línea: http://www.pucesi.edu.ec/congreso_coisint/ (accedido el 28 de Enero 2017)
- García-Santillán, I., Guerrero, M., Montalvo, M., Pajares, G. (2017a). Curved and straight crop row detection by accumulation of green pixels from images in maize fields. *Precision Agriculture*. DOI: 10.1007/s11119-016-9494-1
- García-Santillán, I., Montalvo, M., Guerrero, M., Pajares, G. (2017b). Automatic detection of curved and straight crop rows from images in maize fields. *Biosystems Engineering*. DOI: 10.1016/j.biosystemseng.2017.01.013
- Gée, C., Bossu, J., Jones, G., Truchetet, F. (2008). Crop/weed discrimination in perspective agronomic images. *Computers and Electronics in Agriculture*, 60(1), 49-59.
- GPC (2011). *Plan de desarrollo y ordenamiento territorial del Carchi*. Disponible en línea: [http://www.carchi.gob.ec/ley_transparencia/2013/s\)plandedesarrollo.pdf](http://www.carchi.gob.ec/ley_transparencia/2013/s)plandedesarrollo.pdf) (accedido el 25 de Enero 2017)
- Gonzalez, R., Woods, R. (2010). *Digital Image Processing* (3 Ed.). Pearson/Prentice Hall, Upper Saddle River, N. J., USA.
- Gonzalez-de-Santos, P., Ribeiro, A., Fernandez-Quintanilla, C., López-Granados, F., Brandstötter, M., Tomic, S., Pedrazzi, S., Peruzzi, A., Pajares, G., Kaplanis, G., et al. (2016). Fleets of robots for environmentally-safe pest control in agriculture. *Precision Agriculture*, 1-41.
- Guerrero, J. M., Pajares, G., Montalvo, M., Romeo, J., Guijarro, M. (2012). Support Vector Machines for crop/weeds identification in maize fields. *Expert Systems with Applications*, 39, 11149-11155.
- Guerrero, J. M., Guijarro, M., Montalvo, M., Romeo, J., Emmi, L., Ribeiro, A., et al. (2013). Automatic expert system based on images for accuracy crop row detection in maize fields. *Expert Systems with Applications*, 40(2), 656-664.
- Guijarro, M., Pajares, G., Riomoros, I., Herrera, P. J., Burgos-Artizzu, X. P., Ribeiro, A. (2011). Automatic segmentation of relevant textures in agricultural images. *Computers and Electronics in Agriculture*, 75(1), 75-83.
- Guijarro, M., Riomoros, I., Pajares, G., Zitinski, P. (2015). Discrete wavelets transform for improving greenness image segmentation in agricultural images. *Computers and Electronics in Agriculture*, 118(1), 396-407.
- Hague, T., Tillett, N. D. (2001). A bandpass filter-based approach to crop row location and tracking. *Mechatronics*, 11, 1-12.
- Hague, T., Tillett, N. D., Wheeler, H. (2006). Automated Crop and Weed Monitoring in Widely Spaced Cereals. *Precision Agriculture*, 7(1), 21-32.

- Han, Y. H., Wang, Y. M., Kang, F. (2012). *Navigation line detection based on support vector machine for automatic agriculture vehicle*. In: Proceedings of the International Conference on Automatic Control and Artificial Intelligence (ACAI 2012), [Institution of Engineering and Technology (IET), Xiamen, China], pp 1381-1385.
- Hough, P. V. C. (1962). *Method and means for recognizing complex patterns*. US Patent Office No. 3069654.
- Ishak, A.J., Hussain, A., Mustafa, M.M. (2009). Weed image classification using Gabor wavelet and gradient field distribution. *Computers and Electronics in Agriculture*. 66 (1), 53–61.
- Jafri, M., Deravi, F. (1995). Efficient algorithm for the detection of parabolic curves, In: *Proceedings of the SPIE 2356, Vision Geometry III*, pp 53-61.
- Jeon, H.Y., Tian, L.F., Zhu, H. (2011). Robust Crop and Weed Segmentation under Uncontrolled Outdoor Illumination. *Sensors*, 11, 6270–6283.
- Ji, R., Qi, L. (2011). Crop-row detection algorithm based on Random Hough Transformation. *Mathematical and Computer Modelling*, 54(3-4), 1016-1020.
- Jiang, G., Wang, X., Wang, Z. (2016). Wheat rows detection at the early growth stage based on Hough transform and vanishing point. *Computers and Electronics in Agriculture*, 123, 211-223.
- Jiang, G., Wang, Z., Liu, H. (2015). Automatic detection of crop rows based on multi-ROIs. *Expert Systems with Applications*, 42(5), 2429-2441.
- Jones, D.R., Perttunen, C.D., Stuckman, B.E. (1993). Lipschitzian optimization without the Lipschitz constant. *Journal of Optimization Theory and Applications*. 79, 157–181.
- Jones, G.; Gée, Ch.; Truchetet, F. (2009). Assessment of an inter-row weed infestation rate on simulated agronomic images. *Comput. Electron. Agric.*, 67, 43–50.
- Kataoka, T., Kaneko, T., Okamoto, H., Hata, S. (2003). Crop growth estimation system using machine vision. *Proceedings of the IEEE International Conference on Advanced Intelligent Mechatronics (AIM 2003)*, 1079-1083.
- Kise, M., Zhang, Q. (2008). Development of a stereovision sensing system for 3D crop row structure mapping and tractor guidance. *Biosystems Engineering*, 101(2), 191-198.
- 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.
- Landis, J.R., Kock, G.G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33, 159-174.
- Leemans, V., Destain, M.F., (2006). Line cluster detection using a variant of the Hough transform for culture row localisation. *Image Vision Computing*, 24(5), 541–550.
- Li, M., Imou, K., Wakabayashi, K., Yokoyama, S. (2009). Review of research on agricultural vehicle autonomous guidance. *International Journal of Agricultural and Biological Engineering (AJABE)*, 2, 1–26.
- Linker, R., Cohen, O., Naor, A. (2012). Determination of the number of green apples in RGB images recorded in orchard. *Computers and Electronics in Agriculture*, 81, 45–57.
- López-Granados, F. (2011). Weed detection for site-specific weed management: Mapping and real-time approaches. *Weed Research*, 51, 1–11.
- Mahalanobis, P. (1936). On the generalized distance in statistics. *Proceedings of the National Institute of Science*, 2(1), 49-55.
- Maltsev, A.I. (1962). *Weed vegetation of the USSR and measures of its control*. Leningrad-Moscow: Selkhozizdat. 272 p. (in Russian).

- Marchant, J. (1996). Tracking of row structure in three crops using image analysis. *Computers and Electronics in Agriculture* 15(2), 161–179.
- MathWorks, Inc. (2015). *Matlab Release 2015a*. http://www.mathworks.com/products/new_products/release2015a.html (Accedido el 10 de Febrero 2017).
- Meyer, G.E., Hindman, T.W., Lakshmi, K. (1998). Machine Vision Detection Parameters for Plant Species Identification. *SPIE*, Bellingham, WA.
- Meyer, G.E., Camargo-Neto, J. (2008). Verification of color vegetation indices for automated crop imaging applications. *Computers and Electronics in Agriculture*, 63, 282–293.
- Montalvo, M., Pajares, G., Guerrero, J. M., Romeo, J., Guijarro, M., Ribeiro, A., et al. (2012a). Automatic detection of crop rows in maize fields with high weeds pressure. *Expert Systems with Applications*, 39(15), 11889-11897.
- Montalvo, M., Guerrero, J., Romeo, J., Oliva, D., Guijarro, M., Pajares, G. (2012b). Unsupervised learning for crop/weeds discrimination in maize fields with high weeds densities. *Proceedings of the International Conference of Agricultural Engineering (CIGR-AgEng2012)*, Valencia Spain, pp. 1-5.
- Montalvo, M., Guerrero, J. M., Romeo, J., Emmi, L., Guijarro, M., Pajares, G. (2013a). Automatic expert system for weeds/crops identification in images from maize fields. *Expert Systems with Applications*, 40(1), 75-82.
- Montalvo, M., Guerrero, J.M., Romeo, J., Guijarro, M., de la Cruz, J.M., Pajares, G. (2013b). Acquisition of Agronomic Images with Sufficient Quality by Automatic Exposure Time Control and Histogram Matching. Lecture Notes in Computer Science. *In Proceedings of the Advanced Concepts for Intelligent Vision Systems (ACIVS'13)*, Poznan, Poland; Volume 8192, pp. 37-48.
- Montalvo, M., Guijarro, M., Guerrero, J. M., & Ribeiro, Á. (2016). Identification of Plant Textures in Agricultural Images by Principal Component Analysis. In F. Martínez-Álvarez, A. Troncoso, H. Quintián & E. Corchado (Eds.), *Hybrid Artificial Intelligent Systems: 11th International Conference, HAIS 2016*, Seville, Spain, pp. 391-401. Cham: Springer International Publishing.
- Montserud, R.A., Leamans, R. (1992). Comparing global vegetation maps with the kappa statistic. *Ecological Modelling*, 62, 275-293.
- Moshou, D., Bravo, D., Oberti, R., West, J.S., Ramon, H., Vougioukas, S., Bochtis, D. (2011). Intelligent multi-sensor system for the detection and treatment of fungal diseases in arable crops. *Biosystems Engineering.*, 108, 311–321.
- Nissimov, S., Goldberger, J., Alchanatis, V. (2015). Obstacle detection in a greenhouse environment using the Kinect sensor. *Computers and Electronics in Agriculture*, 113, 104–115.
- Oberti, R., Marchi, M., Tirelli, P., Calcante, A., Iriti, M., Borghese, A.N. (2014). Automatic detection of powdery mildew on grapevine leaves by image analysis: Optimal view-angle range to increase the sensitivity. *Computers and Electronics in Agriculture*, 104, 1–8.
- Ollinger, S.V. (2011). Sources of variability in canopy reflectance and the convergent properties of plants. *New Phytologist.*, 189, 375–394.
- Olsen, H. J. (1995). Determination of row position in small-grain crops by analysis of video images. *Computers and Electronics in Agriculture*, 12(2), 147-162.
- Onyango, C. M., Marchant, J. A. (2003). Segmentation of row crop plants from weeds using colour and morphology. *Computers and Electronics in Agriculture*, 39(3), 141-155.

- Otsu, N. (1979). Threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9(1), 62-66.
- Pajares, G., de la Cruz, J. M. (2008). *Visión por Computador. Imágenes digitales y aplicaciones (Computer Vision. digital images and applications)* (2 ed.). RA-MA Editorial, Madrid, Spain.
- Pajares, G., García-Santillán, I., Campos, Y., Montalvo, M., Guerrero, J.M., Emmi, L., et al. (2016). Machine-Vision Systems Selection for Agricultural Vehicles: A Guide. *Journal of Imaging*, 2, 34.
- Pérez, A. J., López, F., Benlloch, J. V., Christensen, S. (2000). Colour and shape analysis techniques for weed detection in cereal fields. *Computers and Electronics in Agriculture*, 25, 197-212.
- Pla, F., Sanchiz, J. M., Marchant, J. A., Brivot, R. (1997). Building perspective models to guide a row crop navigation vehicle. *Image and Vision Computing*, 15, 465-473.
- Rabatel, G., Gorretta, N., Labbé, S. (2011). Getting NDVI Spectral Bands from a Single Standard RGB Digital Camera: A Methodological Approach. In *Proceedings of the 14th Conference of the Spanish Association for Artificial Intelligence, CAEPIA*. La Laguna, Spain, 7-11 November 2011; Volume 7023, pp. 333-342.
- Ramírez, D. (2013). *Desarrollo de un método de procesamiento de imágenes para la discriminación de maleza en cultivos de maíz (Development of an image processing method for weed discrimination in maize crops)*. Thesis Master, Universidad Autónoma de Querétaro, México. Disponible en línea: <http://ri.uaq.mx/bitstream/123456789/453/1/RI000112.pdf> (accedido el 07 de Febrero 2015)
- Reid, J.F., Searcy, S.W. (1997). Vision-based guidance of an agricultural tractor. *IEEE Control Systems*, 7, 39-43.
- RHEA. (2014). *Proceedings of the Second International Conference on Robotics and Associated High-Technologies and Equipment for Agriculture and Forestry. New trends in mobile robotics, perception and actuation for agriculture and forestry* (P. Gonzalez-de-Santos & A. Ribeiro Eds.). Madrid-Spain: PGM. [Spanish Research Council-CAR] http://www.rhea-project.eu/Workshops/Conferences/Proceedings_RHEA_2014.pdf (accedido el 17 de Enero 2017)
- Ribeiro, A., Fernandez-Quintanilla, C., Barroso, J., & Garcia-Alegre, M. C. (2005). Development of an image analysis system for estimation of weed pressure. *Proceedings of the 5th European Conference on Precision Agriculture (5ECPA)*, pp. 169-174.
- Rodríguez, R. & Sossa, J. (2011). *Procesamiento y análisis digital de imágenes (digital image processing and analysis)*. RA-MA Editorial, Madrid, Spain.
- 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. *Scientific World Journal*. Article ID 484390, 10 pages.
- Romeo, J., Pajares, G., Montalvo, M., Guerrero, J. M., Guijarro, M., de la Cruz, J. M. (2013a). A new Expert System for greenness identification in agricultural images. *Expert Systems with Applications*, 40(6), 2275-2286.
- Romeo, J., Guerrero, J. M., Montalvo, M., Emmi, L., Guijarro, M., Gonzalez-de-Santos, P., Pajares, G. (2013b). Camera sensor arrangement for crop/weeds detection accuracy in agronomic images. *Sensors*, 13, 4348-4366.
- Rong, X., Huanyu, J., Yibin, Y. (2014). Recognition of clustered tomatoes based on binocular stereo vision. *Computers and Electronics in Agriculture*, 106, 75-90.
- Rovira-Más, F., Zhang, Q., Reid, J.F., Will, J.D. (2003). Machine vision based automated

- tractor guidance. *International Journal Smart Engineering System Design*, 5(4), 467-480.
- Rovira-Más, F., Zhang, Q., Reid, J. F. (2008). Stereo vision three-dimensional terrain maps for precision agriculture. *Computers and Electronics in Agriculture*, 60(2), 133-143.
- 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. *Journal of Automobile Engineering*, 219(8), 999-1010.
- Sainz-Costa, N., Ribeiro, A., Burgos-Artizzu, X. P., Guijarro, M., Pajares, G. (2011). Mapping Wide Row Crops with Video Sequences Acquired from a Tractor Moving at Treatment Speed. *Sensors*, 11(7), 7095-7109.
- Schneider Kreuznach (2008). *B+W Filter Tips and Tricks*. Disponible en línea: <http://www.schneiderkreuznach.com/en/photo-imaging/product-field/b-w-fotofilter/products/filtertypes/special-filters/486-uvir-cut/> (accedido el 26 de Enero 2017).
- Schneider Kreuznach (2013). Cinegon 1.9/10 – Ruggedized. Disponible en línea: http://www.schneiderkreuznach.com/fileadmin/user_upload/bu_industrial_solutions/industrieoptik/16mm_Lenses/Compact_Lenses/Cinegon_1.9--10_ruggedized.pdf (accedido el 26 de Enero 2017).
- Senplades (2015). *Agenda Zonal. Zona 1 - Norte*. Disponible en línea: <http://www.planificacion.gob.ec/wp-content/uploads/downloads/2015/11/Agenda-zona-1.pdf> (accedido el 25 de Enero 2017).
- Sogaard, H. T., Olsen, H. J. (2003). Determination of crop rows by image analysis without segmentation. *Computers and Electronics in Agriculture*, 38(2), 141-158.
- Steen, K.A., Christiansen, P., Karstoft, H., Jørgensen, R.N. (2016). Using deep learning to challenge safety standard for highly autonomous machines in agriculture. *Journal of Imaging*, 2(1), 6.
- Svensgaard, J., Roitsch, T., Christensen, S. (2014). Development of a Mobile Multispectral Imaging Platform for Precise Field Phenotyping. *Agronomy*, 4, 322–336.
- SVS-VISTEK (2017). Disponible en línea: <https://www.svs-vistek.com/en/industrial-cameras/svs-camera-detail.php?id=evo4050CFLGEA> (accedido el 30 de Enero 2017).
- Tellaache, A., Burgos-Artizzu, X., Pajares, G., Ribeiro, A., Fernández-Quintanilla, C. (2008a). A new vision-based approach to differential spraying in precision agriculture. *Computers and Electronics in Agriculture*, 60(2), 144-155.
- Tellaache, A., Burgos-Artizzu, X., Pajares, G., Ribeiro, A. (2008b). A vision-based method for weeds identification through the Bayesian decision theory. *Pattern Recognition*, 41(2), 521-530.
- Tellaache, 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.
- Tillett, N., Hague, T. (1999). Computer-vision based hoe guidance for cereals an initial trial. *Journal of Agricultural Engineering Research*, 74, 225–236.
- Tucker, C.J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8, 127–150.
- Vidović, I., Scitovski, R. (2014). Center-based clustering for line detection and application to crop rows detection. *Computers and Electronics in Agriculture*, 109, 212-220.
- Vidović, I., Cupec, R., & Hocenski, Ž. (2016). Crop row detection by global energy minimization. *Pattern Recognition*, 55, 68-86.

- Vioix, J. B., Douzals, J. P., Truchetet, F., Assemat, L., Guillemin, J. P. (2002). Spatial and spectral method for weeds detection and localization. *EURASIP Journal on Advances in Signal Processing*, 7, 679–685.
- Wei, J., Rovira-Mas, F., Reid, J.F., Han, S. (2005). Obstacle detection using stereo vision to enhance safety autonomous machines. *Transactions of the ASAE*, 48, 2389–2397.
- Woebbecke, D. M., Meyer, G. E., Vonbargen, K., Mortensen, D. A. (1995). Color indexes for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*, 38(1), 259-269
- Xue, J., Ju, W. (2010). *Vision-Based Guidance Line Detection in Row Crop Fields*. In: Proceedings of the third IEEE International Conference on Intelligent Computation Technology and Automation (ICICTA 2010), [IEEE Computer Society] vol. 3, 1140-1143.
- Xue, J.; Zhang, L.; Grift, T.E. (2012). Variable field-of-view machine vision based row guidance of an agricultural robot. *Computers and Electronics in Agriculture*, 84, 85–91.