

UNIVERSIDAD AUTÓNOMA DE ZACATECAS



DETECCIÓN DE MALEZAS MEDIANTE EL ANÁLISIS DE IMÁGENES TOMADAS DESDE UN VEHÍCULO AÉREO NO TRIPULADO

Ing. Raikel Bordón López

Tesis de Maestría

presentada a la Unidad Académica de Ingeniería Eléctrica
de acuerdo a los requerimientos de la Universidad para obtener el Grado de

MAESTRO EN CIENCIAS DE LA INGENIERÍA
ORIENTACIÓN: PROCESAMIENTO DE SEÑALES Y MECATRÓNICA

Directores de tesis:

Dr. Francisco Eneldo López Monteagudo y Dr. Carlos Alberto Olvera Olvera

UNIDAD ACADÉMICA DE INGENIERÍA ELÉCTRICA

14 de agosto de 2018

RESUMEN

En este trabajo se propone un método para la detección de malezas en imágenes aéreas de campos agrícolas. Las imágenes fueron obtenidas desde un vehículo aéreo no tripulado con una cámara RGB en un campo de frijol. El objetivo final fue la obtención de un mapa georeferenciado de densidad de malezas a partir de las imágenes obtenidas. El método propuesto consiste en cuatro pasos principales: 1) segmentación de la vegetación, 2) estimación de la orientación media de las filas de cultivos, 3) identificación de las filas de cultivo, y 4) segmentación de las malezas y generación del mapa de densidad de malezas. La detección de malezas se llevó a cabo de manera completamente autónoma, empleando un árbol de decisión como algoritmo de clasificación en la etapa final, pero sin requerir la selección manual de muestras para el entrenamiento. Los resultados obtenidos en la evaluación del desempeño del método propuesto fueron satisfactorios. El modelo de regresión lineal entre las densidades de maleza estimadas y observadas arrojó un coeficiente de determinación de 0.987 y un error cuadrático medio de 0.075. Del área total del campo de estudio, se estimó un 84 % con menos del 1 % de cobertura malezas, lo cual indica un alto potencial para la reducción del volumen de herbicidas aplicados.

Contenido General

	Pag.
Resumen	I
Lista de figuras	IV
Lista de tablas	VI
1. Introducción	1
1.1. Antecedentes	1
1.2. Planteamiento del problema y justificación	3
1.2.1. Hipótesis	4
1.2.2. Objetivo General	4
1.2.3. Objetivos Particulares	5
1.3. Metodología	5
1.4. Estructura de la tesis	5
2. Marco Teórico	7
2.1. Malezas	7
2.1.1. Prevención, control y erradicación de malezas	9
2.2. Tecnologías de visión artificial en la agricultura	10
2.2.1. Segmentación de la vegetación	10
2.2.2. Detección de filas de cultivos	17
2.2.3. Detección de malezas	18
3. Materiales y métodos	20
3.1. Campo agrícola de estudio	20
3.2. Adquisición de las imágenes	22
3.3. Generación del ortomosaico	24
3.4. Análisis de las imágenes	25
3.4.1. Segmentación de la vegetación	27
3.4.2. Estimación de la orientación media de las filas de cultivos	30
3.4.3. Identificación de las filas de cultivos	32
3.4.4. Detección y mapeado de las malezas	33
4. Resultados y discusión	37
4.1. Evaluación de los métodos de segmentación de vegetación	37
4.1.1. Segmentación basada en índices de vegetación	38

	Pag.
4.1.2. Segmentación basada en aprendizaje automático	40
4.2. Evaluación del algoritmo de identificación de las filas de cultivos	42
4.3. Evaluación del algoritmo de detección y mapeado de las malezas	47
Conclusiones	49
Recomendaciones	53
Referencias	54

Lista de figuras

Figura	Pag.
2.1. Segmentación basada en índices de vegetación. (a) Imagen RGB de un campo de cultivo. (b) PDF de los canales R, G y B. (c) Imagen monocromática del índice ExG. (d) PDF del índice ExG.	14
3.1. Sector de una las imágenes aéreas tomadas en el campo agrícola de estudio.	21
3.2. Relación geométrica entre las dimensiones del área del suelo abarcada por la imagen y las dimensiones de la imagen, para una altitud de vuelo h_f y un ángulo de visión de la cámara α_c	23
3.3. Ilustración del concepto de densidad lineal de vegetación.	27
3.4. Diagrama en bloque del sistema de entrenamiento progresivo del clasificador para la segmentación de vegetación basada en aprendizaje automático.	28
3.5. Interfaz de usuario del sistema de entrenamiento progresivo del clasificador para la segmentación de vegetación basada en aprendizaje automático.	29
3.6. Estimación de la orientación media de las filas de cultivos. (a) Máscara de vegetación donde se calcularon cuatro perfiles de vegetación a lo largo de los vectores señalados, todos con el mismo punto de origen q . (b) Perfiles de vegetación calculados.	31
3.7. Enlazado de los picos de vegetación en el algoritmo de identificación de las filas de cultivos.	34
3.8. Asociación de los píxeles de vegetación a las líneas de cultivo y maleza en el algoritmo de detección y mapeado de las malezas.	36
4.1. Sector de una de las imágenes del campo empleado como referencia en la evaluación de los algoritmos de segmentación de vegetación (a) Imagen RGB. (b) Máscara de vegetación correspondiente.	38

Figura	Pag.
4.2. Histogramas de los índices de vegetación calculados para la imagen de referencia (figura 4.1a) (a) Índice de diferencia normalizado (NDI). (b) Índice de exceso de verde (ExG). (c) Índice de exceso de rojo (ExR). (d) Índice de exceso de verde menos rojo (ExGR). (e) Índice vegetativo (VEG). (f) Índice de exceso de verde modificado (MExg).	39
4.3. Factor de calidad de la segmentación en función del umbral de binarización para los métodos de segmentación basados en índices de vegetación.	40
4.4. Estructura del árbol de decisión del método de segmentación basada en aprendizaje automático.	41
4.5. Sector de una de las imágenes del campo empleado como referencia en la evaluación de los algoritmos de segmentación de vegetación (a) Imagen RGB. (b) Máscara de vegetación correspondiente.	43
4.6. Desempeño del algoritmo de identificación de las filas de cultivos para la imagen de la figura 4.5a (a) Factor de calidad de identificación de las filas (Q_r) en función extensión de los perfiles de vegetación (E_p) (b) Factor de calidad de identificación de las filas (Q_r) en función extensión de la distancia estimada entre filas de cultivos (W_r).	45
4.7. Desempeño del algoritmo de identificación de las filas de cultivos para la imagen de la figura 4.5b (a) Factor de calidad de identificación de las filas (Q_r) en función extensión de los perfiles de vegetación (E_p) (b) Factor de calidad de identificación de las filas (Q_r) en función extensión de la distancia estimada entre filas de cultivos (W_r).	46
4.8. Regiones de cultivo y maleza detectadas.	48
4.9. Mapa de densidad de malezas.	49
4.10. Relación entre la densidad de malezas estimada y la observada.	50

Lista de tablas

Tabla	Pag.
2.1. Índices de vegetación	12
3.1. Características técnicas del Phantom 4 Pro.	22
4.1. Parámetros de desempeño de la segmentación basada en aprendizaje automático	41
4.2. Valores de los parámetros de los algoritmos de estimación de la orientación e identificación de las filas de cultivo.	44
4.3. Valores de los parámetros del algoritmo de detección y mapeado de las malezas.	48

Lista de Acrónimos

AP	Agricultura de Precisión
NDI	Índice de diferencia normalizado
ExG	Índice de exceso de verde
ExR	Índice de exceso de rojo
CIVE	Índice de color de extracción de vegetación
ExGR	Índice de exceso de verde menos rojo
VEG	Índice vegetativo
COM1	Índices combinados 1
MExG	Índice de exceso de verde modificado
COM2	Índices combinados 2
PDF	Función de Densidad de Probabilidad
TH	Transformada de Hough
RMSE	Raíz cuadrada del error cuadrático medio

Capítulo 1

Introducción

1.1. Antecedentes

En la actualidad, la agricultura se enfrenta a inmensos retos, dada la necesidad de aumentar la producción de alimentos y la creciente preocupación por los problemas ambientales y el cambio climático. El rendimiento agrícola ha aumentado notablemente durante los últimos 30 años, como resultado de la intensificación en la gestión de los cultivos, así como las mejoras en los sistemas de riego y fertilizantes [1]. Satisfacer la futura demanda de alimentos dependerá, en primer lugar, del crecimiento continuo del rendimiento de las cosechas. Sin embargo, actualmente la tasa de aumento del potencial de rendimiento es mucho menor que el aumento esperado de la demanda [2].

Uno de los enfoques propuestos para resolver estos desafíos es la intensificación sostenible de la agricultura, que tiene como objetivo aumentar la producción de alimentos de las tierras existentes, minimizando el impacto ambiental, para asegurar las necesidades de las generaciones presentes y futuras [3]. El logro de una producción consistente con estos niveles elevados sin causar daños ambientales requiere mejoras en la calidad del suelo y un manejo preciso de todos los factores de producción en el tiempo y el espacio. Por tanto, este progreso requerirá claramente la integración de los principales enfoques en la investigación y el desarrollo de la agricultura.

Dentro de la dimensión técnica de la agricultura sustentable a gran escala, la agricultura de precisión (AP) desempeña un importante papel e introduce un cambio de paradigma al considerar a los campos como entidades heterogéneas con variaciones en múltiples dimensiones [2]. Se ha argumentado que varios tipos de sistemas de las tecnologías de la información y las comunicaciones serían los principales contribuyentes a la transición hacia la sostenibilidad, y los sistemas agrícolas de apoyo a la toma de decisiones constituyen un importante ejemplo. La AP es un concepto de gestión agrícola basado en la observación, la medida y la actuación frente a la variabilidad espacial y temporal de los cultivos. El objetivo de la AP es definir un sistema de apoyo a las decisiones para la gestión de los cultivos con el objetivo de optimizar el rendimiento de los insumos y preservar los recursos [4].

La AP implica una mejor gestión de los recursos e insumos agrícolas, tales como fertilizantes, agua, herbicidas y plaguicidas, realizando la gestión correcta de los cultivos en el lugar y momento adecuados. Mientras que en la mayoría de los grandes campos agrícolas bajo manejo convencional estos insumos se aplican de manera uniforme, con la AP, los campos se pueden dividir en diferentes zonas de manejo a las cuales se destinan los recursos en función de las características de cada zona en particular. La AP busca mejorar la productividad y rentabilidad de los cultivos a través de una mejor gestión de los recursos agrícolas, para lo cual se basa en la recopilación y el procesamiento intensivo, en el tiempo y el espacio, de datos e información sobre los cultivos. Por tanto, se requiere la obtención de mapas precisos del crecimiento de los cultivos, malezas, infestaciones de insectos, deficiencias de nutrientes y otras condiciones del cultivo y del suelo. La recolección de estos datos se lleva a cabo mediante la teledetección.

En la literatura se reportan varias aplicaciones de la teledetección a la AP. Estas incluyen la estimación del rendimiento y de la biomasa [5, 6], la detección del estrés hídrico y de los nutrientes de los cultivos [7–9], el mapeo de las infestaciones de malezas [10, 11], la presencia de insectos y enfermedades [12, 13] y la determinación de diferentes propiedades del suelo [14–17].

1.2. Planteamiento del problema y justificación

Las malezas pueden ocasionar pérdidas directas o indirectas en los cultivos y por tanto su control es una tarea de gran importancia en la producción agrícola [18–21]. Cuando el control de malezas se realiza de manera inapropiada se afecta el rendimiento de los cultivos y se incrementan los impactos negativos sobre el medio ambiente [22, 23]. Uno de los métodos más empleados en la actualidad para el control de malezas es el uso de herbicidas. Aunque efectivos, los métodos de control de malezas mediante la aplicación de herbicidas no siempre son eficientes [24, 25]. En muchos casos, del volumen total de herbicidas aplicados, una parte significativa se pierde debido a la evaporación, la imprecisión de los sistemas de aplicación o debido a que se depositan sobre los cultivos o el suelo, y como resultado sólo una pequeña parte del herbicida aplicado alcanza de manera efectiva a las malezas. Otro factor que afecta la eficiencia es la distribución no uniforme de las malezas a través de los campos de cultivos [26]. Varias propiedades físicas y químicas del suelo, tales como el pH, los niveles de nutrientes, la elevación topográfica, el contenido de materia orgánica y la capacidad de intercambio catiónico, contribuyen a esta distribución no homogénea. A pesar de esto, los herbicidas se suelen aplicar en iguales cantidades a lo largo de los sembrados.

En adición al impacto ambiental potencialmente adverso y las crecientes preocupaciones sobre los posibles efectos de los residuos de plaguicidas en la salud humana [27], los herbicidas y su aplicación representan un costo variable significativo en la producción agrícola. Estas preocupaciones han llevado a la creación de regulaciones legales en relación al uso de herbicidas en varios países. Una parte esencial del progreso hacia una gestión sostenible de las malezas, económica y ambientalmente, es la reducción del volumen de químicos aplicados.

Para poder aplicar los herbicidas de forma regulada en función de los requerimientos de cada zona del campo, es necesario como paso previo realizar un mapeado de la distribución de las malezas. Los mapas de distribución de malezas pueden ser empleados en la generación de mapas de prescripción para el tratamiento con herbicidas. Considerando la variabilidad espacial en la distribución de las malezas, es posible lograr una disminución significativa en la cantidad de herbicida aplicado mediante el uso de los mapas de prescripción.

Hace algunos años, la exploración manual intensiva era el único medio de proporcionar información acerca de las distribuciones de malezas. Estas labores manuales de mapeo de malezas son laboriosas y requieren mucho tiempo [28,29]. Durante la última década, se han desarrollado e implementado una amplia gama de nuevas tecnologías para la recopilación y procesamiento de información de los campos de cultivos. Entre estas tecnologías se encuentran las asociadas a la adquisición y procesamiento de imágenes de los cultivos desde plataformas terrestres, satelitales y aéreas. Estas plataformas y sus sistemas de adquisición de imágenes asociados pueden distinguirse en base a la altitud de la plataforma, la resolución espacial de las imágenes y la frecuencia en la obtención de los datos. Hasta el presente, el uso de las plataformas satelitales ha estado limitado por sus elevados costos, los retardos considerables en la obtención de los datos y las bajas resoluciones espaciales de las imágenes [30–34].

Con los recientes avances en el desarrollo de los vehículos aéreos no tripulados o drones, estos se han convertido en una alternativa prometedora para el monitoreo de los cultivos. El uso de drones en la AP ofrece tres ventajas fundamentales sobre otros sistemas de monitoreo de cultivos: (1) menores costos por área de cultivo, en comparación con el monitoreo mediante imágenes satelitales, (2) elevada precisión, debido a que las imágenes se toman en vuelos de baja altura y por tanto se pueden obtener resoluciones espaciales en el orden de los centímetros, (3) gran rapidez en la obtención de los datos, lo cual garantiza que se puedan tomar las medidas de control de manera oportuna.

1.2.1. Hipótesis

Mediante el análisis de las imágenes de un campo agrícola tomadas desde un vehículo aéreo no tripulado es posible detectar las malezas presentes en el campo.

1.2.2. Objetivo General

Desarrollar un método para la generación de mapas georreferenciados de infestación de malezas basado en el análisis de imágenes tomadas desde un vehículo aéreo no tripulado.

1.2.3. Objetivos Particulares

1. Establecer una metodología para la adquisición de las imágenes aéreas.
2. Diseñar e implementar un método para detectar las malezas en las imágenes adquiridas.
3. Validar el método diseñado mediante la comparación con los resultados derivados de la inspección humana en muestras representativas del campo.

1.3. Metodología

Para alcanzar los objetivos de la investigación, primeramente se llevó a cabo una fase de planificación y selección de la tecnología durante los primeros tres meses de trabajo. Una vez seleccionada la tecnología, se procedió a adquirir el todo equipamiento necesario para llevar a cabo la investigación. En el siguiente paso se coordinó con los agricultores los procedimientos necesarios para adquirir las imágenes de los cultivos.

En la siguiente fase de la investigación se realizó el trabajo de campo siguiendo una metodología con los siguientes pasos fundamentales:

1. Planificación del vuelo y adquisición de las imágenes.
2. Pre-procesamiento de las imágenes.
3. Análisis de las imágenes.

La última fase de la investigación involucró la participación de algunos grupos de interés locales, de conjunto con los cuales se llevó a cabo la revisión y validación de los resultados preliminares.

1.4. Estructura de la tesis

El presente documento se estructura en introducción, capitulario, conclusiones, recomendaciones y referencias bibliográficas. En el Capítulo 1 se establecen los fundamentos teóricos necesarios para abordar la problemática de investigación general. En este capítulo se exponen los resultados del estudio realizado sobre las técnicas de procesamiento de imágenes aplicadas en la agricultura. En el Capítulo 2 se presenta y argumenta la solución del problema a la que se arriba como resultado de la investigación. En este capítulo se presentan los algoritmos de

procesamiento de imágenes desarrollados. En el Capítulo 3 se presentan los resultados experimentales obtenidos y se evalúa el desempeño de los algoritmos desarrollados en función de varios parámetros. Por último, en las conclusiones se realiza un análisis crítico de los resultados obtenidos.

Capítulo 2

Marco Teórico

En este capítulo se establecen los fundamentos teóricos necesarios para abordar la problemática de investigación. En el epígrafe 2.1 se describen las características de las malezas y las afectaciones que producen en los campos agrícolas. En el epígrafe 2.2 se analizan varias técnicas de procesamiento de imágenes que son de interés para nuestro trabajo. En el epígrafe 2.2.1 describen algunos métodos de segmentación de vegetación. Seguidamente, en el epígrafe 2.2.2 se abordan las técnicas que se han utilizado en trabajos precedentes para detectar las filas de cultivos. Finalmente, en el epígrafe 2.2.3 se discuten algunos estudios previos sobre detección de malezas.

2.1. Malezas

En [35] se definió una maleza como “una planta que forma poblaciones capaces de ingresar a hábitats cultivados u ocupados por el hombre, y potencialmente deprimir o desplazar las poblaciones de plantas residentes que se cultivan deliberadamente o son de interés ecológico y/o estético”. Las malezas pueden prosperar bajo las condiciones generadas por las prácticas agrícolas de labranza, irrigación, fertilización y separación entre hileras que minimizan las tensiones debido a la sequía, baja fertilidad, luz limitada y altos niveles de plagas. Entre los problemas específicos que pueden causar las malezas se incluyen los siguientes:

- *Reducción del rendimiento agrícola:* El control de malezas es una parte costosa pero necesaria de la producción agrícola, que afecta directamente el precio de los alimentos y otros productos agrícolas. Sin embargo, tales productos serían menos abundantes y

más caros si no se aplicara el control de malezas. El rendimiento agrícola se reduce principalmente por la competencia entre la maleza y el cultivo por el agua y los nutrientes del suelo, la luz y el dióxido de carbono. Ciertas malezas también pueden reducir los rendimientos del cultivo al liberar compuestos alelopáticos.

- *Uso menos eficiente de la tierra:* La presencia de malezas en un terreno determinado puede reducir la eficacia máxima del uso de ese terreno de varias maneras. Estas incluyen mayores costos de producción y cosecha, reforestación y mantenimiento no agrícola, así como también reducción en el crecimiento de las plantas, limitación de los cultivos que se pueden cultivar y reducción del valor de la tierra.
- *Mayores costos de control de plagas:* Las malezas pueden albergar organismos dañinos para los cultivos. Por ejemplo, el gorgojo y la mosca de la zanahoria pueden ser alojados por la zanahoria silvestre, y luego atacar la zanahoria cultivada. Los áfidos y los gusanos de la raíz de la col viven en la mostaza y luego atacan la col, la coliflor, el rábano y los nabos.
- *Reducción de la calidad de los productos:* Todos los cultivos son susceptibles a una reducción de la calidad debido a la presencia de malezas. Algunos ejemplos son las semillas de malezas y los bulbos de cebolla en granos y semillas, los restos de malezas en el heno y el algodón.
- *Problemas de gestión del agua:* Las malezas acuáticas pueden ser un problema importante en los sistemas de riego y drenaje, lagos, estanques, embalses y puertos. Restringen el flujo de agua, interfieren con actividades comerciales y recreativas, y pueden emitir sabores y olores indeseables en los suministros de agua domésticos. Su control es a menudo difícil y costoso. Las malezas terrestres que crecen en los bordes de los sitios acuáticos también pueden ser un problema.
- *Menor eficiencia humana:* El control de malezas constituye una gran parte del trabajo de un agricultor requerido para producir un cultivo. Este esfuerzo afecta directamente el costo de la producción de cultivos y, por lo tanto, el costo de los alimentos. Nos afecta a todos, ya sea que cultivemos o no. Las malas hierbas reducen la eficiencia humana a través de alergias y envenenamiento. La fiebre del heno, causada principalmente por el

polen de las malezas, por sí sola representa tremendas pérdidas en la eficiencia humana. La hiedra venenosa, el roble venenoso y el zumaque venenoso causan pérdidas en términos de tiempo y sufrimiento humano.

2.1.1. Prevención, control y erradicación de malezas

La prevención, que significa evitar que una especie de maleza determinada contamine un área, es a menudo el medio más práctico para controlar las malezas. Entre las medidas que toman los agricultores para prevenir las infestaciones de malezas se encuentran las siguientes: (1) evitar que nuevas semillas de malezas sean introducidas mediante semillas de cultivos, alimentos o maquinaria contaminados, (2) evitar que las malezas ya presentes produzcan semillas, (3) prevenir la propagación de malezas perennes que se reproducen vegetativamente.

El control, por otro lado, tiene como objetivo limitar infestaciones de malezas existentes. El grado de control suele ser una cuestión de economía, un balance entre los costos involucrados y el aumento esperado de las ganancias. Cada agricultor tiene la capacidad de decidir el nivel de control de malezas adecuado para alcanzar los objetivos del sistema de cultivo. En las zonas no cultivadas, a menudo es deseable eliminar esencialmente toda la vegetación durante un período específico de tiempo, de modo que las malezas sean limitadas a un nivel que no les permita interferir con las actividades humanas. La mayoría de los programas de control biológico que utilizan un organismo altamente específico como agente de control se basan en la obtención de un manejo económico adecuado de una maleza, pero no en la erradicación.

La erradicación es la eliminación total de todas las malezas, incluidos sus propágulos vegetativos y semillas. La erradicación es mucho más difícil que la prevención o el control. En general, está justificada solo para la eliminación de infestaciones graves de malezas en un área limitada. La parte más difícil de la erradicación es la eliminación de los propágulos vegetativos y las semillas en el suelo. Las semillas de muchas malezas pueden permanecer latentes durante varios años, y en este estado latente no suelen ser eliminadas por las prácticas comunes de control de malezas. Los propágulos vegetativos y muchas semillas de malezas se pueden erradicar

mediante la fumigación del suelo. Se suelen utilizar herbicidas persistentes; sin embargo, debido a su larga persistencia en el suelo, impiden el crecimiento de especies deseables durante períodos de tiempo sustanciales.

Los métodos empleados para manejar malezas varían, dependiendo de la situación, la información disponible, las herramientas, la economía y la experiencia. La tecnología agrícola mejorada a lo largo de los siglos ha contribuido en gran medida al aumento de la producción de alimentos y, en consecuencia, al aumento del nivel de vida de las personas. Los avances en las prácticas de control de malezas han sido una parte importante de estos resultados.

Las prácticas de control de malezas son tan antiguas como el cultivo de alimentos y han evolucionado desde métodos que requerían grandes aportaciones de trabajo humano a métodos donde se minimiza el gasto de energía humana mediante la mecanización de las labores y uso de químicos. Progresivamente, y con un impulso creciente, los humanos aprendieron a usar sus propias manos, herramientas manuales, fuerza animal y la potencia de vehículos a motor para manejar las malezas. Las labores asociadas al control de malezas cambiaron radicalmente a partir de 1947 con la introducción de los herbicidas. A partir de entonces se han desarrollado numerosos herbicidas nuevos y se han utilizado ampliamente, lo que ha provocado que la energía química se convierta en la principal herramienta de control de malezas en muchos países.

2.2. Tecnologías de visión artificial en la agricultura

Las tecnologías de visión artificial han sido ampliamente utilizadas y estudiadas en la agricultura para identificar y detectar la vegetación (cultivos y malezas). A pesar de los desafíos existentes, estas tecnologías han demostrado un elevado potencial para su aplicación exitosa en varios sistemas automatizados de control de malezas descritos en estudios recientes [11, 36–39].

2.2.1. Segmentación de la vegetación

El primer paso de procesamiento en la mayoría de las aplicaciones de análisis de imágenes en la agricultura es segmentar los píxeles de la imagen en dos clases: vegetación y suelo.

La segmentación de imagen es un proceso mediante el cual los píxeles que comparten determinadas características se agrupan para formar diferentes regiones siguiendo algún criterio de homogeneidad. Este primer paso de procesamiento es esencial, ya que la precisión de la segmentación inicial influirá directamente en el desempeño de las etapas posteriores de procesamiento. En la literatura se han propuesto varios métodos para segmentar la vegetación en imágenes de campos agrícolas. Los métodos de segmentación más empleados se pueden dividir en dos grupos: (1) métodos basados en índices de vegetación y (2) métodos basados en aprendizaje automático. En las siguientes secciones se describirán ambos tipos de métodos de segmentación.

2.2.1.1. Segmentación basada en índices de vegetación

Los métodos de segmentación basados en índices de vegetación se encuentran entre los más utilizados en aplicaciones agrícolas. Se denomina índice de vegetación a una función que permite transformar una imagen RGB a una imagen de un solo canal en la cual existe un mayor contraste de los píxeles de vegetación con respecto al resto de los píxeles. Sea \mathcal{A} una imagen RGB donde solo existen dos clases de píxeles: vegetación y suelo. Una función $f : \mathbb{R}^3 \rightarrow \mathbb{R}$ se denomina índice de vegetación *ideal* si para cualquier \mathcal{A} se cumple que

$$\mathcal{B}(p) = f(\mathcal{A}_r(p), \mathcal{A}_g(p), \mathcal{A}_b(p)) : \mathcal{B}(q) \geq \mathcal{B}(r) \quad \forall q \in R_{\mathcal{A}}^V, r \in R_{\mathcal{A}}^S, \quad (2.1)$$

donde \mathcal{B} es la imagen del índice de vegetación, \mathcal{A}_r , \mathcal{A}_g y \mathcal{A}_b representan los canales rojo, verde y azul de \mathcal{A} , respectivamente, y $R_{\mathcal{A}}^V$ y $R_{\mathcal{A}}^S$ representan los conjuntos de coordenadas de los píxeles de vegetación y suelo de la imagen \mathcal{A} , respectivamente. Aunque en la práctica resulta difícil encontrar una función f que cumpla de manera estricta la condición (2.1) para cualquier imagen \mathcal{A} , esta definición de índice de vegetación ideal puede ser empleada como base para comprender y evaluar los diferentes índices de vegetación que se han propuesto en la literatura. En la tabla 2.1 se presentan algunos de los índices más utilizados en investigaciones precedentes. En esta tabla, para simplificar la notación, los valores de $\mathcal{A}_r(p)$, $\mathcal{A}_g(p)$ y $\mathcal{A}_b(p)$ se representan como R , G y B , respectivamente. Debido a la relativa simplicidad de las funciones de cálculo de estos índices de vegetación, su costo computacional es muy bajo en comparación con otros métodos de segmentación más complejos que se han propuesto.

Tabla 2.1: Índices de vegetación

Método	Función $f(R, G, B)$	Ref.
Índice de diferencia normalizado (NDI)	$\frac{G - R}{G + R}$	[40]
Índice de exceso de verde (ExG)	$\frac{2G - R - B}{R + G + B}$	[41]
Índice de exceso de rojo (ExR)	$1,4R - G$	[42]
Índice de color de extracción de vegetación (CIVE)	$0,441R - 0,811G + 0,385B + 18,787$	[43]
Índice de exceso de verde menos rojo (ExGR)	$\text{ExG} - \text{ExR}$	[44]
Índice vegetativo (VEG)	$\frac{G}{\sqrt[3]{R^2B}}$	[45]
Índices combinados 1 (COM1)	$\text{ExG} + \text{CIVE} + \text{ExGR} + \text{VEG}$	[46]
Índice de exceso de verde modificado (MExG)	$1,262G - 0,884R - 0,311B$	[47]
Índices combinados 2 (COM2)	$0,36\text{ExG} + 0,47\text{CIVE} + 0,17\text{VEG}$	[48]

Después de calcular el índice de vegetación de cada píxel de la imagen \mathcal{A} , la imagen obtenida \mathcal{B} se transforma en una imagen binaria \mathcal{V} mediante un proceso de umbralización, esto es

$$\mathcal{V}(p) = \begin{cases} 1, & \mathcal{B}(p) > V_{th} \\ 0, & \mathcal{B}(p) \leq V_{th} \end{cases}, \quad (2.2)$$

donde V_{th} es el umbral de binarización.

En la figura 2.1 se ilustra la idea de la segmentación basada en índices de vegetación. La figura 2.1a es una imagen RGB de un campo de cultivo. Las funciones de densidad de probabilidad (PDF) de los canales R, G y B de esta imagen se muestran en la figura 2.1b. Utilizando el índice de vegetación ExG, la imagen RGB se transformó en la imagen monocromática de la figura 2.1c, cuya PDF se muestra en la figura 2.1d. Nótese que en la figura 2.1c existe un contraste significativo entre las regiones de vegetación y suelo. En el histograma de la figura 2.1d se distinguen claramente dos picos dominantes, correspondientes a las regiones de vegetación

y suelo. El pico más prominente y cercano al cero corresponde a los píxeles de suelo, mientras que el pico de menor tamaño y mayor dispersión corresponde a los píxeles de la región de vegetación. Cuando el número total de píxeles de vegetación es comparable al número de píxeles de suelo, como es el caso del ejemplo de la figura 2.1, en la PDF del índice de vegetación se distinguen claramente los picos correspondientes a ambas regiones. En estos casos, que ocurren generalmente cuando el cultivo se encuentra en una etapa de desarrollo avanzada, es posible emplear un método automático (como por ejemplo, el método de Otsu [49]) para encontrar el umbral de binarización V_{th} . Sin embargo, no siempre es factible el uso de métodos automáticos para encontrar V_{th} , ya que si el área cubierta de vegetación es mucho menor que el área total del campo (como suele ocurrir en etapas tempranas de desarrollo del cultivo), no aparece un pico de vegetación distinguible en el histograma del índice de vegetación.

En [50] se compararon los índices de vegetación ExG, ExGR y NDI aplicados a la segmentación de plantas de frijol de soya. Se consideraron condiciones de cultivo en invernadero y a campo abierto. En los resultados obtenidos en esta investigación concluyó que el índice ExGR con $V_{th} = 0$ presentó el mejor desempeño en ambos tipos de entornos, con un factor de calidad medio del 90 %. En condiciones de invernadero el factor de calidad de los índices ExG y NDI fue similar, con un valor de alrededor del 50 %. En cultivos abiertos el desempeño del índice ExG fue del 90 % (similar al de ExGR), mientras que el de NDI disminuyó hasta el 25 %.

En [51] se evaluaron los índices de vegetación ExG y CIVE, considerando diferentes condiciones en cuanto a tipo de cultivo, iluminación y tipo de suelo. Se segmentaron cuatro tipos de imágenes diferentes: imágenes con vegetación verde sin sombra (GV), imágenes con vegetación verde con sombra (GVS), imágenes con vegetación no verde sin sombra (NGV) e imágenes con vegetación no verde con sombra (NGVS). En general, el índice ExG tuvo un mejor desempeño que CIVE en imágenes con sombra (GVS y NGVS). Tanto ExG como CIVE tuvieron un pobre desempeño en imágenes GVS, mientras que en imágenes NGV el desempeño de ExG fue muy superior al de CIVE.

En [52] se tomaron imágenes en diferentes campos de frijol de soya, en varios momentos del día. Se compararon los índices NDI, ExGR y CIVE, con V_{th} seleccionado por el método de Otsu. Los resultados mostraron un desempeño similar para los tres índices estudiados. Sin




Figura 2.1: Segmentación basada en índices de vegetación. (a) Imagen RGB de un campo de cultivo. (b) PDF de los canales R, G y B. (c) Imagen monocromática del índice ExG. (d) PDF del índice ExG.

embargo, se señala en la investigación que este desempeño no fue estable y presentó una gran variabilidad entre imágenes. En algunas imágenes el desempeño de los índices NDI y CIVE fue superior al del ExGR, mientras que en otras imágenes ocurrió todo lo contrario.

Los índices ExG, CIVE, ExGR y VEG fueron comparados en [53]. La comparación se llevó a cabo en imágenes de campos de maíz, considerando varias condiciones de iluminación. En

este estudio los índices ExG, ExGR y VEG presentaron un desempeño similar entre el 88 % y el 90 %, mientras que el índice CIVE presentó un desempeño del 68 %.

La correcta elección del umbral de binarización es fundamental para garantizar un adecuado desempeño de los métodos de segmentación basados en índices de vegetación. En la literatura se han propuesto varias técnicas de umbralización. En [54] la selección del umbral se basó en la entropía del histograma. Esta técnica es efectiva cuando el histograma es bimodal, pero resulta difícil de aplicar cuando los picos del histograma varían significativamente en tamaño. El método de Otsu [55] es uno de los métodos de selección automática del umbral más utilizados. Con el método de Otsu se obtiene el valor de un umbral que minimiza la varianza interclases entre dos regiones a segmentar. En el método de cálculo del umbral propuesto en [56], se calculó para cada píxel un factor de homogeneidad local a partir del cual se determinó un umbral local. Este método puede ser útil en la segmentación de regiones de vegetación pequeñas y debido a que se considera información local, su desempeño no se ve degradado en imágenes con iluminación variable. Los autores de [57] asumieron que los valores de intensidad de los píxeles de vegetación y suelo siguen distribuciones gaussianas. Los píxeles pertenecientes a la distribución gaussiana con el menor valor medio se clasificaron como vegetación. De manera similar, los píxeles pertenecientes a la distribución gaussiana con el mayor valor medio se clasificaron como suelo.

De acuerdo con algunos de los estudios considerados anteriormente, los métodos de segmentación basados en índices de vegetación tienen algunas limitaciones. La más notable de todas es que los resultados que se obtienen para un mismo método son muy sensibles a las condiciones en que se tomó la imagen a segmentar. Otra de sus desventajas es que requieren la optimización del umbral de binarización para lograr un adecuado desempeño. Además, son adecuados para la segmentación solo cuando color dominante de la plantas es el verde. Sin embargo, tienen algunas ventajas, tales como su simplicidad de implementación y bajo costo computacional, lo que los hace apropiados para aplicaciones de tiempo real. Asociado a su baja complejidad también está el hecho de que, a diferencia de otros métodos basados en aprendizaje automático, no requieren entrenamiento. El hecho de que en los estudios publicados se

han utilizado diferentes datos de prueba dificulta la comparación directa. Pocos estudios se han llevado a cabo utilizando un conjunto común de datos de prueba.

2.2.1.2. Segmentación basada en aprendizaje automático

Aunque en varias investigaciones se ha demostrado la efectividad de los métodos de segmentación basados en índices de vegetación, en algunos casos particulares su desempeño se degrada significativamente. Estos casos particulares pueden presentarse, por ejemplo, en imágenes tomadas en días muy soleados o nublados. Como resultado, en varios estudios se han investigado métodos de segmentación más sofisticados, entre ellos los métodos basados en aprendizaje automático, supervisados y no supervisados. Algunos de los métodos propuestos son los siguientes:

- Algoritmo de clusterización con lógica difusa [58].
- Algoritmo de desplazamiento medio (*mean-shift*) con una red neuronal de retropropagación [51].
- Algoritmo de desplazamiento medio con discriminante lineal de Fisher [52].
- Máquinas de soporte vectorial [48].
- Árboles de decisión [59].
- Clusterización por propagación de afinidad [53].
- Modelación morfológica [60].
- Clusterización mediante optimización de enjambre de partículas y modelación morfológica [61].

Como se ha demostrado en estudios precedentes, los métodos basados en aprendizaje automático tienen un mejor desempeño que los métodos basados en el índices de vegetación, ya que emplean una fase de entrenamiento previa. Sin embargo, esta característica puede representar una desventaja en aplicaciones de tiempo real. Además, para obtener resultados de segmentación fiables se requiere un número considerable de muestras de entrenamiento.

2.2.2. Detección de filas de cultivos

En la literatura se han propuesto diferentes métodos de procesamiento de imágenes para la detección de filas de cultivo en imágenes de campos agrícolas. En algunos de los métodos propuestos se combinan dos o más técnicas y en todos se aplican condicionamientos previos en forma de diferentes restricciones. Por ejemplo, se asumen como conocidos uno o más de los siguientes elementos: el número de filas de cultivos a detectar, la geometría del sistema de la cámara, el espaciamiento entre filas de cultivos, las orientaciones y posiciones esperadas de filas de cultivos, los parámetros intrínsecos y extrínsecos de la cámara. Algunos de las técnicas que se han utilizado para la detección de filas de cultivos son los siguientes:

- Transformada de Hough (TH): inicialmente propuesta por Hough [62], su aplicación para la detección de filas de cultivos se basa en la acumulación y conteo de los píxeles de vegetación de las filas. La TH se ha aplicado en la detección de filas rectas en varios tipos de cultivos (coliflor, remolacha azucarera y trigo) [63–69]. Modificaciones de la TH también fueron aplicadas en [70] y [71]. Los autores de [72] aplicaron el conocimiento previo acerca de la posición y dirección de las filas de cultivos con el propósito de restringir la búsqueda en el espacio de la TH. En [73] se propuso un método para detectar curvas parabólicas mediante la reducción del tamaño del acumulador.
- Regresión lineal: La idea principal de este enfoque es asumir que las filas de cultivos se pueden aproximar mediante líneas rectas y estimar los parámetros de la ecuación de cada línea empleando el método de mínimos cuadrados [45, 74–79].
- División de la imagen en franjas: la imagen se divide en múltiples regiones de interés formadas por franjas continuas que abarcan toda la imagen, asumiendo que cada franja corresponde a una fila de cultivo. Luego, dentro de cada franja se estima la posición de la fila de cultivo mediante mínimos cuadrados o la TH [47, 76, 80, 81].
- Punto de fuga: En proyección de perspectiva, las filas de cultivo paralelas se cruzan en el punto de fuga de la imagen. La idea de este método es considerar únicamente estas filas de cultivos que se cruzan en el punto de fuga [81, 82].

- Filtrado: Las filas de cultivos paralelas muestran características y patrones específicos en las imágenes en perspectiva después de aplicar algunos tipos de filtros. En [83] se utilizó un filtro pasa-banda en el dominio de la frecuencia, mientras que en [84,85] se utilizaron filtros wavelet de Gabor.
- Uso de cámaras estereoscópicas: las ubicaciones de las filas de cultivo se obtuvieron a partir de una cámara estereoscópica en [86], mientras que en [87] la información obtenida de la cámara estereoscópica fue combinada con un sistema inercial de medición.
- Correspondencia de plantillas: la correspondencia de plantillas (*template matching*) con programación dinámica fue utilizada en [79] para la detección de filas de cultivo rectas y curvas en diferentes tipos de cultivos (maíz, apio, patata, cebolla, girasol y soja) y etapas de crecimiento. En este trabajo se demostró que el método propuesto puede ser efectivo sin necesidad de conocer a priori el número de filas. Sin embargo, se basa en la asunción de que el espaciado entre filas es uniforme y el costo computacional del algoritmo se incrementa significativamente con el aumento de la resolución de la imagen, lo cual se traduce en tiempos de ejecución elevados.

2.2.3. Detección de malezas

La detección de malezas basada en el análisis de imágenes es un tema que ha sido investigado en varios trabajos precedentes. Dentro de las investigaciones más recientes en esta área se pueden establecer distinciones en cuanto a las plataformas empleadas para la obtención de las imágenes y los algoritmos de procesamiento de las imágenes. En relación a las plataformas, se distinguen dos tipos: terrestres [11, 36–39] y aéreas [30, 31, 34, 88–91]. Algunas de estas investigaciones donde se emplean plataformas terrestres tienen como característica que la detección de las malezas se realiza en tiempo real y a nivel de plantas individuales [11, 36, 39]. En cuanto a los algoritmos de procesamiento, en términos generales pueden dividirse en dos grupos: los que se basan en modelos que requieren entrenamiento supervisado con selección manual de muestras [11, 36–38, 88–90], y los que no requieren ningún tipo de entrenamiento para detectar las malezas [30, 31, 34, 91]. La detección de malezas basada en clasificadores con aprendizaje supervisado requiere el entrenamiento de los algoritmos con muestras de las regiones a clasificar

y por tanto los datos de entrenamiento deben ser cuidadosamente seleccionados por expertos para garantizar el adecuado desempeño del algoritmo. Estos algoritmos se ven limitados por las características del conjunto de datos empleado para entrenar el algoritmo y pueden fallar cuando se emplea en un campo donde el cultivo o las malezas son diferentes a las del conjunto de entrenamiento. En [34] las imágenes fueron segmentadas en objetos homogéneos empleando el algoritmo de segmentación multiresolución y las malezas fueron detectadas en base a su distancia a las filas de cultivos. Estrategias similares fueron presentadas en [30,31,91].

Capítulo 3

Materiales y métodos

En este capítulo se describen los materiales y métodos utilizados a lo largo de las diferentes etapas de experimentación y procesamiento de datos. En el epígrafe 3.1 se describe el campo agrícola de estudio en el que se tomaron las imágenes. En el epígrafe 3.2 se detallan las condiciones en que se adquirieron las imágenes y los procedimientos que se utilizaron para ello. En el epígrafe 3.3 se describe el proceso de generación del ortomosaico a partir de las imágenes adquiridas. A continuación, en el epígrafe 3.4 se presentan los algoritmos de procesamiento de imágenes desarrollados. La segmentación de la vegetación se describe en el epígrafe 3.4.1. En el epígrafe 3.4.2 se describe el algoritmo de estimación de la orientación media de las filas de cultivo. El algoritmo de identificación de las filas de cultivo se describe en el epígrafe 3.4.2. Finalmente, en el epígrafe 3.4.4 se describe el método de detección y mapeado de las malezas.

3.1. Campo agrícola de estudio

Para llevar a cabo nuestro estudio se tomaron imágenes aéreas de un campo de frijol de la variedad *Flor de Mayo* localizado en Morelos, Estado de Zacatecas, México (Latitud 22,854547°N, Longitud 102,654144°W). Las imágenes fueron tomadas el 26 de junio de 2017 entre las 11:53 y las 11:58. El frijol (*Phaseolus vulgaris L.*) es uno de los cultivos más importantes en México, donde el estado de Zacatecas es el principal productor. En Zacatecas, las malezas que con mayor frecuencia afectan los campos de frijol son *Amaranthus palmeri* (quelite), *Brassica campestris L.* (mostacilla) y *Bidens spp.* (aceitillas). La competencia por recursos




Figura 3.1: Sector de una las imágenes aéreas tomadas en el campo agrícola de estudio.

de humedad, luz y nutrientes de estas hierbas durante el desarrollo vegetativo del frijol puede resultar en una reducción considerable del rendimiento de la cosecha.

En el campo agrícola de estudio, el frijol fue sembrado en condiciones de temporal en surcos espaciados a 1,60 m. En cada surco se sembraron dos filas de cultivos separadas 0,40 m. Para la fecha en que se tomaron las imágenes las plantas de frijol se encontraban en la etapa principal 1 (tercera hoja trifoliada, código 13) de la escala BBCH (Biologische Bundesanstalt, Bundessortenamt und Chemische Industrie) extendida [92]. El campo se encontraba infestado de manera natural con las malezas *Amaranthus palmeri* y *Bidens odorata*, las cuales presentaban un tamaño similar, y en algunos caso menor, al de las plantas de frijol. La figura 3.1 muestra un sector de una las imágenes aéreas tomadas en el campo agrícola de estudio, donde se pueden observar las plantas de frijol y las malezas.

Tabla 3.1: Características técnicas del Phantom 4 Pro.

Parámetros generales	
Peso	1388 g
Longitud (diagonal)	350 mm
Tiempo de vuelo máximo	30 min
Velocidad máxima de traslación	72 km/h
Velocidad máxima de ascenso	6 m/s
Sistema de posicionamiento	GPS/GLONASS
Alcance máximo del control remoto	7 km
Parámetros de la cámara	
Tamaño y tipo del sensor	1" CMOS
Ángulo de visión	84°
Lentes	24 mm $f/2,8 - f/11$
Resolución máxima	5472 × 3648

3.2. Adquisición de las imágenes

Para la adquisición de las imágenes áreas se utilizó un cuadricóptero modelo Phantom 4 Pro. Este dron puede realizar vuelos controlados de forma manual, mediante un control remoto, o de forma autónoma, con la ayuda de un sistema de navegación a bordo basado en GPS/GLONASS. Se encuentra equipado además con una cámara de 20 Megapíxeles montada en un sistema de suspensión con estabilización en los tres ejes y libertad de movimiento en el pitch. En la tabla 3.1 se resumen las principales características técnicas del Phantom 4 Pro.

El plan de adquisición de las imágenes se diseñó tomando en cuenta los siguientes parámetros: (1) la resolución de muestreo a nivel del suelo requerida, (2) el área de interés del campo de cultivo y (3), el porcentaje de solapamiento frontal y lateral de las imágenes. La resolución de muestreo a nivel del suelo, G_s , es un parámetro que establece una relación entre las




Figura 3.2: Relación geométrica entre las dimensiones del área del suelo abarcada por la imagen y las dimensiones de la imagen, para una altitud de vuelo h_f y un ángulo de visión de la cámara α_c .

dimensiones del área del suelo abarcada por la imagen y las dimensiones de la imagen, para una altitud de vuelo dada. Asumiendo que el sistema de suspensión mantiene el lente de la cámara apuntando verticalmente hacia el suelo durante el desplazamiento del dron, G_s se puede calcular como

$$G_s = \frac{\sqrt{W_c^2 + H_c^2}}{2h_f \tan \alpha_c/2}, \quad (3.1)$$

donde $W_c = 5472$ y $H_c = 3648$ representan el ancho y la altura de la imagen, respectivamente, h_f es la altitud del vuelo y $\alpha_c = 84^\circ$ es el ángulo de visión de la cámara. En la figura 3.2 se ilustra la relación geométrica entre estos parámetros. La altitud del vuelo requerida para garantizar la resolución de muestreo deseada se determinó empleando (3.1). En nuestro estudio empleamos un valor de $G_s = 100$ px/m, a partir del cual se determinó la altitud de vuelo requerida $h_f = 36$ m. Para la planificación de la misión del dron se utilizó el software *DroneDeploy*. Este software toma como entradas la altura del vuelo y los porcentajes de solapamiento (frontal y lateral) de las imágenes, y a partir de la delimitación del área del cultivo, planifica la trayectoria

de vuelo, el intervalo entre la toma de fotografías sucesivas y la velocidad del dron. Para garantizar una adecuada precisión en la construcción del ortomosaico es necesario que exista un solapamiento significativo entre las imágenes adyacentes, por lo cual se tomaron las imágenes con un solapamiento frontal y lateral del 75 % y el 65 %, respectivamente. Durante la misión se tomaron un total de 65 imágenes, para cubrir un área total de 0,66 ha.

3.3. Generación del ortomosaico

La información que se puede obtener a partir de las imágenes aéreas individuales se encuentra limitada por varios factores, entre ellos la distorsión producida por el lente de la cámara, la posible falta de verticalidad de la toma de las imágenes, las deformaciones producidas por el relieve del terreno [93]. Por tanto, fue necesario realizar la ortoproyección fotográfica de las imágenes tomadas por el dron como paso previo a su análisis. Para ello utilizamos *OpenDroneMap* [94], un conjunto de herramientas de software de código abierto para el procesamiento de imágenes aéreas. Con el uso de estas herramientas se obtuvo, a partir de las imágenes aéreas, una imagen georreferenciada en la que se corrigieron las distorsiones geométricas de las fotografías individuales mediante la ortorrectificación, pasando de una representación en perspectiva cónica del campo de cultivo a una perspectiva ortogonal. Esta imagen georreferenciada se conoce como ortofotografía u ortomosaico. El ortomosaico mantiene toda la información de la fotografía aérea, permitiendo además medir a escala tanto distancias como superficies, garantizando el ajuste con mapas existentes [93].

En términos generales, el proceso de ortoproyección en *OpenDroneMap* consta de los siguientes pasos: (1) un procesamiento inicial en el que se realiza una búsqueda y alineación de puntos clave en las imágenes, se optimiza el modelo de cámara y se registra la información de geolocalización contenida en las imágenes, (2) la construcción de un modelo 3D a partir de la estimación de la posición y pose de la cámara en cada una de las imágenes, y (3) la generación del ortomosaico mediante un proceso denominado ortorrectificación con el cual se elimina la distorsión de perspectiva de las imágenes, para posteriormente combinarlas en una única imagen que es el ortomosaico.

3.4. Análisis de las imágenes

Para el desarrollo los métodos de análisis de las imágenes del campo de cultivo asumimos que:

1. Existe una región de interés principal dentro de la imagen del campo de cultivo, la cual, en el caso general, no coincide con toda el área de la imagen. Dentro de la región de interés principal solo existen áreas de vegetación y suelo.
2. Cada fila de cultivos se extiende a lo largo de una línea recta y todas las filas del campo tienen aproximadamente la misma orientación. La desviación máxima de la orientación de cualquier fila con respecto a la orientación media de todas las filas es mucho menor que la separación media entre filas.

Empleamos una metodología que consta de cuatro pasos fundamentales: (1) segmentación de la vegetación, (2) estimación de la orientación media de las filas de cultivos, (3) identificación de las filas de cultivos y (4) segmentación de las malezas y generación del mapa de densidad de malezas. En las siguientes secciones se describen los procedimientos seguidos en cada uno de los pasos del análisis. Las siguientes notaciones y definiciones serán empleadas en la descripción de los algoritmos:

- Imagen del campo de cultivo \mathcal{O} : Ortofotografía del campo de cultivo, la cual es una imagen RGB con dimensiones $W_o \times H_o$.
- Máscara de vegetación \mathcal{V} : Imagen binaria que resulta del proceso de segmentación de la vegetación en \mathcal{O} . Cada píxel de esta imagen puede tomar un valor de 0, para los píxeles de las regiones del suelo, o 1, para los píxeles de las regiones de vegetación.
- Máscara de la región de interés \mathcal{V}_R : Imagen binaria que representa la región de interés dentro de \mathcal{V} .
- Segmento de línea $S_p^{\vec{n}}$: Conjunto de pares de coordenadas de los píxeles con valor 1 contenidos en el segmento de línea con origen en el punto p , paralelo al vector \vec{n} y longitud $\|\vec{n}\|$, dentro en la imagen \mathcal{V} .
- Un par de coordenadas de un píxel de una imagen se representará con una letra minúscula, por ejemplo, p , q o r . Las coordenadas x e y de un píxel p se denotarán como $p(x)$ y

$p(y)$, respectivamente. El valor de intensidad de un píxel p en una imagen X de un solo canal se denotará como $X(p)$.

Dos conceptos clave para el desarrollo de los métodos propuestos son el de *densidad lineal de vegetación* y el de *perfil de vegetación*. A continuación se definen ambos conceptos.

Densidad lineal de vegetación $\rho_{\mathcal{V}}^{p, \vec{n}}$: Razón entre el número de pares de coordenadas de píxeles contenidas en el conjunto $S_{\mathcal{V}}^{p, \vec{n}} \cap S_{\mathcal{V}_R}^{p, \vec{n}}$ y el número de pares de coordenadas de píxeles contenidas en $S_{\mathcal{V}_R}^{p, \vec{n}}$, si $|S_{\mathcal{V}_R}^{p, \vec{n}}|$ es mayor que un umbral ε_s , o cero, en caso contrario. Matemáticamente,

$$\rho_{\mathcal{V}}^{p, \vec{n}} = \begin{cases} \frac{|S_{\mathcal{V}}^{p, \vec{n}} \cap S_{\mathcal{V}_R}^{p, \vec{n}}|}{|S_{\mathcal{V}_R}^{p, \vec{n}}|}, & \text{si } |S_{\mathcal{V}_R}^{p, \vec{n}}| > \varepsilon_s \\ 0, & \text{en caso contrario} \end{cases}, \quad (3.2)$$

donde $|x|$ denota el número de elementos del conjunto x y ε_s es un umbral que representa el tamaño mínimo del segmento de línea $S_{\mathcal{V}_R}^{p, \vec{n}}$ por debajo del cual la densidad lineal de vegetación se toma como cero. Es decir, que para una máscara de vegetación donde la región de interés coincide con toda la imagen, la densidad lineal de vegetación representa la cantidad de píxeles de vegetación por unidad de longitud en un segmento de línea dado. El umbral ε_s se introduce con el propósito de evitar las singularidades que ocurren cuando $|S_{\mathcal{V}_R}^{p, \vec{n}}| = 0$, las cuales pueden ocurrir, por ejemplo, en los bordes de la región de interés. El concepto de densidad lineal de vegetación se ilustra en la figura 3.3. En esta figura los cuadros claros y oscuros representan los píxeles con valor 1 y 0, respectivamente, de imágenes binarias. En la figura 3.3a se muestra la máscara de la región de interés \mathcal{V}_R , en la cual se define el segmento de línea $S_{\mathcal{V}_R}^{p, \vec{n}} = \{(2, 6), (3, 5), (4, 4), (5, 3)\}$. Similarmente, en la figura 3.3b se muestra la máscara de vegetación \mathcal{V} , donde se define el segmento de línea $S_{\mathcal{V}}^{p, \vec{n}} = \{(2, 6), (5, 3), (6, 2)\}$. La densidad lineal de vegetación, $\rho_{\mathcal{V}}^{p, \vec{n}}$, se calcula como $\rho_{\mathcal{V}}^{p, \vec{n}} = |S_{\mathcal{V}}^{p, \vec{n}} \cap S_{\mathcal{V}_R}^{p, \vec{n}}| / |S_{\mathcal{V}_R}^{p, \vec{n}}| = 1/2$, con $\varepsilon_s = 0$.

Perfil de vegetación $P(p, E_p), p \in S_{\mathcal{V}}^{q, \vec{m}}$: Es una función que hace corresponder a cada punto p del segmento de línea $S_{\mathcal{V}}^{q, \vec{m}}$ la densidad lineal de vegetación en p , $\rho_{\mathcal{V}}^{p, \vec{n}}$, donde se cumple que $\vec{n} \perp \vec{m}$ y $\|\vec{n}\| = E_p$. El parámetro E_p es una constante y se denomina extensión del perfil. El resto de los parámetros que definen el perfil de vegetación son la longitud, $L_p = \|\vec{m}\|$, la orientación, $\theta_p = \angle \vec{m}$ y el punto de origen q .

3.4.1. Segmentación de la vegetación

El objetivo de este primer paso fue obtener la máscara de vegetación \mathcal{V} a partir del procesamiento de la imagen del campo de cultivo \mathcal{O} . Se evaluaron varios métodos de segmentación de vegetación, incluyendo algunos de los métodos basados en índices de vegetación descritos en la sección 2.2.1. En particular, se consideraron los índices de vegetación NDI, ExG, ExR, ExGR, VEG, MExG.

Adicionalmente, se desarrolló un método de segmentación de vegetación basado en aprendizaje automático, empleando un algoritmo de clasificación. Con el propósito de simplificar el proceso de selección manual de muestras de entrenamiento se diseñó un sistema que integra el entrenamiento progresivo del clasificador con una interfaz de usuario para la selección de muestras. En la figura 3.4 se muestra un diagrama en bloque del sistema diseñado. El área principal de la interfaz de usuario muestra una imagen del campo de cultivo. En esta imagen el usuario puede seleccionar de manera iterativa regiones poligonales de muestra que representan las dos clases de interés: vegetación y suelo. Después de seleccionar una región de muestra, esta es etiquetada con la clase activa (vegetación o suelo) y enviada al clasificador. Progresivamente, el clasificador va almacenando muestras de entrenamiento. En cualquier momento

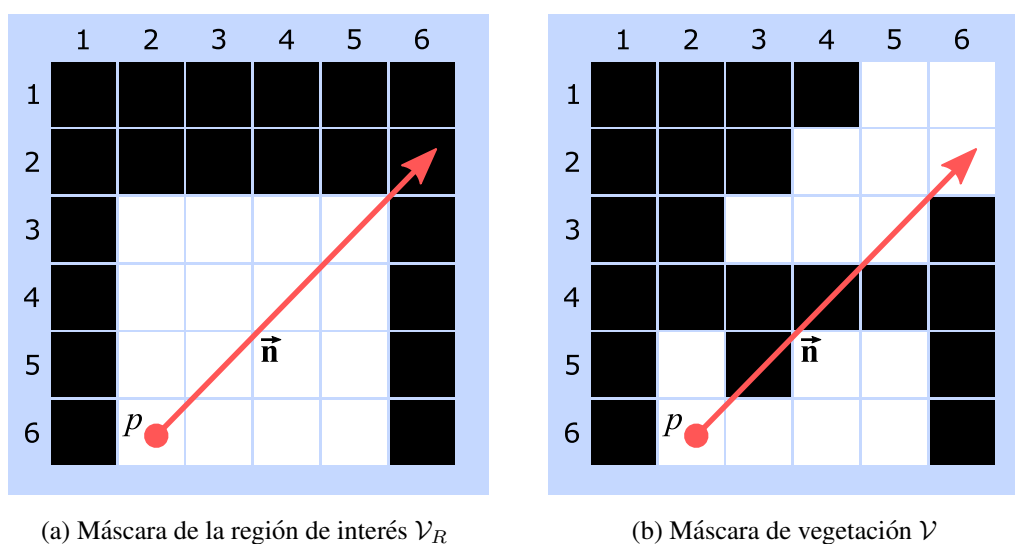


Figura 3.3: Ilustración del concepto de densidad lineal de vegetación.

el usuario puede iniciar el entrenamiento del clasificador. El desempeño del clasificador, en términos del error de validación cruzada, se muestra en la interfaz de usuario después de cada entrenamiento. De este modo, si el usuario observa que el desempeño no es satisfactorio, puede seleccionar mayor número de muestras y repetir el entrenamiento hasta que consiga los resultados deseados.

En la figura 3.5 se muestra una captura de pantalla de la interfaz gráfica desarrollada, donde se resaltan las características principales de la misma. La interfaz se diseñó de modo que al interactuar con ella el usuario pueda:

- Seleccionar una muestra delimitando una región poligonal dentro de la imagen.
- Cambiar la imagen mostrada por otra que se seleccionada aleatoriamente del banco de imágenes conectado al sistema al presionar la barra espaciadora.
- Iniciar el entrenamiento del clasificador presionando la tecla *T*.
- Cambiar la clase activa que etiqueta la muestra seleccionada presionado la tecla *C*.
- Visualizar la máscara de vegetación que se obtiene al segmentar la imagen actual con el clasificador al presionar la tecla *S*.

Cada muestra i -ésima enviada al clasificador contiene un conjunto de $M_{t,i}$ píxeles que conforman la región seleccionada por el usuario. Las muestras se almacenan en forma de una matriz de tamaño $M_t \times 3$, donde cada fila contiene los valores de intensidad de los canales

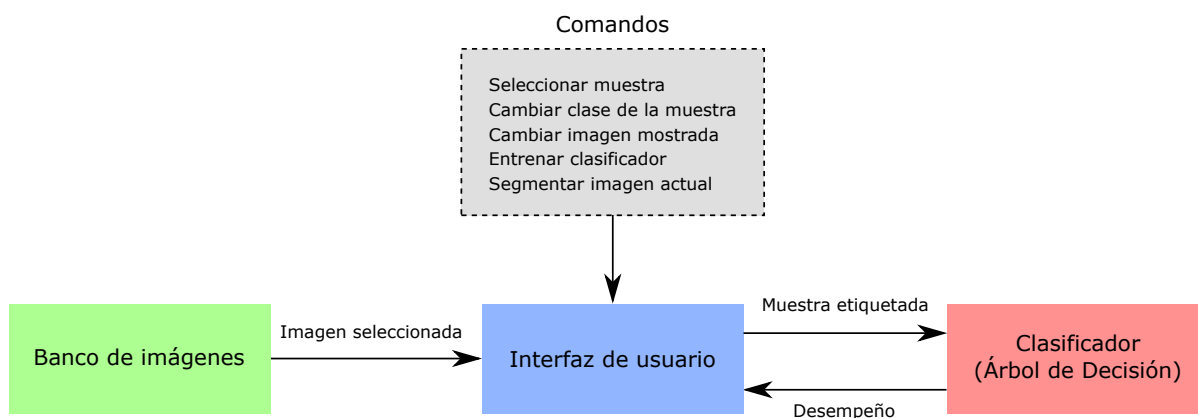


Figura 3.4: Diagrama en bloque del sistema de entrenamiento progresivo del clasificador para la segmentación de vegetación basada en aprendizaje automático.

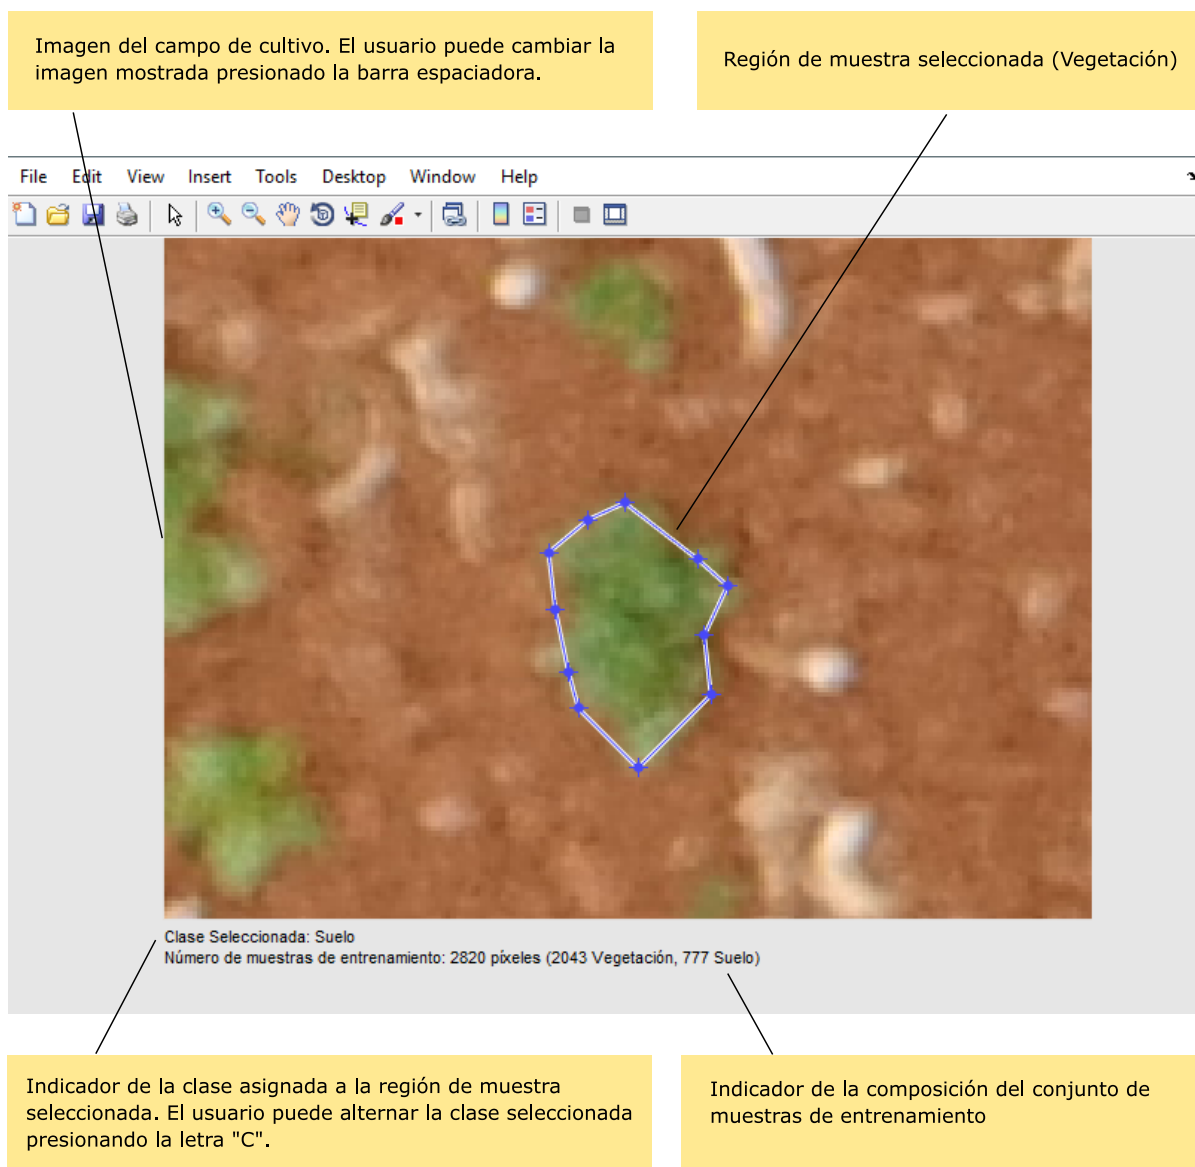


Figura 3.5: Interfaz de usuario del sistema de entrenamiento progresivo del clasificador para la segmentación de vegetación basada en aprendizaje automático.

R, G y B de cada píxel de la muestra. El sistema completo se implementó en *Matlab*. Como clasificador empleamos un árbol de decisión binario, implementado en la clase *Classification-Tree* del *toolbox* de estadísticas y aprendizaje automático de *Matlab*. Una vez entrenado, el clasificador toma como entrada un vector de los valores RGB de un píxel y devuelve la clase (vegetación o suelo) a la que pertenece el píxel.


3.4.2. Estimación de la orientación media de las filas de cultivos

La idea principal del algoritmo de estimación de la orientación media de las filas de cultivos se ilustra en la figura 3.6. En la figura 3.6a se muestra una máscara de vegetación donde se han calculado varios perfiles de vegetación con un mismo punto de origen q pero con diferentes orientaciones $\theta_{p,k} = k\pi/4$, $k \in \{0, 1, 2, 3\}$. En la figura 3.6b se muestran las gráficas de los cuatro perfiles de vegetación calculados. Como puede notarse en la figura 3.6b, los perfiles de vegetación tienden a mostrar picos más prominentes y con una distribución más uniforme en el perfil que corresponde a $\theta_{p,0}$, o sea, cuando su orientación se acerca a una dirección perpendicular a la de los surcos, que en este caso es de aproximadamente 90° . El algoritmo desarrollado se basa en esta variación de las características de los perfiles de vegetación en función de su dirección con respecto a las filas de cultivos para estimar la orientación de las filas.


Dada una máscara de vegetación \mathcal{V} , para estimar la orientación de los surcos en la vecindad de un punto q , calculamos los perfiles de vegetación de N_d segmentos de línea que parten del punto q en ángulos espaciados uniformemente $\theta_{p,k} = k\pi/(N_d - 1)$, $k \in \{0, 1, \dots, (N_d - 1)\}$. Para seleccionar el perfil con los picos más prominentes, se determinó para cada perfil k -ésimo su variación pico a pico, ΔP_k . Entonces, la orientación estimada de los surcos en la vecindad de q , ψ_q , se calculó como

$$\psi_q = \begin{cases} \pi/2 + \theta_{p,k}, & \text{si } \theta_{p,k} < \pi/2 \\ \pi/2 - \theta_{p,k}, & \text{en caso contrario} \end{cases}, k = \arg \max_k \{\Delta P_k\} \quad (3.3)$$

Para hacer el algoritmo más robusto, la orientación de las filas se estimó en M_d puntos seleccionados aleatoriamente y distribuidos uniformemente dentro de la máscara de la región de interés. La orientación global de los surcos, ψ , se obtuvo como la mediana de los valores estimados en cada uno de los puntos de muestreo. De este modo se descartaron los posibles valores atípicos (outliers) que pudieran aparecer en las estimaciones locales.



(a)



(b)

Figura 3.6: Estimación de la orientación media de las filas de cultivos. (a) Máscara de vegetación donde se calcularon cuatro perfiles de vegetación a lo largo de los vectores señalados, todos con el mismo punto de origen q . (b) Perfiles de vegetación calculados.

3.4.3. Identificación de las filas de cultivos

El paso que sigue a la estimación de la orientación media de las filas de cultivos es su identificación. El algoritmo que se desarrolló con este propósito consta de los siguientes pasos principales:

1. **Alineación de las filas de cultivos:** Las imágenes \mathcal{O} , \mathcal{V} y \mathcal{V}_R se rotaron en un ángulo $-\psi$, obteniéndose las imágenes \mathcal{O}' , \mathcal{V}' y \mathcal{V}'_R , respectivamente, con dimensiones $W'_o \times H'_o$ cada una. Con esta operación, las filas de cultivos quedaron orientadas horizontalmente en las imágenes \mathcal{O}' y \mathcal{V}' .
2. **Cálculo de los perfiles de vegetación:** En la imagen \mathcal{V}' se calcularon K_p perfiles de vegetación con una orientación perpendicular a las filas de cultivos y con un espaciamiento horizontal uniforme E_p , donde $K_p = \lfloor W'_o/E_p \rfloor$ y $\lfloor x \rfloor$ denota el entero más pequeño menor o igual que x . La extensión de cada perfil coincide con el espaciamiento entre perfiles, E_p . Debido a la rotación previa de la imagen, la dirección del vector de densidad lineal de vegetación de los perfiles coincide con la orientación de los surcos. El i -ésimo perfil de vegetación se calcula sobre un segmento con origen en el punto $q_i = (iE_p, 0)$, con $i = 0, 1, \dots, (K_p - 1)$ y se denota como $P_i(p, E_p)$, $p \in S_{\mathcal{V}'}^{q_i, \vec{m}}$, donde $\|\vec{m}\| = H'_o$ y $\angle \vec{m} = \pi/2$.
3. **Identificación de los picos dominantes en los perfiles de vegetación:** El objetivo de este paso es determinar la posición de los picos dominantes en cada uno de los perfiles de vegetación calculados en el paso anterior. Debido a que los perfiles se encuentran orientados perpendicularmente a las filas de cultivos, las posiciones de los picos dominantes de cada perfil coinciden con las posiciones de las filas que atraviesan el perfil de vegetación. En cada perfil de vegetación $P_i(p, E_p)$, $p \in S_{\mathcal{V}'}^{q_i, \vec{m}}$, un punto p se considera un pico dominante si se cumple que $P_i(p, E_p) > P_{v,i}(r, E_p), \forall r \in S_{\mathcal{V}'}^{q_i, \vec{m}}(p, 2\epsilon_d)$ y $P_i(p, E_p) > \epsilon_h \cdot \max_r P_{v,i}(r, E_p)$, $\{p, r\} \in S_{\mathcal{V}'}^{q_i, \vec{m}}$, donde $S_{\mathcal{V}'}^{q_i, \vec{m}}(p, \epsilon_d)$ representa el conjunto de puntos en una vecindad centrada en p y de tamaño $2\epsilon_d + 1$ en el segmento de línea $S_{\mathcal{V}'}^{q_i, \vec{m}}$. Los parámetros ϵ_d y ϵ_h se denominan distancia mínima entre picos y altura mínima de picos relativa. Como paso previo a la identificación de los picos se aplicó un

filtro de promedio móvil de tamaño ω_m a cada perfil de vegetación, con el objetivo de reducir el ruido y evitar la detección de falsos picos.

4. **Enlazado de los picos de vegetación:** El objetivo de este paso es obtener, para cada una de las filas de cultivos, un segmento de línea continuo a trozos alineado y centrado con respecto a la fila. Para esto se lleva a cabo un proceso de alineación de los picos pertenecientes a perfiles adyacentes, de modo que un pico en la posición p_i se enlaza con un pico en la posición p_j perteneciente a un perfil adyacente si el desplazamiento vertical de p_j con respecto a p_i es menor que un umbral δ_p . Cada pico se puede enlazar únicamente con los picos de los perfiles adyacentes y por tanto el número máximo de enlaces por cada pico es dos. Como resultado de este proceso se obtiene un conjunto de segmentos de línea continuos a trozos, cada uno de los cuales se asume que representa una fila de cultivo si el número de puntos del segmento de línea es mayor que un umbral S_{min} . Cada segmento de línea asociado a una fila de cultivo se denomina línea de cultivo y se denota como $\mathcal{L}_{c,i}, i \in \{1, 2, \dots, \hat{K}_r\}$, donde \hat{K}_r es el número de filas de cultivos identificadas. La línea de cultivo $\mathcal{L}_{c,i}$ está formada por una serie de puntos sucesivos enlazados, esto es, $\mathcal{L}_{c,i} = \{p_{i,k}\}, k \in \{1, 2, \dots, M_{c,i}\}$, donde $M_{c,i}$ es el número de puntos que forman la i -ésima línea de cultivo. En la figura 3.7 se ilustra mediante un ejemplo el procedimiento previamente descrito.

3.4.4. Detección y mapeado de las malezas

Para el desarrollo del algoritmo de detección de malezas nos basamos en sus patrones de distribución observados en el campo de cultivo. Mientras que los cultivos generalmente se distribuyen uniformemente a lo largo de los surcos, las malezas tienden a presentar una mayor densidad de distribución en los espacios entre filas de cultivos adyacentes y se ubican de manera más dispersa en relación a las filas. La idea principal es seleccionar los píxeles que por su posición con respecto a las filas de cultivos se pueden clasificar como cultivo o maleza con una alta certeza y utilizarlos para entrenar un algoritmo de clasificación que permita clasificar el resto de los píxeles. Asumimos que los píxeles de vegetación más cercanos a las líneas de cultivos tienen una alta probabilidad de pertenecer al cultivo, mientras que los píxeles más

alejados tienen una alta probabilidad de pertenecer a las malezas. El algoritmo desarrollado consta de los siguientes pasos principales:

1. **Generación de las líneas de malezas:** A partir del conjunto de líneas de cultivo se generaron las líneas de maleza. Se denomina línea de maleza al segmento de línea continuo a trozos localizado en entre dos líneas de cultivo adyacentes. Cada punto de discontinuidad de una línea de malezas es equidistante de los puntos de discontinuidad de las líneas de cultivo circundantes localizados en la misma vertical. Una línea de maleza se denota como $\mathcal{L}_{w,i}, i \in \{1, 2, \dots, (\hat{K}_r - 1)\}$.




Figura 3.7: Enlazado de los picos de vegetación en el algoritmo de identificación de las filas de cultivos.

2. **Asociación de los píxeles de vegetación a las líneas de cultivo y maleza:** Para cada píxel de vegetación con coordenadas p se calculan dos parámetros, la distancia de cultivo $D_c(p)$, y la distancia de maleza $D_w(p)$. Los parámetros $D_c(p)$ y $D_w(p)$ representan las menores distancias del píxel de vegetación a las líneas de cultivo y maleza más cercanas, respectivamente. Si $\mathcal{L}_{c,i}$ es la línea de cultivo más cercana al píxel p y $\mathcal{L}_{w,j}$ es la línea de maleza más cercana al píxel p , entonces se dice que p está asociado a $\mathcal{L}_{c,i}$ y a $\mathcal{L}_{w,j}$. Los conjuntos de píxeles asociados a $\mathcal{L}_{c,i}$ y a $\mathcal{L}_{w,j}$ se denotan como $\mathcal{R}_{c,i}$ y $\mathcal{R}_{w,j}$, respectivamente. El procedimiento descrito en este paso se ilustra en la figura 3.8.
3. **Clasificación parcial de los píxeles de vegetación:** Para cada conjunto $\mathcal{R}_{c,i}$ se calcula el valor medio de las distancias de cultivo de los píxeles del conjunto, $\bar{D}_{c,i}$. De manera similar, para cada conjunto $\mathcal{R}_{w,i}$ se calcula el valor medio de las distancias de maleza de los píxeles del conjunto, $\bar{D}_{w,i}$. Un píxel de vegetación p tal que $p \in \mathcal{R}_{c,i}$ y $p \in \mathcal{R}_{w,j}$ es clasificado como cultivo si se cumple que $D_c(p) \leq \lambda_c \bar{D}_{c,i}$ y $D_w(p) > \lambda_w \bar{D}_{w,j}$, o como maleza si se cumple que $D_w(p) \leq \lambda_w \bar{D}_{w,j}$ y $D_c(p) > \lambda_c \bar{D}_{c,i}$. Los parámetros λ_c y λ_w se denominan factores de ponderación de la distancia de cultivo y de malezas, respectivamente.
4. **Clasificación de los píxeles de vegetación indeterminados:** Con las coordenadas de los píxeles clasificados como cultivo o maleza en el paso anterior se seleccionaron los valores de intensidad de los píxeles RGB en la imagen \mathcal{O}' y se utilizaron estos valores para entrenar un algoritmo de clasificación basado en árboles de decisión [95]. Una vez entrenado, el árbol de decisión se empleó para predecir la clase (cultivo o maleza) a la que pertenece cada uno de los píxeles de la imagen \mathcal{O}' que no fueron clasificados en el paso anterior.
5. **Generación del mapa de densidad de malezas:** Se generó una imagen binaria \mathcal{W}_{est} con las mismas dimensiones que \mathcal{V}' denominada máscara de malezas estimada y en la cual cada píxel con valor 1 representa un píxel de maleza. La máscara de malezas se dividió en celdas rectangulares empleando una cuadrícula uniforme de dimensiones $C_w \times C_h$. En cada celda, se calculó la densidad de malezas como la razón entre el número de píxeles de maleza y el número total de píxeles dentro de la celda.

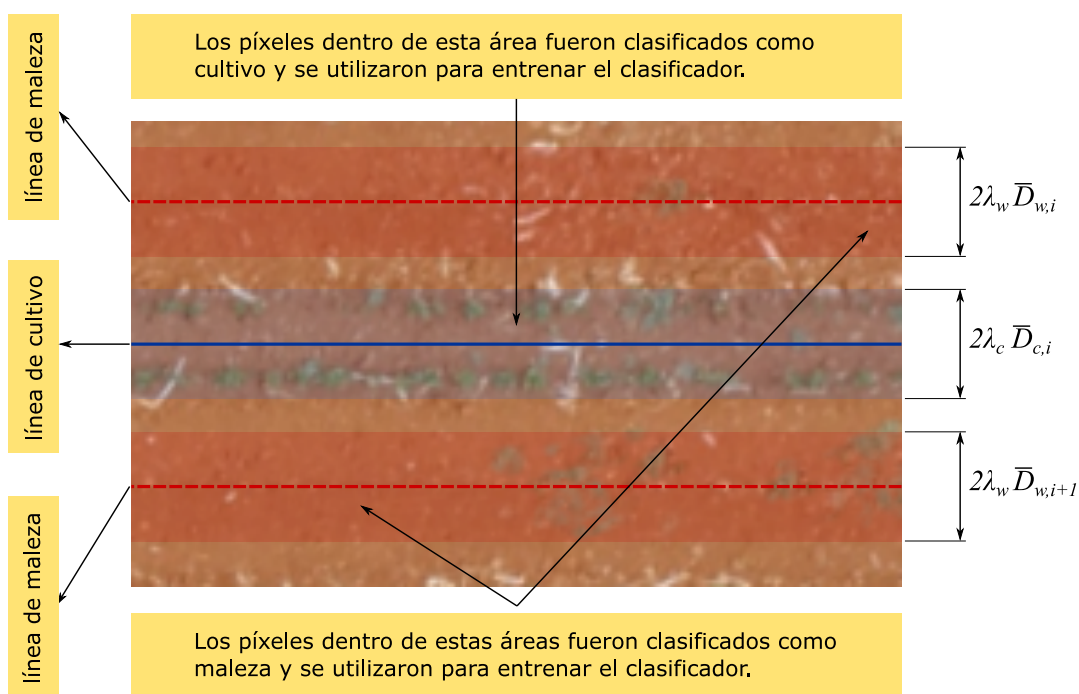


Figura 3.8: Asociación de los píxeles de vegetación a las líneas de cultivo y maleza en el algoritmo de detección y mapeado de las malezas.

Capítulo 4

Resultados y discusión

En este capítulo se presentan los resultados experimentales obtenidos. En el epígrafe 4.1 se analiza el desempeño de los métodos de segmentación de la vegetación. Seguidamente, en el epígrafe 4.2 se discuten los resultados obtenidos en la evaluación del desempeño del algoritmo de identificación de las filas de cultivos. Finalmente, en el epígrafe 4.3 se evalúa el algoritmo de detección y mapeado de las malezas.

4.1. Evaluación de los métodos de segmentación de vegetación

La evaluación de los métodos de segmentación de vegetación se llevó a cabo utilizando como referencia un sector de una de las imágenes del campo (figura 4.1a). La vegetación contenida dentro de este sector se segmentó de forma manual, obteniéndose la máscara de vegetación de referencia mostrada en la figura 4.1b. La imagen de la figura 4.1a se segmentó empleando cada uno de los métodos de segmentación de vegetación evaluados y se obtuvo en cada caso una máscara de vegetación estimada. El desempeño de cada método de segmentación se evaluó en términos del factor de calidad de la segmentación [50]. Denotando la máscara de referencia de la figura 4.1b como $\mathcal{V}_{s,ref}$, y la máscara estimada mediante segmentación como $\mathcal{V}_{s,est}$, el factor de calidad de la segmentación, Q_{seg} , puede escribirse como

$$Q_{seg} = \frac{|\{i \in (\mathcal{V}_{s,ref} \wedge \mathcal{V}_{s,est}) : i = 1\}|}{|\{j \in (\mathcal{V}_{s,ref} \vee \mathcal{V}_{s,est}) : j = 1\}|}, \quad (4.1)$$

donde los operandos \wedge y \vee representan las operaciones AND lógico y OR lógico, elemento a elemento, entre dos matrices binarias, respectivamente. El numerador de (4.1) representa el




Figura 4.1: Sector de una de las imágenes del campo empleado como referencia en la evaluación de los algoritmos de segmentación de vegetación (a) Imagen RGB. (b) Máscara de vegetación correspondiente.

número de píxeles de vegetación de $\mathcal{V}_{s,ref}$ clasificados correctamente como vegetación, mientras que el denominador incluye todos los píxeles de vegetación de $\mathcal{V}_{s,ref}$ más los píxeles de suelo que fueron clasificados erróneamente como vegetación.

4.1.1. Segmentación basada en índices de vegetación

En la figura 4.2 se muestran los histogramas de los índices de vegetación calculados para la imagen de referencia (figura 4.1a). Puede notarse claramente que todos los histogramas son unimodales, con un único pico dominante que puede asociarse a los píxeles de la región del suelo. Esto significa que en este caso no resulta factible utilizar un método de selección automática del umbral de binarización. Este resultado está en correspondencia con lo planteado en la sección 2.2.1 en relación a la efectividad de los métodos de selección automática del umbral en imágenes donde la densidad de vegetación es relativamente baja. Nótese también que los rangos de valores de los índices de vegetación son diferentes en todos los casos. Como




Figura 4.2: Histogramas de los índices de vegetación calculados para la imagen de referencia (figura 4.1a) (a) Índice de diferencia normalizado (NDI). (b) Índice de exceso de verde (ExG). (c) Índice de exceso de rojo (ExR). (d) Índice de exceso de verde menos rojo (ExGR). (e) Índice vegetativo (VEG). (f) Índice de exceso de verde modificado (MExg).

resultado, no se puede definir una única estrategia para la selección del valor apropiado del umbral, válida para todos los índices de vegetación.

La correcta elección del umbral de binarización es fundamental en los métodos basados en índices de vegetación. En la figura 4.3 se muestra el factor de calidad de la segmentación en función del umbral de binarización, para los diferentes índices de vegetación. En esta gráfica puede observarse que todos los índices, excepto NDI y MExG, tienen un desempeño máximo similar. El índice de peor desempeño fue el NDI, corroborando lo ya reportado en investigaciones precedentes [50,52]. Aunque los índices ExG, ExR, ExGR y VEG presentan un desempeño similar, se observa que el índice ExGR es el de menor sensibilidad a la variación del umbral, ya que presenta una caída más lenta del factor de calidad alrededor del punto máximo, con respecto a los demás índices. Otro elemento importante que debemos hacer notar y que se observa




Figura 4.3: Factor de calidad de la segmentación en función del umbral de binarización para los métodos de segmentación basados en índices de vegetación.

en estos resultados es que la efectividad de la segmentación basada en índices de vegetación es sensible a la variación del umbral, ya que el factor de calidad cae rápidamente cuando el umbral se aleja del valor óptimo. A partir de estos resultados se puede entender la importancia de la correcta selección del umbral.

4.1.2. Segmentación basada en aprendizaje automático

En el método de segmentación basada en aprendizaje automático, el árbol de decisión se entrenó con 3088740 muestras (píxeles) en total, de las cuales el 4,78% fueron píxeles de vegetación y el resto suelo. El desempeño de este método de segmentación se resume en la tabla 4.1, en la que se muestran tres parámetros de desempeño: el error de resustitución, el error de validación cruzada y el factor de calidad de la segmentación.

El error de resustitución es el error cuadrático medio entre la respuesta de los datos de entrenamiento y la respuesta que predice el clasificador a los datos de entrenamiento de entrada.

Tabla 4.1: Parámetros de desempeño de la segmentación basada en aprendizaje automático

Parámetro	Valor
Error de resustitución	$3,22 \times 10^{-4}$
Error de validación cruzada	$61,2 \times 10^{-4}$
Calidad de la segmentación	0,988

Si el error de resustitución es alto, no se puede esperar un buen desempeño del clasificador. Sin embargo, obtener un bajo error de resustitución no garantiza predicciones correctas para nuevos datos. El error de resustitución a menudo es una estimación optimista del error predictivo en nuevos datos. En nuestro caso obtuvimos un error de resustitución de $3,22 \times 10^{-4}$.

Para obtener una mejor idea de la exactitud de predicción del árbol para nuevos datos utilizamos como métrica el error de validación cruzada. La validación cruzada divide los datos de entrenamiento en 10 partes de forma aleatoria. Luego, el algoritmo entrena 10 nuevos árboles de decisión, cada uno con 9 de las partes en que se dividen los datos de entrenamiento. A continuación, examina la exactitud de predicción (en términos del error cuadrático medio) de cada

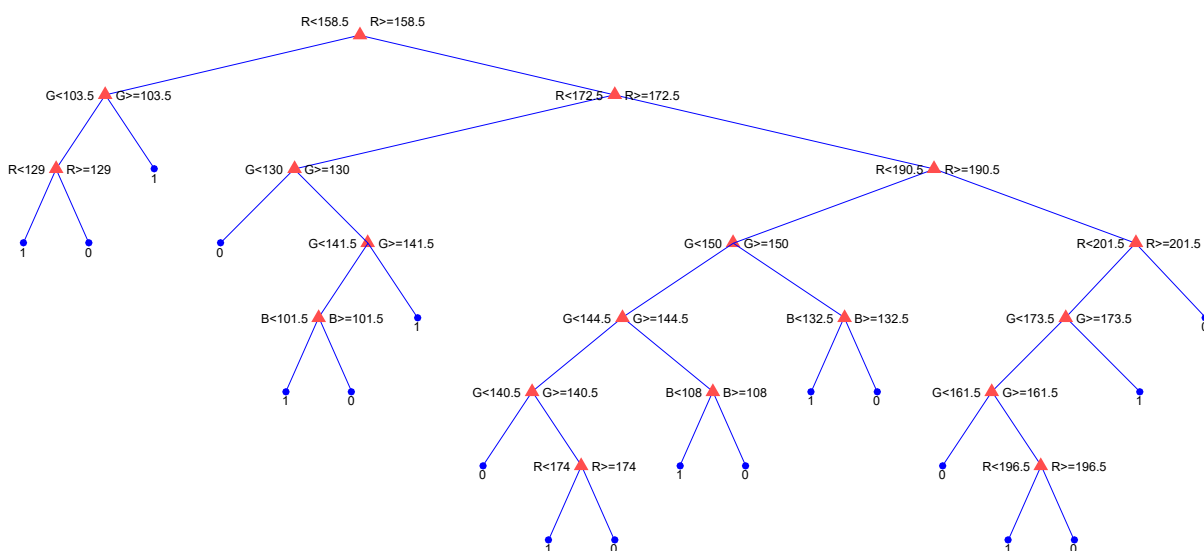


Figura 4.4: Estructura del árbol de decisión del método de segmentación basada en aprendizaje automático.

nuevo árbol, tomando como entradas los datos no incluidos en el entrenamiento de ese árbol. Esta métrica, que fue de $61,2 \times 10^{-4}$ para el árbol entrenado, proporciona una buena estimación de la precisión predictiva del árbol. Nótese que el error de validación cruzada es casi 20 veces mayor que el error de resustitución.

La siguiente métrica de desempeño, el factor de calidad de la segmentación Q_{seg} , indica que el desempeño de este método de segmentación fue muy superior al de los métodos basados en índices de vegetación. Se obtuvo un valor de $Q_{seg} = 0,988$, mientras que el mayor valor de que Q_{seg} para los métodos basados en índices de vegetación fue de 0,74.

El árbol se configuró con un número máximo de divisiones de decisión por nodo de 30. En la figura 4.4 se muestra la estructura del árbol resultante, donde puede notarse que el número de divisiones del nodo raíz fue de 18.

4.2. Evaluación del algoritmo de identificación de las filas de cultivos

La evaluación del algoritmo de identificación de las filas de cultivo se llevó a cabo comparando las líneas de cultivo identificadas por el algoritmo con las que se identificaron de forma manual en una de las imágenes del campo (figura 4.5a). Para propósitos de comparación, el desempeño del algoritmo también se evaluó en una imagen de un campo de cultivo (figura 4.5b) con características diferentes a las del cultivo objeto de estudio. La imagen de la figura 4.5b fue tomada sobre un campo de chile a 50 m de altura, para una resolución de muestro de 73 px/m. Además del tipo de cultivo y la altura a la que fueron tomadas, las imágenes de las figuras 4.5a y 4.5b se diferencian en cuanto a la densidad de vegetación y a la distribución de las filas. Mientras que la imagen del campo de frijol presenta una densidad de vegetación muy baja (de alrededor del 5 %) debido a las etapas tempranas de crecimiento del cultivo, la imagen del campo de chile presenta una densidad de vegetación alta (de alrededor del 50 %) debido a que se trata de un cultivo en las etapas finales de desarrollo. En el campo de frijol las filas de cultivos se agrupan en pares separados 0,40 m con una distancia entre pares de filas de 1,60 m, mientras que en el campo de chile las filas de cultivos tienen un espaciamiento uniforme de 1,65 m.




Figura 4.5: Sector de una de las imágenes del campo empleado como referencia en la evaluación de los algoritmos de segmentación de vegetación (a) Imagen RGB. (b) Máscara de vegetación correspondiente.

Sobre cada fila de cultivo se trazó una línea recta centrada y orientada con respecto a la fila correspondiente, como puede notarse en la figura 4.5. A cada línea j -ésima se hizo corresponder una ecuación de la forma $y = a_j x + b_j$, $j \in \{1, 2, \dots, K_r\}$, donde K_r es el número de filas de cultivos presentes en la imagen. Posteriormente, para cada línea de referencia se calculó la raíz cuadrada del error cuadrático medio (RMSE) con respecto a todas las líneas de cultivo identificadas. El RMSE de la j -ésima línea de referencia con respecto a la i -ésima línea identificada se calculó como

$$RMSE_{j,i} = \sqrt{\frac{1}{M_{c,i}} \sum_{k=1}^{M_{c,i}} [p_{i,k}(y) - (a_j p_{i,k}(x) + b_j)]^2}, \quad i \in 1, 2, \dots, \hat{K}_r \quad (4.2)$$

donde \hat{K}_r es el número de líneas de cultivo identificadas y $M_{c,i}$ es el número de puntos que forman la i -ésima línea de cultivo identificada. Se consideró que la fila de cultivo j -ésima fue correctamente identificada si se cumple que

$$\min_i \{RMSE_{j,i}\} \leq RMSE_{max}, \quad (4.3)$$

Tabla 4.2: Valores de los parámetros de los algoritmos de estimación de la orientación e identificación de las filas de cultivo.

Estimación de la orientación media de las filas de cultivos	
Número de perfiles de vegetación por punto de muestreo, N_d	360
Número puntos de muestreo, N_d	40
Identificación de las filas de cultivo	
Extensión de los perfiles de vegetación, E_p	$0,2\text{m} \leq E_p \leq 3,0\text{m}$
Distancia mínima entre picos, ϵ_d	$W_r/2$
Altura mínima de picos relativa, ϵ_h	0,2
Tamaño del filtro de promedio móvil, ω_m	$W_r/2$
Umbral de enlace de picos adyacentes, δ_p	$W_r/2$
Umbral de conformación de las líneas de cultivos, S_{min}	3

donde $RMSE_{max}$ es el máximo RMSE permisible. Para una evaluación cuantitativa del algoritmo se definió un factor de calidad de identificación de las filas, Q_r , el cual se calculó como

$$Q_r = \frac{N_{dc}}{N_{dc} + N_{di} + N_{ud}}, \quad (4.4)$$

donde N_{dc} es el número de líneas de referencia detectadas correctamente, N_{di} es el número de filas que fueron detectadas pero que no se asociaron a ninguna línea de referencia y N_{ud} es el número de líneas de referencia que no fueron detectadas. Se cumple que $N_{dc} + N_{ud} = K_r$ y $N_{dc} + N_{di} = \hat{K}_r$.

En la tabla 4.2 se muestran los valores asignados a los parámetros de los algoritmos de estimación de la orientación e identificación de las filas de cultivo. Por conveniencia, los valores de los parámetros E_p , ϵ_d , ω_m y δ_p aparecen expresados en unidades de longitud. En particular, ϵ_d , ω_m y δ_p se presentan en función de la distancia estimada entre filas de cultivos, W_r . La conversión a unidades de píxeles (requerida por los algoritmos) se puede realizar multiplicando los valores por la resolución de muestreo de la imagen analizada. Se consideró $RMSE_{max} =$

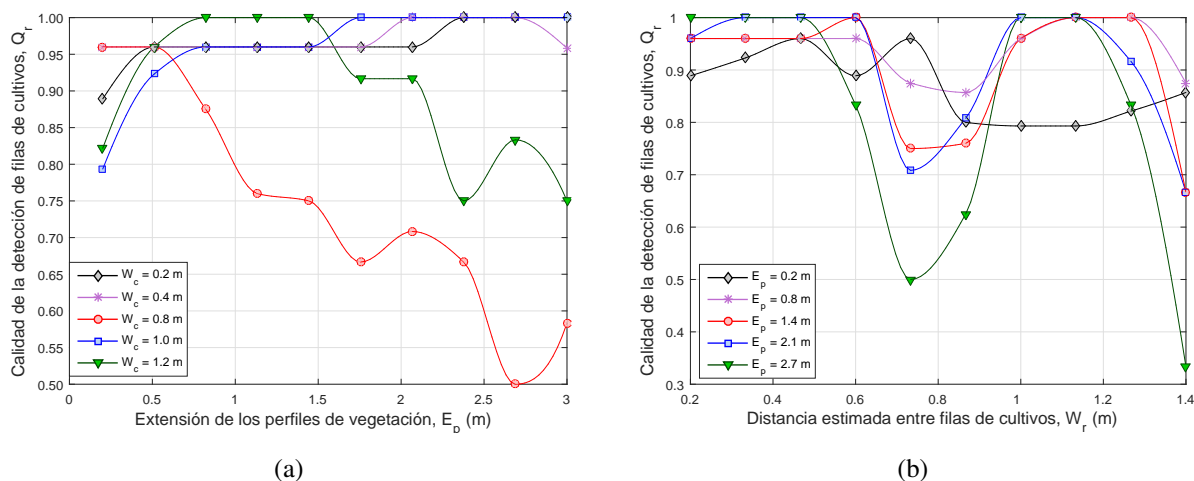


Figura 4.6: Desempeño del algoritmo de identificación de las filas de cultivos para la imagen de la figura 4.5a (a) Factor de calidad de identificación de las filas (Q_r) en función extensión de los perfiles de vegetación (E_p) (b) Factor de calidad de identificación de las filas (Q_r) en función extensión de la distancia estimada entre filas de cultivos (W_r).

15 cm, el cual es un valor razonable si tenemos en cuenta que la menor distancia entre filas de cultivos es de 40 cm, para ambas imágenes.

En las figuras 4.6a y 4.6b se muestra la variación del factor de calidad de identificación de las filas (Q_r) en función extensión de los perfiles de vegetación (E_p) y la distancia estimada entre filas de cultivos (W_r), respectivamente. Estos resultados fueron obtenidos para la imagen de la figura 4.5a. En la figura 4.6a puede observarse que algoritmo tiene un desempeño satisfactorio ($Q_r > 95\%$) para valores de E_p mayores a 0,5 m cuando $W_r = \{0,1, 0,2, 0,5\}$ m. Es notable que la gráfica correspondiente a $W_r = 0,4$ m presenta un comportamiento completamente opuesto: su desempeño solo es satisfactorio para $E_p < 0,5$ m y luego cae abruptamente. Nótese que $W_r = 0,4$ m corresponde a la distancia real entre los pares de filas de cultivos. En la figura 4.6b puede observarse que el valor de Q_r se mantiene por encima del 89 % para todos los valores de E_p , pero existe una caída significativa para $0,3 \text{ m} < W_r < 0,5 \text{ m}$. Este comportamiento está en correspondencia con el observado en la figura 4.5a, donde se observó

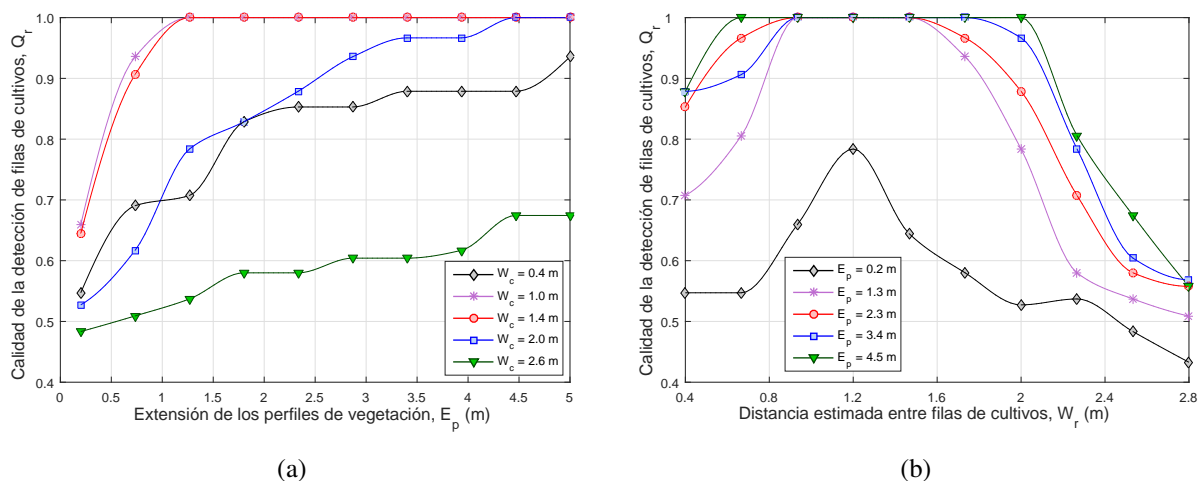


Figura 4.7: Desempeño del algoritmo de identificación de las filas de cultivos para la imagen de la figura 4.5b (a) Factor de calidad de identificación de las filas (Q_r) en función extensión de los perfiles de vegetación (E_p) (b) Factor de calidad de identificación de las filas (Q_r) en función extensión de la distancia estimada entre filas de cultivos (W_r).

que el peor desempeño ocurrió para $W_r = 0,4$ m. También puede notarse que las gráficas con peor desempeño son las que corresponden a $E_p = 0,2$ m y $E_p = 2,7$ m.

En la figura 4.7a se muestra el desempeño del algoritmo de identificación de las filas de cultivos para la imagen de la figura 4.5b. En la figura 4.7a puede observarse que algoritmo tiene el mejor desempeño para las gráficas correspondientes a $W_r = 0,5$ m y $W_r = 0,7$ m, y que para estas gráficas el valor de Q_r es del 100 % cuando $E_p > 1,5$ m. Puede notarse también que la tendencia en todas las gráficas es al aumento del valor de Q_r con el aumento del valor de E_p , aunque el desempeño para $W_r = \{0,2, 1,0, 1,3\}$ m fue pobre independientemente del valor de E_p . Los resultados que se muestran en la figura 4.7b están en correspondencia con los de la figura 4.7a. Nótese que para todas las gráficas existe un máximo en el valor de Q_r alrededor de $W_r = 0,6$ m. Todas las gráficas, excepto la que corresponde a $E_p = 0,2$ m, presentan un desempeño satisfactorio ($Q_r > 90$ %) para $0,4$ m $< W_r < 0,8$ m.

La identificación de las filas de cultivo con el algoritmo propuesto puede verse afectada por diferentes factores. La aparición de altas densidades de malezas con características similares

a los cultivos en los espacios entre filas puede conducir a la falsa identificación de filas. Por otro lado, discontinuidades en las filas de cultivo debido a la no germinación de plantas puede causar que no se identifique una fila de cultivo. La influencia negativa de estos factores puede ser controlada con la selección adecuada de los valores de los parámetros del algoritmo. En general, el algoritmo es capaz de identificar correctamente las filas de cultivo para valores de ϵ_d , ω_m y δ_p en el orden de la mitad de la distancia estimada entre filas. Como en el cultivo de estudio el valor mínimo de esta distancia es 40 cm, a estos parámetros mencionados se les asignó un valor de 20 cm. El valor de E_p debe de estar en el orden de unos pocos metros, lo suficiente para cubrir una distancia en la fila de cultivo con baja probabilidad de ocurrencia de discontinuidades. Teniendo en cuenta los resultados discutidos previamente, se utilizó $E_p = 1,0$ m.

4.3. Evaluación del algoritmo de detección y mapeado de las malezas

Para evaluar el desempeño del algoritmo de detección y mapeado de las malezas, se llevó a cabo un detallado proceso de segmentación manual de todas las malezas observadas en la imagen \mathcal{O}' . Como resultado, se obtuvo una máscara de malezas \mathcal{W}_{ref} a partir de la cual se generó un mapa de densidad de malezas de referencia, siguiendo el mismo procedimiento descrito en la sección 3.4.4. Comparando las densidades de malezas estimadas y las de referencia se realizó la evaluación cuantitativa del algoritmo. En la tabla 4.3 se muestran los valores asignados a los parámetros del algoritmo de detección y mapeado de las malezas. En la figura 4.8 se muestra un sector del campo de cultivo, rotado en dirección contraria y en la misma magnitud que la orientación de las filas de cultivos detectada, y donde se destacaron las regiones de cultivo y malezas detectadas. El método propuesto fue capaz de identificar el 100 % de las filas de cultivo del campo.

En la figura 4.9 se muestra el mapa de densidad de malezas generado y en la figura 4.10 se muestra la relación entre la densidad de malezas estimada y la observada. Del área total del campo de estudio, se estimó un 84 % con menos del 1 % de cobertura malezas, lo cual indica un alto potencial para la reducción del volumen de herbicidas aplicados. Como puede

Tabla 4.3: Valores de los parámetros del algoritmo de detección y mapeado de las malezas.

Detección y mapeado de las malezas	
Factor de ponderación de la distancia de cultivo, λ_c	0,5
Factor de ponderación de la distancia de maleza, λ_w	0,5
Dimensiones de la cuadrícula del mapa, $C_w \times C_h$	2m \times 1,5m




Figura 4.8: Regiones de cultivo y maleza detectadas.

notarse, las estimaciones obtenidas con el algoritmo desarrollado fueron satisfactorias, con un coeficiente de determinación $R^2 = 0,9875$ y un error $RMSE = 0,0747$. Los valores de densidad de maleza estimados estuvieron entre el 0% y el 6,0%, mientras que los observados estuvieron entre el 0% y el 7%. Para las regiones observadas con cero malezas existe una cierta sobrestimación, como puede notarse en la gráfica de la figura 4.10 cerca del origen. Para densidades de maleza mayores al 1% se observa una ligera subestimación, dado que la línea




Figura 4.9: Mapa de densidad de malezas.

de regresión permanece por debajo de la línea ideal 1 : 1. Desde el punto de vista agronómico, la sobrestimación resulta preferible a una subestimación, ya que en la práctica los agricultores no suelen asumir el riesgo asociado a dejar sin tratamiento de herbicidas a zonas con probable presencia de malezas.

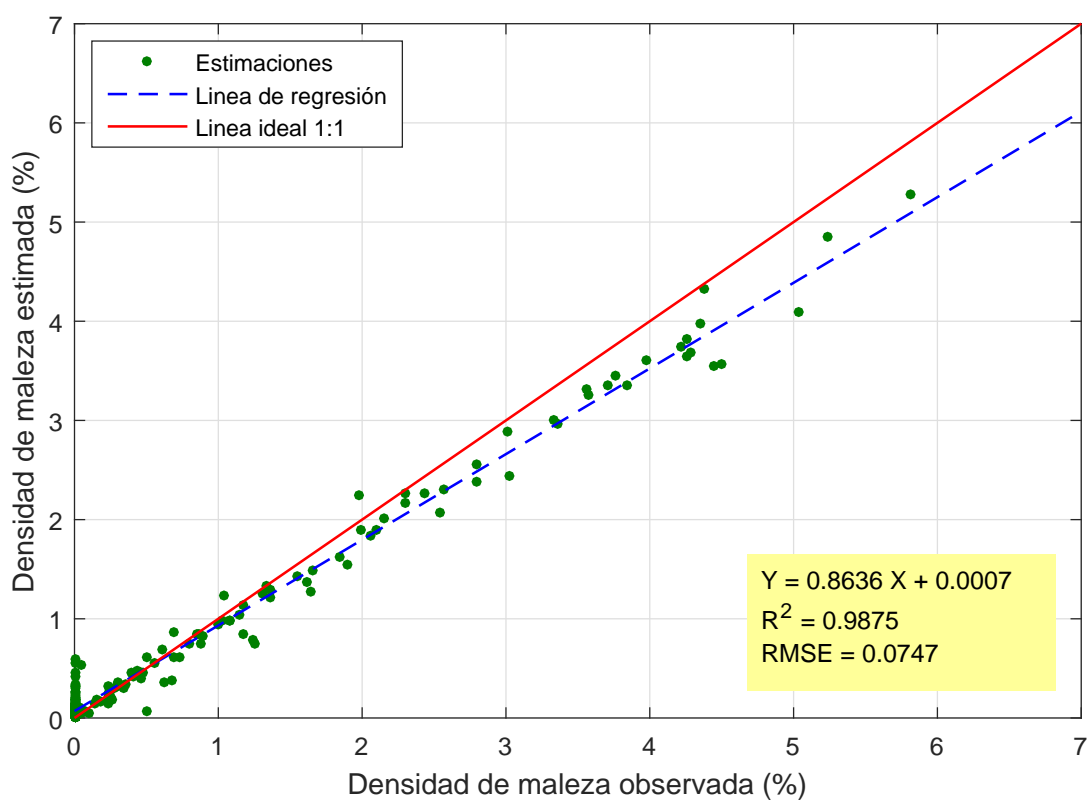


Figura 4.10: Relación entre la densidad de malezas estimada y la observada.

Conclusiones

Mediante el análisis de las imágenes aéreas del campo agrícola de estudio fue posible detectar las malezas presentes en el campo, con lo cual se corrobora la hipótesis de la investigación. En base a los conceptos de densidad lineal de vegetación y perfil de vegetación se desarrollaron los algoritmos de estimación de la orientación e identificación de las filas de cultivos. Explorando el conocimiento previo acerca de las diferencias entre los patrones de distribución de los cultivos y malezas, se logró implementar con éxito el algoritmo de detección de malezas. El algoritmo identificó correctamente todas las filas de cultivo presentes en el campo agrícola y se obtuvo una alta correspondencia entre los valores de densidad de maleza observados y estimados.

El método propuesto depende de varios parámetros que pueden ser configurados para adaptarse a condiciones diferentes a las descritas en la presente investigación. En combinación con la tecnología de los vehículos aéreos no tripulados, los resultados presentados en esta investigación pueden ser de utilidad en la implementación de medidas para el uso sostenible de herbicidas, mediante la utilización de dosis apropiadas para los niveles de infestación de malezas detectados en cada zona del campo.

Si bien se han logrado avances notables en la investigación sobre las tecnologías de visión artificial aplicadas a la agricultura, aún persisten varios desafíos asociados al desarrollo de algoritmos que sean robustos ante diferentes condiciones adversas, tales como:

- Variaciones en las condiciones de iluminación de las imágenes tomadas en exteriores.
- Presencia de sombras, tanto del tipo que proyectan las plantas sobre el suelo como del tipo de sombra proyectada por otros objetos sobre las plantas.
- Presencia de objetos, tales como residuos de paja, piedras y tuberías de agua, que pueden afectar la segmentación de las plantas.

Estos factores siguen siendo un desafío para los métodos de segmentación de vegetación, detección de filas de cultivos y detección de malezas. Por tanto, se requieren más investigaciones para optimizar al máximo la tecnología de visión por computadora para las complejas condiciones de segmentación de imágenes de campos agrícolas.

Recomendaciones

Se considera que las siguientes recomendaciones pueden ser de utilidad para enriquecer el estudio realizado y los resultados obtenidos:

- Utilizar el método desarrollado para detectar malezas en otros tipos de cultivos y evaluar su desempeño.
- Extender el método desarrollado para detectar las malezas en tiempo real para su posible utilización en un sistema integrado a bordo de un vehículo terrestre.
- Extender el algoritmo de identificación de las filas de cultivos para identificar las filas en imágenes de cultivos en proyección de perspectiva.
- Desarrollar un método para evaluar los patrones de crecimiento y evolución de las malezas mediante la superposición de los mapas de densidad de malezas obtenidos en diferentes etapas de desarrollo de los cultivos.
- Desarrollar una interfaz gráfica accesible desde la web en la cual se integren los algoritmos de procesamiento de imágenes.

Referencias

- [1] M. Oliver, T. Bishop, and B. Marchant, *Precision agriculture for sustainability and environmental protection*. Routledge, 2013.
- [2] R. Lal and B. A. Stewart, *Soil-Specific Farming: Precision Agriculture*. CRC Press, 2015, vol. 22.
- [3] T. Garnett, M. C. Appleby, A. Balmford, I. J. Bateman, T. G. Benton, P. Bloomer, B. Burlingame, M. Dawkins, L. Dolan, D. Fraser *et al.*, “Sustainable intensification in agriculture: premises and policies,” *Science*, vol. 341, no. 6141, pp. 33–34, 2013.
- [4] A. McBratney, B. Whelan, T. Ancev, and J. Bouma, “Future directions of precision agriculture,” *Precision agriculture*, vol. 6, no. 1, pp. 7–23, 2005.
- [5] J. F. Shanahan, J. S. Schepers, D. D. Francis, G. E. Varvel, W. W. Wilhelm, J. M. Tringe, M. R. Schlemmer, and D. J. Major, “Use of remote-sensing imagery to estimate corn grain yield,” *Agronomy Journal*, vol. 93, no. 3, pp. 583–589, 2001.
- [6] C. Yang, J. Everitt, J. Bradford, and D. Escobar, “Mapping grain sorghum growth and yield variations using airborne multispectral digital imagery,” *Transactions of the ASAE*, vol. 43, no. 6, p. 1927, 2000.
- [7] W. G. Bastiaanssen, D. J. Molden, and I. W. Makin, “Remote sensing for irrigated agriculture: examples from research and possible applications,” *Agricultural water management*, vol. 46, no. 2, pp. 137–155, 2000.
- [8] D. Clay, K.-I. Kim, J. Chang, S. Clay, and K. Dalsted, “Characterizing water and nitrogen stress in corn using remote sensing,” *Agronomy Journal*, vol. 98, no. 3, pp. 579–587, 2006.
- [9] B. J. Erickson, C. J. Johannsen, J. J. Vorst, and L. L. Biehl, “Using remote sensing to assess stand loss and defoliation in maize,” *Photogrammetric Engineering & Remote Sensing*, vol. 70, no. 6, pp. 717–722, 2004.
- [10] I. Scotford and P. Miller, “Applications of spectral reflectance techniques in northern european cereal production: a review,” *Biosystems engineering*, vol. 90, no. 3, pp. 235–250, 2005.

- [11] M. S. Laursen, R. N. Jørgensen, H. S. Midtiby, K. Jensen, M. P. Christiansen, T. M. Gisselsson, A. K. Mortensen, and P. K. Jensen, "Dicotyledon weed quantification algorithm for selective herbicide application in maize crops," *Sensors*, vol. 16, no. 11, p. 1848, 2016.
- [12] Y. Lan, Y. Huang, D. Martin, and W. Hoffmann, "Development of an airborne remote sensing system for crop pest management: system integration and verification," *Applied engineering in agriculture*, vol. 25, no. 4, pp. 607–615, 2009.
- [13] F. Garcia-Ruiz, S. Sankaran, J. M. Maja, W. S. Lee, J. Rasmussen, and R. Ehsani, "Comparison of two aerial imaging platforms for identification of huanglongbing-infected citrus trees," *Computers and Electronics in Agriculture*, vol. 91, pp. 106–115, 2013.
- [14] D. Corwin and S. Lesch, "Application of soil electrical conductivity to precision agriculture," *Agronomy journal*, vol. 95, no. 3, pp. 455–471, 2003.
- [15] C. D. Christy, "Real-time measurement of soil attributes using on-the-go near infrared reflectance spectroscopy," *Computers and electronics in agriculture*, vol. 61, no. 1, pp. 10–19, 2008.
- [16] W. R. DeTar, J. H. Chesson, J. V. Penner, and J. C. Ojala, "Detection of soil properties with airborne hyperspectral measurements of bare fields," *Transactions of the ASABE*, vol. 51, no. 2, pp. 463–470, 2008.
- [17] C. Gomez, R. A. V. Rossel, and A. B. McBratney, "Soil organic carbon prediction by hyperspectral remote sensing and field vis-NIR spectroscopy: An australian case study," *Geoderma*, vol. 146, no. 3, pp. 403–411, 2008.
- [18] A. E. Smith, *Handbook of weed management systems*. Routledge, 2017.
- [19] G. Fried, B. Chauvel, P. Reynaud, and I. Sache, "Decreases in crop production by non-native weeds, pests, and pathogens," in *Impact of biological invasions on ecosystem services*. Springer, 2017, pp. 83–101.
- [20] N. Soltani, J. A. Dille, I. C. Burke, W. J. Everman, M. J. VanGessel, V. M. Davis, and P. H. Sikkema, "Potential corn yield losses from weeds in north america," *Weed Technology*, vol. 30, no. 4, pp. 979–984, 2016.
- [21] S. Fahad, S. Hussain, B. S. Chauhan, S. Saud, C. Wu, S. Hassan, M. Tanveer, A. Jan, and J. Huang, "Weed growth and crop yield loss in wheat as influenced by row spacing and weed emergence times," *Crop Protection*, vol. 71, pp. 101–108, 2015.
- [22] M. Liebman, B. Baraibar, Y. Buckley, D. Childs, S. Christensen, R. Cousens, H. Eizenberg, S. Heijting, D. Loddo, A. Merotto *et al.*, "Ecologically sustainable weed management: How do we get from proof-of-concept to adoption?" *Ecological applications*, vol. 26, no. 5, pp. 1352–1369, 2016.

- [23] S. Petit, N. Munier-Jolain, V. Bretagnolle, C. Bockstaller, S. Gaba, S. Cordeau, M. Lechenet, D. Mézière, and N. Colbach, “Ecological intensification through pesticide reduction: weed control, weed biodiversity and sustainability in arable farming,” *Environmental management*, vol. 56, no. 5, pp. 1078–1090, 2015.
- [24] K.-H. Dammer, “Real-time variable-rate herbicide application for weed control in carrots,” *Weed Research*, vol. 56, no. 3, pp. 237–246, 2016.
- [25] B. S. Chauhan, S. Ahmed, T. H. Awan, K. Jabran, and S. Manalil, “Integrated weed management approach to improve weed control efficiencies for sustainable rice production in dry-seeded systems,” *Crop Protection*, vol. 71, pp. 19–24, 2015.
- [26] I. Borra-Serrano, J. M. Peña, J. Torres-Sánchez, F. J. Mesas-Carrascosa, and F. López-Granados, “Spatial quality evaluation of resampled unmanned aerial vehicle-imagery for weed mapping,” *Sensors*, vol. 15, no. 8, pp. 19 688–19 708, 2015.
- [27] J. P. Myers, M. N. Antoniou, B. Blumberg, L. Carroll, T. Colborn, L. G. Everett, M. Hansen, P. J. Landrigan, B. P. Lanphear, R. Mesnage *et al.*, “Concerns over use of glyphosate-based herbicides and risks associated with exposures: a consensus statement,” *Environmental Health*, vol. 15, no. 1, p. 19, 2016.
- [28] F. Castaldi, F. Pelosi, S. Pascucci, and R. Casa, “Assessing the potential of images from unmanned aerial vehicles (UAV) to support herbicide patch spraying in maize,” *Precision Agriculture*, vol. 18, no. 1, pp. 76–94, 2017.
- [29] C. Tardif-Paradis, M.-J. Simard, G. D. Leroux, B. Panneton, R. E. Nurse, and A. Vanasse, “Effect of planter and tractor wheels on row and inter-row weed populations,” *Crop Protection*, vol. 71, pp. 66–71, 2015.
- [30] F. López-Granados, J. Torres-Sánchez, A. Serrano-Pérez, A. I. de Castro, F.-J. Mesas-Carrascosa, and J.-M. Peña, “Early season weed mapping in sunflower using UAV technology: variability of herbicide treatment maps against weed thresholds,” *Precision agriculture*, vol. 17, no. 2, pp. 183–199, 2016.
- [31] J. M. Peña, J. Torres-Sánchez, A. Serrano-Pérez, A. I. de Castro, and F. López-Granados, “Quantifying efficacy and limits of unmanned aerial vehicle (UAV) technology for weed seedling detection as affected by sensor resolution,” *Sensors*, vol. 15, no. 3, pp. 5609–5626, 2015.
- [32] S. Sankaran, L. R. Khot, C. Z. Espinoza, S. Jarolmasjed, V. R. Sathuvalli, G. J. Vandemark, P. N. Miklas, A. H. Carter, M. O. Pumphrey, N. R. Knowles *et al.*, “Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: A review,” *European Journal of Agronomy*, vol. 70, pp. 112–123, 2015.
- [33] C. Hung, Z. Xu, and S. Sukkarieh, “Feature learning based approach for weed classification using high resolution aerial images from a digital camera mounted on a UAV,” *Remote Sensing*, vol. 6, no. 12, pp. 12 037–12 054, 2014.

- [34] J. M. Peña, J. Torres-Sánchez, A. I. de Castro, M. Kelly, and F. López-Granados, “Weed mapping in early-season maize fields using object-based analysis of unmanned aerial vehicle (UAV) images,” *PLoS One*, vol. 8, no. 10, p. e77151, 2013.
- [35] M.-L. NAVAS, “Using plant population biology in weed research: a strategy to improve weed management,” *Weed Research*, vol. 31, no. 4, pp. 171–179, 1991.
- [36] M. Sujaritha, S. Annadurai, J. Satheeshkumar, S. K. Sharan, and L. Mahesh, “Weed detecting robot in sugarcane fields using fuzzy real time classifier,” *Computers and electronics in agriculture*, vol. 134, pp. 160–171, 2017.
- [37] Y. Zheng, Q. Zhu, M. Huang, Y. Guo, and J. Qin, “Maize and weed classification using color indices with support vector data description in outdoor fields,” *Computers and Electronics in Agriculture*, vol. 141, pp. 215–222, 2017.
- [38] A. Bakhshipour, A. Jafari, S. M. Nassiri, and D. Zare, “Weed segmentation using texture features extracted from wavelet sub-images,” *Biosystems Engineering*, vol. 157, pp. 1–12, 2017.
- [39] J.-L. Tang, X.-Q. Chen, R.-H. Miao, and D. Wang, “Weed detection using image processing under different illumination for site-specific areas spraying,” *Computers and Electronics in Agriculture*, vol. 122, pp. 103–111, 2016.
- [40] D. M. Woebbecke, G. E. Meyer, K. Von Bargen, and D. A. Mortensen, “Plant species identification, size, and enumeration using machine vision techniques on near-binary images,” in *Optics in Agriculture and Forestry*, vol. 1836. International Society for Optics and Photonics, 1993, pp. 208–220.
- [41] D. M. Woebbecke, G. E. Meyer, K. Von Bargen, and D. Mortensen, “Color indices for weed identification under various soil, residue, and lighting conditions,” *Transactions of the ASAE*, vol. 38, no. 1, pp. 259–269, 1995.
- [42] G. E. Meyer, T. W. Hindman, and K. Laksmi, “Machine vision detection parameters for plant species identification,” in *Precision Agriculture and Biological Quality*, vol. 3543. International Society for Optics and Photonics, 1999, pp. 327–336.
- [43] T. Kataoka, T. Kaneko, H. Okamoto, and S. Hata, “Crop growth estimation system using machine vision,” in *Advanced Intelligent Mechatronics, 2003. AIM 2003. Proceedings. 2003 IEEE/ASME International Conference on*, vol. 2. IEEE, 2003, pp. b1079–b1083.
- [44] J. Camargo Neto, “A combined statistical-soft computing approach for classification and mapping weed species in minimum-tillage systems,” Ph.D. dissertation, University of Nebraska, Lincoln, NE, 2004.
- [45] T. Hague, N. Tillett, and H. Wheeler, “Automated crop and weed monitoring in widely spaced cereals,” *Precision Agriculture*, vol. 7, no. 1, pp. 21–32, 2006.

- [46] M. Guijarro, G. Pajares, I. Riomoros, P. Herrera, X. Burgos-Artizzu, and A. Ribeiro, "Automatic segmentation of relevant textures in agricultural images," *Computers and Electronics in Agriculture*, vol. 75, no. 1, pp. 75–83, 2011.
- [47] X. P. Burgos-Artizzu, A. Ribeiro, M. Guijarro, and G. Pajares, "Real-time image processing for crop/weed discrimination in maize fields," *Computers and Electronics in Agriculture*, vol. 75, no. 2, pp. 337–346, 2011.
- [48] J. M. Guerrero, G. Pajares, M. Montalvo, J. Romeo, and M. Guijarro, "Support vector machines for crop/weeds identification in maize fields," *Expert Systems with Applications*, vol. 39, no. 12, pp. 11 149–11 155, 2012.
- [49] M. H. J. Vala and A. Baxi, "A review on otsu image segmentation algorithm," *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, vol. 2, no. 2, pp. pp–387, 2013.
- [50] G. E. Meyer and J. C. Neto, "Verification of color vegetation indices for automated crop imaging applications," *Computers and electronics in agriculture*, vol. 63, no. 2, pp. 282–293, 2008.
- [51] L. Zheng, J. Zhang, and Q. Wang, "Mean-shift-based color segmentation of images containing green vegetation," *Computers and Electronics in Agriculture*, vol. 65, no. 1, pp. 93–98, 2009.
- [52] L. Zheng, D. Shi, and J. Zhang, "Segmentation of green vegetation of crop canopy images based on mean shift and fisher linear discriminant," *Pattern Recognition Letters*, vol. 31, no. 9, pp. 920–925, 2010.
- [53] Z. Yu, Z. Cao, X. Wu, X. Bai, Y. Qin, W. Zhuo, Y. Xiao, X. Zhang, and H. Xue, "Automatic image-based detection technology for two critical growth stages of maize: Emergence and three-leaf stage," *Agricultural and Forest Meteorology*, vol. 174, pp. 65–84, 2013.
- [54] A. Tellaeché, X. P. Burgos-Artizzu, G. Pajares, and A. Ribeiro, "A vision-based method for weeds identification through the bayesian decision theory," *Pattern Recognition*, vol. 41, no. 2, pp. 521–530, 2008.
- [55] N. Otsu, "A threshold selection method from gray-level histograms," *IEEE transactions on systems, man, and cybernetics*, vol. 9, no. 1, pp. 62–66, 1979.
- [56] S. Gebhardt, J. Schellberg, R. Lock, and W. Kühbauch, "Identification of broad-leaved dock (*Rumex obtusifolius* L.) on grassland by means of digital image processing," *Precision Agriculture*, vol. 7, no. 3, pp. 165–178, 2006.
- [57] K. Kirk, H. J. Andersen, A. G. Thomsen, J. R. Jørgensen, and R. N. Jørgensen, "Estimation of leaf area index in cereal crops using red–green images," *Biosystems Engineering*, vol. 104, no. 3, pp. 308–317, 2009.

- [58] G. E. Meyer, J. C. Neto, D. D. Jones, and T. W. Hindman, "Intensified fuzzy clusters for classifying plant, soil, and residue regions of interest from color images," *Computers and electronics in agriculture*, vol. 42, no. 3, pp. 161–180, 2004.
- [59] W. Guo, U. K. Rage, and S. Ninomiya, "Illumination invariant segmentation of vegetation for time series wheat images based on decision tree model," *Computers and electronics in agriculture*, vol. 96, pp. 58–66, 2013.
- [60] X. Bai, Z. Cao, Y. Wang, Z. Yu, X. Zhang, and C. Li, "Crop segmentation from images by morphology modeling in the CIE L*a*b* color space," *Computers and electronics in agriculture*, vol. 99, pp. 21–34, 2013.
- [61] X. Bai, Z. Cao, Y. Wang, Z. Yu, Z. Hu, X. Zhang, and C. Li, "Vegetation segmentation robust to illumination variations based on clustering and morphology modelling," *Biosystems engineering*, vol. 125, pp. 80–97, 2014.
- [62] P. V. Hough, "Method and means for recognizing complex patterns," 1962, US Patent Office No. 3069654.
- [63] J. Marchant, "Tracking of row structure in three crops using image analysis," *Computers and electronics in agriculture*, vol. 15, no. 2, pp. 161–179, 1996.
- [64] B. Åstrand and A.-J. Baerveldt, "A vision based row-following system for agricultural field machinery," *Mechatronics*, vol. 15, no. 2, pp. 251–269, 2005.
- [65] T. Bakker, H. Wouters, K. Van Asselt, J. Bontsema, L. Tang, J. Müller, and G. van Straten, "A vision based row detection system for sugar beet," *Computers and electronics in agriculture*, vol. 60, no. 1, pp. 87–95, 2008.
- [66] T. Bakker, K. van Asselt, J. Bontsema, J. Müller, and G. van Straten, "Autonomous navigation using a robot platform in a sugar beet field," *Biosystems Engineering*, vol. 109, no. 4, pp. 357–368, 2011.
- [67] F. Rovira-Más, Q. Zhang, J. Reid, and J. Will, "Hough-transform-based vision algorithm for crop row detection of an automated agricultural vehicle," *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, vol. 219, no. 8, pp. 999–1010, 2005.
- [68] A. Tellaeché, X. P. Burgos-Artizzu, G. Pajares, A. Ribeiro, and C. Fernández-Quintanilla, "A new vision-based approach to differential spraying in precision agriculture," *Computers and electronics in agriculture*, vol. 60, no. 2, pp. 144–155, 2008.
- [69] A. Tellaeché, X. P. Burgos-Artizzu, G. Pajares, and A. Ribeiro, "A vision-based method for weeds identification through the bayesian decision theory," *Pattern Recognition*, vol. 41, no. 2, pp. 521–530, 2008.
- [70] R. Ji and L. Qi, "Crop-row detection algorithm based on random hough transformation," *Mathematical and Computer Modelling*, vol. 54, no. 3-4, pp. 1016–1020, 2011.

- [71] C. Gée, J. Bossu, G. Jones, and F. Truchetet, “Crop/weed discrimination in perspective agronomic images,” *Computers and Electronics in Agriculture*, vol. 60, no. 1, pp. 49–59, 2008.
- [72] V. Leemans and M.-F. Destain, “Line cluster detection using a variant of the hough transform for culture row localisation,” *Image and Vision Computing*, vol. 24, no. 5, pp. 541–550, 2006.
- [73] M. Z. M. Jafri and F. Deravi, “Efficient algorithm for the detection of parabolic curves,” in *Vision Geometry III*, vol. 2356. International Society for Optics and Photonics, 1995, pp. 53–62.
- [74] J. Billingsley and M. Schoenfisch, “The successful development of a vision guidance system for agriculture,” *Computers and electronics in agriculture*, vol. 16, no. 2, pp. 147–163, 1997.
- [75] N. Tillett and T. Hague, “Computer-vision-based hoe guidance for cereals-an initial trial,” *Journal of Agricultural Engineering Research*, vol. 74, no. 3, pp. 225–236, 1999.
- [76] H. T. Søgaaard and H. J. Olsen, “Determination of crop rows by image analysis without segmentation,” *Computers and electronics in agriculture*, vol. 38, no. 2, pp. 141–158, 2003.
- [77] M. Montalvo, J. M. Guerrero, J. Romeo, L. Emmi, M. Guijarro, and G. Pajares, “Automatic expert system for weeds/crops identification in images from maize fields,” *Expert Systems with Applications*, vol. 40, no. 1, pp. 75–82, 2013.
- [78] J. M. Guerrero, M. Guijarro, M. Montalvo, J. Romeo, L. Emmi, A. Ribeiro, and G. Pajares, “Automatic expert system based on images for accuracy crop row detection in maize fields,” *Expert Systems with Applications*, vol. 40, no. 2, pp. 656–664, 2013.
- [79] I. Vidović and R. Scitovski, “Center-based clustering for line detection and application to crop rows detection,” *Computers and electronics in agriculture*, vol. 109, pp. 212–220, 2014.
- [80] N. Sainz-Costa, A. Ribeiro, X. P. Burgos-Artizzu, M. Guijarro, and G. Pajares, “Mapping wide row crops with video sequences acquired from a tractor moving at treatment speed,” *Sensors*, vol. 11, no. 7, pp. 7095–7109, 2011.
- [81] G. Jiang, X. Wang, Z. Wang, and H. Liu, “Wheat rows detection at the early growth stage based on hough transform and vanishing point,” *Computers and Electronics in Agriculture*, vol. 123, pp. 211–223, 2016.
- [82] J. Romeo, G. Pajares, M. Montalvo, J. Guerrero, M. Guijarro, and A. Ribeiro, “Crop row detection in maize fields inspired on the human visual perception,” *The Scientific World Journal*, vol. 2012, 2012.

- [83] T. Hague and N. Tillett, “A bandpass filter-based approach to crop row location and tracking,” *Mechatronics*, vol. 11, no. 1, pp. 1–12, 2001.
- [84] J.-B. Vioix, J.-P. Douzals, F. Truchetet, L. Assémat, and J.-P. Guillemin, “Spatial and spectral methods for weed detection and localization,” *Eurasip Journal on Advances in Signal Processing*, vol. 2002, no. 7, p. 793080, 2002.
- [85] J. Bossu, C. Gée, G. Jones, and F. Truchetet, “Wavelet transform to discriminate between crop and weed in perspective agronomic images,” *computers and electronics in agriculture*, vol. 65, no. 1, pp. 133–143, 2009.
- [86] M. Kise and Q. Zhang, “Development of a stereovision sensing system for 3d crop row structure mapping and tractor guidance,” *Biosystems Engineering*, vol. 101, no. 2, pp. 191–198, 2008.
- [87] F. Rovira-Más, Q. Zhang, and J. F. Reid, “Stereo vision three-dimensional terrain maps for precision agriculture,” *Computers and Electronics in Agriculture*, vol. 60, no. 2, pp. 133–143, 2008.
- [88] J. Lambert, H. Hicks, D. Childs, and R. Freckleton, “Evaluating the potential of unmanned aerial systems for mapping weeds at field scales: a case study with *alopecurus myosuroides*,” *Weed Research*, vol. 58, no. 1, pp. 35–45, 2018.
- [89] T. K. Alexandridis, A. A. Tamouridou, X. E. Pantazi, A. L. Lagopodi, J. Kashefi, G. Ovakoglou, V. Polychronos, and D. Moshou, “Novelty detection classifiers in weed mapping: *Silybum marianum* detection on UAV multispectral images,” *Sensors*, vol. 17, no. 9, p. 2007, 2017.
- [90] C. Franco, S. M. Pedersen, H. Papaharalampos, and J. E. Ørum, “The value of precision for image-based decision support in weed management,” *Precision Agriculture*, vol. 18, no. 3, pp. 366–382, 2017.
- [91] F. López-Granados, J. Torres-Sánchez, A.-I. De Castro, A. Serrano-Pérez, F.-J. Mesas-Carrascosa, and J.-M. Peña, “Object-based early monitoring of a grass weed in a grass crop using high resolution UAV imagery,” *Agronomy for sustainable development*, vol. 36, no. 4, p. 67, 2016.
- [92] U. Meier, *Growth stages of mono-and dicotyledonous plants. BBCH Monograph*. Berlin/Braunschweig, Germany: Federal Biological Research Centre for Agriculture and Forestry, 1997.
- [93] F. Chiabrando, E. Donadio, and F. Rinaudo, “Sfm for orthophoto to generation: A winning approach for cultural heritage knowledge,” *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 40, no. 5, p. 91, 2015.
- [94] J. Park, H. Jeong, J. Kim, and C. Choi, “Development of open source-based automatic shooting and processing UAV imagery for orthoimage using smart camera UAV,” *ISPRS Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. 41, p. B7, 2016.

- [95] I. H. Witten, E. Frank, M. A. Hall, and C. J. Pal, *Data Mining: Practical machine learning tools and techniques*. Morgan Kaufmann, 2016.