



UNIVERSIDAD NACIONAL DE COLOMBIA

# Método para la estimación de maleza en cultivos de lechuga utilizando aprendizaje profundo e imágenes multiespectrales

**Anderson Kavir Osorio Delgado**

Universidad Nacional de Colombia  
Facultad de Ingeniería, Departamento de Ingeniería de Sistemas e Industrial.  
Bogotá D.C, Colombia  
2021



# Método para la estimación de maleza en cultivos de lechuga utilizando aprendizaje profundo e imágenes multiespectrales

**Anderson Kavir Osorio Delgado**

Tesis presentada como requisito parcial para optar al título de:  
**Magister en Ingeniería de Sistemas y Computación**

Director:

Ph.D., César Augusto Pedraza Bonilla

Codirector:

M.Sc., Leonardo Rodríguez Mújica

Línea de Investigación:

Agricultura de precisión

Grupo de Investigación:

PLaS - Programming Languages and Systems

Universidad Nacional de Colombia

Facultad de Ingeniería, Departamento de Ingeniería de Sistemas e Industrial.

Bogotá D.C, Colombia

2021



A mi familia.

A la vida misma que se abre paso de manera resiliente en el tiempo y entre partículas al punto de darnos conciencia para entender su grandeza y perpetuidad.



# Agradecimientos

A mi director de tesis profesor César Augusto Pedraza Bonilla, a mi codirector de tesis el profesor Leonardo Rodríguez, al profesor Andrés Esteban Puerto Lara el cual sentó las bases con sus trabajos previos en esta línea de investigación y al Grupo de investigación PLaS y sus integrantes siempre dispuestos a escuchar y aportar.



# Resumen

## **Método para la estimación de maleza en cultivos de lechuga utilizando aprendizaje profundo e imágenes multiespectrales**

La estimación de maleza es una de las tareas más importantes durante el proceso de control de maleza, pues de esta depende la estimación de costos que deberán emplearse para proteger el cultivo, por tanto este trabajo presenta el desarrollo de un método que utiliza imágenes multiespectrales capturadas por un vehículo aéreo no tripulado y redes neuronales convolucionales para realizar la estimación porcentual de maleza en cultivos de lechuga. El método presentado tiene una exactitud del 89% y un valor-F de 94% para la detección del cultivo, con un tiempo de ejecución promedio de 0.4 segundos sin GPU y una correlación de 0.57 en la evaluación de cobertura de maleza en relación con un Ph.D en malherbología. Estos resultados indican que la tarea de estimación de maleza usando CNNs es más precisa y rápida que la realizada por expertos, pero sin alejarse del conocimiento tácito el cual es importante en la estimación de costos y recursos para el control de la maleza.

**Palabras clave:** Agricultura de precisión, Lechuga, Maleza, Detección de Malezas, Imágenes multiespectrales, Inteligencia artificial, Aprendizaje automático, Aprendizaje profundo, Redes neuronales convolucionales.

# Abstract

## **Method for weed estimation in lettuce crops using deep learning and multispectral imagery**

Weed estimation is one of the most important tasks during the weed control process. The estimation of costs to be used to protect the crop depends on it. Therefore, this work presents the development of a method, which uses multispectral images captured by an unmanned aerial vehicle and convolutional neural networks. In order to perform percentage quantification of weeds in lettuce crops. The presented method has an accuracy of 89% and an F-value of 94% for crop detection. Its average run time is 0.4 seconds without GPU. In addition to a correlation of 0.57 in the weed cover assessment in relation to a Ph.D. weed science expert. These results indicate that the weed estimation task using CNNs is more accurate and faster than that performed by experts. But without departing from the tacit knowledge which is important in estimating costs and resources for weed control.

**Keywords:** Weed detection, Weed estimation, Artificial intelligence, Machine learning, Smart agriculture, Precision agriculture, Convolutional Neural networks, Deep learning, Multispectral images, Weed mapping, Lettuce crops

Esta tesis de maestría se sustentó el 13 de 09 de 2021 a las 10:00 am - 12:00 pm,  
y fue evaluada por los siguientes jurados:

Jaime Vitola Oyaga

Universidad Santo Tomás

Edgar Hernando Criollo Velázquez

Universidad de Cundinamarca

# Contenido

<b>Agradecimientos</b>	<b>vii</b>
<b>Resumen</b>	<b>ix</b>
<b>Lista de figuras</b>	<b>xii</b>
<b>1 Introducción</b>	<b>2</b>
<b>2 Objetivos</b>	<b>4</b>
2.1 Objetivo General . . . . .	4
2.2 Objetivos específicos . . . . .	4
<b>3 Estado del arte</b>	<b>5</b>
<b>4 Metodología</b>	<b>14</b>
4.1 Conjunto de datos . . . . .	15
4.2 Selección de imágenes y etiquetado . . . . .	16
4.3 Preprocesado . . . . .	17
4.4 Selección del Método . . . . .	18
4.5 Método base y selección de tipo de imagen multiespectral . . . . .	19
4.6 Selección del tipo de imagen multiespectral . . . . .	21
4.7 Métodos propuestos . . . . .	22
4.7.1 Método 1 Detección dos clases con Yolo V3 . . . . .	22
4.7.2 Método 2 Detección una clase con segmentación NDVI . . . . .	25
<b>5 Análisis y comparación</b>	<b>27</b>
<b>6 Conclusiones y trabajo futuro</b>	<b>31</b>
6.1 Conclusiones . . . . .	31
6.2 Publicación . . . . .	32
6.3 Trabajo futuro . . . . .	32
<b>Bibliografía</b>	<b>36</b>

# Lista de Figuras

4-1	Metodología . . . . .	14
4-2	Mavic Pro equipado con la cámara multiespectral Parrot Sequoia. . . . .	15
4-3	Imágenes obtenidas con la cámara multiespectral Parrot Sequoia. . . . .	15
4-4	Etiquetado de imagen - Altura elevada . . . . .	16
4-5	a. NDVI-32, b. Falso Verde, c. NDVI-64, d. Rojos filtrados . . . . .	17
4-6	Arquitectura YOLOv1. Tomado de [Redmon J. and A., 2016] . . . . .	18
4-7	Arquitectura extractor de características YOLOv3.[Redmon and Farhadi, 2018]	19
4-8	Diagrama del preprocesado para obtener imagen multiespectral en falso verde.	22
4-9	Diagrama método 1. . . . .	23
4-10	Imagen de salida YOLOv3 Modelo B . . . . .	24
4-11	Diagrama método 2 . . . . .	25
5-1	Matriz de correlación métodos y expertos. . . . .	27
5-2	Distribución de probabilidad para las evaluaciones de maleza. . . . .	28
5-3	Tiempo promedio de procesamiento por imagen. . . . .	29
6-1	Captura artículo publicado en MDPI por la revista AgriEngineering . . . . .	32
6-2	AgroIA inicio . . . . .	33
6-3	AgroIA tablero . . . . .	33
6-4	AgroIA formulario de carga . . . . .	34
6-5	AgroIA resultados . . . . .	35

# 1 Introducción

Actualmente con el aumento de la población en el mundo, la demanda de alimento crece proporcionalmente. Y teniendo en cuenta los recursos limitados de tierra, agua y mano de obra, se estima que la eficiencia de la productividad agrícola debe aumentar en un 25 % para el año 2050 [Cheng and Matson, 2015]. Por lo anterior, es de vital importancia enfocarse en las problemáticas que enfrenta la industria agrícola. Liakos *et al.* [Liakos et al., 2018] proponen diferentes categorías para clasificar los retos afrontados por el campo del aprendizaje automático en la agricultura de precisión, como lo son: la administración del ganado, la administración del agua, el manejo del suelo, la detección de enfermedades en plantas, la calidad del cultivo, el reconocimiento de especies y la detección de maleza. Esta última categoría ayuda a enfrentar una de las amenazas más importantes contra la productividad de los cultivos, puesto que las malezas le quitan al cultivo nutrientes, agua y luz solar. Además, son difíciles de detectar debido a su crecimiento aleatorio y su solapamiento con el cultivo [Wang et al., 2019].

La técnica más antigua utilizada para enfrentar la amenaza de las malezas en los cultivos es el deshierbe manual, pero este tiene un alto coste en mano de obra y tiempo que lo hace ineficiente en cultivos a mayor escala, por lo cual hoy en día la industria agrícola tiene sistemas de deshierbe mecanizado y motorizado, no obstante, estos dependen mucho del espacio en las hileras del cultivo y de su contextura, lo que no los hace aptos para toda clase de campos y genera un margen de error de deshierbe elevado, además que pueden causar daños en las plantas. El método más empleado en el mundo es la erradicación o control químico, el cual presenta sus propios retos en costos y políticas ambientales lo que hace importante la optimización en la localización, en la estimación de la maleza y en el cálculo de cantidades de los herbicidas empleados [Cheng and Matson, 2015].

En la década de los ochenta, las imágenes digitales empezaron a usarse para la detección de malezas, desde entonces el uso de imágenes digitales para la agricultura fue creciendo y especializándose, llegando a tener cámaras multiespectrales enfocadas a la agricultura utilizando como eje principal los diferentes índices de vegetación y sus importantes correlaciones con características y componentes vegetales [Thorp and Tian, 2004, Lameski et al., 2018]. Este trabajo usa tecnologías como las imágenes multiespectrales y la inteligencia artificial para sumarse a los esfuerzos en diseñar, mejorar e implementar algoritmos que ayuden en el campo de la agricultura de precisión y control de malezas en nuestro país.

Actualmente en Colombia la detección de maleza es un problema que dificulta la producción de los cultivos, puesto que es la tarea más importante para el control y erradicación de la

vegetación no deseada. El muestreo convencional es el método de estimación y clasificación de malezas más usado en el país, pero este demanda bastante tiempo en su ejecución, puede contener errores de estimación y la varianza de los datos obtenidos entre expertos es considerablemente alta [Puerto, 2019]. Por lo anterior, es necesario plantear, proponer y desarrollar métodos computacionales acordes a las tendencias del mundo actual para la detección de maleza, que mejoren la exactitud de la evaluación de la cobertura de maleza teniendo en cuenta el conocimiento y la experiencia de profesionales expertos, y que además involucren tecnologías que ayuden a mejorar el proceso como los sistemas aéreos no tripulados o UAS (Por sus siglas en inglés Unmanned Aircraft Systems), cámaras multiespectrales y técnicas de inteligencia artificial [Barrero et al., 2016, Kamilaris and Prenafeta-Boldú, 2018, Hernández, 2017].

Uno de los cultivos más afectados por la maleza es de la lechuga, esta hortaliza en etapas tempranas del cultivo se ve afectada gravemente, ya que puede atraer insectos, generando enfermedades y afectando su crecimiento por lo que requiere un control periódico con químicos [Fuentes and Romero, 1991, CCB, 2015, INDAP, 2017]. Considerando lo anterior, este trabajo presenta un método funcional para la estimación porcentual de maleza en cultivos de lechuga. Primero, se presenta un análisis literario en el cual el autor se basó para diseñar los métodos. Segundo, se presentan métodos los cuales usan redes neuronales convolucionales e imágenes digitales tomadas por una cámara multiespectral de cuatro bandas: verde, rojo, rojo cercano e infrarrojo, para su entrenamiento y evaluación. Y tercero, se evalúa el desempeño de los métodos tanto en la detección de malezas y cultivos como en la evaluación porcentual de cobertura de maleza en las imágenes, comparando sus resultados con evaluaciones reales realizadas por expertos en malherbología, logrando una exactitud del 89% en la identificación del cultivo y un valor de correlación de 0.57 con respecto a la evaluación del experto con más experiencia en control de malezas.

## **2 Objetivos**

### **2.1. Objetivo General**

- Proponer un método para la estimación de maleza en cultivos de lechuga basado en técnicas de aprendizaje profundo utilizando imágenes multiespectrales.

### **2.2. Objetivos específicos**

- Determinar por medio de una revisión de literatura los métodos y características con mejor desempeño en la estimación, detección y localización de maleza en cultivos.
- Diseñar al menos dos métodos basados en aprendizaje de máquina, para la estimación de maleza en cultivos de lechuga mediante imágenes multiespectrales.
- Evaluar los resultados de los métodos diseñados para la estimación de maleza mediante un conjunto de datos real.

### 3 Estado del arte

Desde la década de 1940 el método utilizado con mayor frecuencia para el control de malezas es la eliminación química, pero debido a las políticas de uso en algunas naciones y el costo elevado en países con procesos de agricultura precarios, se da la necesidad de realizar procesos de detección y cálculo de maleza con el fin de reducir el impacto ambiental de los herbicidas y optimizar su uso [Hamuda et al., 2018]. Ambrosio *et al.* [Wang et al., 2019] afirma que el muestreo convencional por mallas cuadradas es uno de los métodos más simples y efectivos, ya que da la posibilidad de determinar la densidad de maleza como una variable que puede seguir una distribución de probabilidad de Poisson o binomial negativa [Puerto, 2019].

La teledetección agrícola comenzó a mediados del siglo XX, aunque no se utilizó para la detección de malezas hasta la década de los ochenta [Thorp and Tian, 2004], actualmente el uso de imágenes digitales es ampliamente usado desde el uso de cámaras caseras capturando manualmente imágenes de las hileras del cultivo en perspectiva y realizando grandes recorridos para localizar las zonas con malezas [Tellaache et al., 2008], hasta el análisis de imágenes remotas capturadas desde aeronaves y satélites, lo cual daba buenos resultados en el mapeo de malezas en etapas de crecimiento tardías [Srinivasan, 2006, Koger et al., 2003]. Considerando el muestreo convencional y las tecnologías que han surgido las últimas décadas nos involucramos en lo que a comienzos del siglo XXI se denomina sistemas de gestión de malezas en sitios específicos SSWM (Systems por sus siglas en inglés site-specific weed management)[Brown and Noble, 2005], Según López Granados *et al.* [López-Granados, 2011] los sistemas SSWM tiene como idea principal rociar con herbicidas a solo grupos de malezas teniendo en cuenta su densidad y el tipo determinado de maleza, este proceso incluye cuatro pasos: el primero implica mapear con ayuda de tecnología especializada la ubicación de las malezas dentro del cultivo, el segundo involucra la toma de decisiones con el fin de seleccionar el mejor método para eliminar las amenazas encontradas, en el tercero se procede a ejecutar la decisión tomada, el cuarto y último paso se evalúa el rendimiento de la operación completa [Wang et al., 2019].

Dado que en el SSWM el proceso de mayor importancia es la detección de malezas puesto que provee la información con la cual se decide y ejecuta, es necesario usar herramientas modernas de hardware y software con el propósito de continuar con el desarrollo y mejoramiento de métodos en la detección, estimación y clasificación de maleza.

Se han utilizado imágenes satelitales para detección de maleza, sin embargo no llegan a ofrecer la información necesaria para esta tarea, como se puede evidenciar en las etapas crecimiento temprano donde los cultivos son pequeños, altamente vulnerables y pueden llegar

a tener características similares con la maleza lo que dificulta la detección si no se cuenta con una resolución apropiada. La solución llegó con los sistemas de aeronaves no tripuladas UASs (Por sus siglas en inglés Unmanned Aircraft Systems), estos permiten hacer cortos y largos recorridos automatizados o controlados remotamente capturando imágenes digitales a la altura y frecuencia de tiempo que requiera el usuario, lo cual puede variar dependiendo del tipo de UAV (Por sus siglas en inglés Unmanned Aircraft Vehicle) que maneje el sistema [Peña et al., 2013, Kharuf et al., 2018].

En adición, estos UAV se pueden equipar con cámaras multiespectrales las cuales ofrecen mayor información que una imagen digital tipo RGB, debido a que con ellas se capturan bandas espectrales no reconocidas por el ojo humano como el infrarrojo cercano o NIR (Por sus siglas en inglés Near-infrared), obteniendo aspectos como la reflectancia de la luz visible y los índices de vegetación. Estas características mencionadas anteriormente han dado paso para encontrar importantes correlaciones que ayudan en diferentes estimaciones, por ejemplo Bell *et al.* en el 2004, encontró que al medir la energía reflejada en la banda de 350 nm a 1100 nm existe una correlación aceptable entre el índice de vegetación de diferencia normalizada NDVI (Por sus siglas en inglés normalized difference vegetation index) y los contenidos de clorofila en el césped [Bell et al., 2004] o la correlación entre el estado del nitrógeno de la hoja y las características espectrales del dosel en el trigo usando el índice de reflectancia de la banda NIR a la verde [Behmann et al., 2015].

Lo anterior ha hecho que alrededor de las imágenes multiespectrales se creen métodos de clasificación más eficientes y utilizados ampliamente desde comienzo de siglo hasta la actualidad, como por ejemplo el análisis de imágenes basado en objetos OBIA (Por sus siglas en inglés object-based image analysis), en el cual se definen claramente las hileras formadas por el cultivo, con el fin de facilitar el proceso, luego se identifica espacial y espectralmente objetos homogéneos creados a partir de la agrupación de píxeles adyacentes combinando información espectral, contextual y morfológica, enseguida las imágenes se dividen en cuadrículas y dependiendo de la etapa de segmentación se clasifican, aquellas que se identifiquen con maleza corresponden a las zonas que deben ser tratadas químicamente para eliminar la amenaza, en el presente, este mismo enfoque se utiliza en ortomosaicos obtenidos con UAS y en algunos casos cámaras hiperespectrales las cuales pueden manejar más de 100 bandas para generar toda una firma espectral lo que las hace costosas y disponibles solo para un pequeño público. Actualmente, la metodología OBIA en la mayoría de los casos se realiza usando varios softwares comerciales los cuales ya tienen ciertos algoritmos implementados como por ejemplo Pix4Dmapper Pro, Argisoft, eCognition Developer, ENVI software system entre otros [Peña et al., 2013, López-Granados et al., 2015, López-Granados et al., 2016, Ahmed et al., 2017, Tao et al., 2018].

Las imágenes multiespectrales también proveen otro tipo de ventajas como facilitar la clasificación entre algunos tipos de plantas y la fácil segmentación del cultivo en su entorno, gracias a los diferentes índices de vegetación como el índice de absorción de clorofila y el índice de absorción de celulosa entre otros, además, de el hecho de aportar mayor información en procesos

de extracción de características como los utilizados en técnicas de clasificación con máquinas de soporte vectorial SVM (Por sus siglas en inglés Support vector machine), siendo la segunda técnica con mayor uso por los expertos para la detección de maleza, puesto que al no necesitar gran poder computacional se obtienen muy buenos resultados lo que aún las mantiene vigentes, sin embargo, estos dependen mucho de la metodología empleada por el investigador, los métodos de preprocesado de las imágenes, los tipos de características seleccionados y los métodos para realizar su extracción, los cuales tienen sus propios retos y vuelven el modelo rígido, debido a que se termina personalizando demasiado para imágenes con ciertas características de un cultivo en específico [Puerto, 2019, Binch and Fox, 2017, Rumpf et al., 2012]. No obstante, las imágenes multiespectrales dependen mucho de las condiciones climáticas de los días en las que son capturadas, dado que el clima hace que la reflectancia de las plantas cambie, también en etapas tempranas de algunos cultivos ciertos índices de vegetación son demasiado parecidos a los de las malezas que los rodean lo cual plantea retos para los algoritmos de clasificación [Thorp and Tian, 2004], estos y otros retos fueron afrontados con redes neuronales artificiales ANN (Por sus siglas en inglés Artificial neural network) que hoy en día son el método más usado en la detección de maleza, como lo indica Behmann *et al.* en su estudio con imágenes RGB. Las ANN utilizaban características de tipo morfológico, color, textura, momentums, entre otros. Sin embargo, gracias al avance tecnológico y a la facilidad para obtener sensores multiespectrales se puede mejorar su rendimiento. Ya que estos sensores ofrecen nuevas características como los índices de vegetación de longitud de onda, la relación de banda de onda, la intensidad de fluorescencia en rangos de bandas, los componentes principales de los espectros de fluorescencia [Pantazi et al., 2016, Nieuwenhuizen et al., 2007, Pantazi et al., 2017, Behmann et al., 2015]. Sin embargo las imágenes RGB siguen estando vigentes en este campo, la tabla **3-1** presenta varios artículos de los últimos diez años que enfrentan la detección de maleza con buenos resultados y utilizando métodos de aprendizaje automático e imágenes como conjunto de datos, se obtienen varias conclusiones como que a pesar de la llegada de las imágenes multiespectrales las imágenes RBG se usan en un 80 % de los casos, ya sea para realizar comparaciones con métodos nuevos, para ser usadas en sistemas de detección en tiempo real usando cámaras web por su rapidez, o para proponer sistemas asequibles de bajo costo [Dyrmann et al., 2016b, López-Granados et al., 2016, Ahmed et al., 2017, Partel et al., 2018].

**Tabla 3-1:** Trabajos en detección o clasificación de malezas y cultivos utilizando aprendizaje automático

Autor - Problema	Datos usado	Técnica	Rendimiento
[Abdulsalam and Aouf, 2020] Detección de cuatro tipos de maleza	4000 imágenes RGB	ResNet-50 y YO-LOv2	Precisión 99 %.

**Tabla 3-1:** Trabajos en detección o clasificación de malezas y cultivos utilizando aprendizaje automático

Autor - Problema	Datos usado	Técnica	Rendimiento
[Ahmed et al., 2017] Clasificación con múltiples clases. (Bosque, arbusto, herbácea, suelo, Área Construida)	Imágenes multiespectrales (Parrot Sequoia) y RGB (cámara Sony DCS-wx220) capturadas en UAV a 20 metros.	OBIA (object-based image analysis) usando Pix4Dmapper Pro y ENVI software system	Para 10 clases con imágenes multiespectral 82% de exactitud promedio, con imágenes RGB 79% de exactitud promedio
[Binch and Fox, 2017] Detección de césped y malezas rumex y urtica	Imágenes RGB de césped y de las malezas	SVM (Support vector Machine)	Precisión Rumex 94.65%. Precisión Urtica 95.1%
[Liu and Bruch, 2020] Detección de cultivos de lechuga	Imágenes RGB en tiempo real con cámara web	VGG 16 YOLOv2	Precisión media promedio 92.8%
[Chavan and Nandedkar, 2018] Identificar diferentes especies vegetales de cultivos y maleza.	4750 imágenes RGB para entrenamiento y 794 imágenes para pruebas	AgroAVNET modelo híbrido de AlexNet y VGGNET propuesto por el autor.	AgroAVNET porcentaje de precisión promedio (98.21%) AlexNet (94.99%) y VGGNET (92.81%).
[Dyrmann et al., 2016a] Clasificación con 22 tipos de maleza	10,413 imágenes RGB que contienen 22 especies de malezas y cultivos en etapas tempranas de crecimiento.	CCN propuesta por el autor	Precisión 86.2%
[Dyrmann et al., 2016b] Detectar y clasificar maleza en campos de maíz	301 imágenes de suelo y 8430 de plantas segmentadas	Versión adaptada de CNN VGG16	Precisión 94%
[Dyrmann et al., 2017] Detección automática de maleza en imágenes a color	1427 imágenes de cosechas con cámara en vehículo de terreno	CCN DetectNet basado GoogLeNet	Precisión 86.6%
[Elstone et al., 2020] Identificación de de maleza y cultivos de lechuga.	Imágenes RGB en tiempo real con iluminación multiespectral	Método esterero cinemático usando umbralización y reflectancia	Tasa de identificación 81% para malezas y 88% para el cultivo
[Hamuda et al., 2018] Detección de cultivo (Coliflor)	Imágenes RGB usando espacio de color HSV	Algoritmo de seguimiento usando RCNN, el filtro Kalman y el algoritmo húngaro	Sensibilidad 99.34%
[Huang et al., 2018c] Mapeo de malezas en cultivos de arroz	Imágenes RGB de 4000x3000 pixels multiespectrales capturadas en UAV a 6 metros.	Fully convolutional network (FCN) mejorada por el autor	Precisión media cultivo 80%, maleza 88%

**Tabla 3-1:** Trabajos en detección o clasificación de malezas y cultivos utilizando aprendizaje automático

Autor - Problema	Datos usado	Técnica	Rendimiento
[Huang et al., 2018b] Mapeo de maleza en campos de arroz	Imágenes RGB (ortomosaico) capturadas en UAV divididas en imágenes de 1000x1000px	CNN propuesta por el autor denominada ASPP-1 before CRF (Conditional random field)	Precisión del cultivo 94.4 %, maleza 92.5 %
[Huang et al., 2018a] Mapeo de maleza en campos de arroz	Imágenes RGB (ortomosaico) capturadas en UAV divididas en imágenes de 1000x1000px	FCN4s (Fully convolutional networks) propuesta por el autor	Precisión 91.96 % en maleza.
[Hung et al., 2014] Clasificación de tres tipos de maleza	Imágenes aéreas RGB de 384x384px	Texton based linear classifier	Precisión 70 % - 93.79 %
[López-Granados et al., 2015] Mapeo de malezas en maíz de temporada temprana	Imágenes (ortomosaico) multiespectrales capturadas en UAV a 30 60 y 100 metros en campos de maíz.	OBIA (object-based image analysis)	Precisión 86 %
[López-Granados et al., 2016] Detección y mapeo de la maleza Sorghum halepense	Imágenes (ortomosaico) multiespectrales capturadas en UAV a 30 60 y 100 metros en campos de maíz.	OBIA (object-based image analysis)	RGB+NIR 86 % - 92 % precisión. RGB 66 % - 67 % precisión
[McCool et al., 2017] Segmentación de malezas para plataformas robóticas	Imágenes de zanahoria orgánica (Dataset CW-FID)	Inception-v3 - lightweight DCNN	Precisión 93.90 %
[Milioto et al., 2017] Detectar plantas de remolacha azucarera y maleza	Cámara multiespectral en UAV de 4 bandas	CNN definida por el autor	Precisión 96.1 %
[Nieuwenhuizen et al., 2007] Identificar la plaga de plantas de crecimiento tardío de papa no deseadas en cultivos de remolacha	Imágenes a color con cámara sobre vehículo terrestre	Clasificación por color usando K-means y Naive Bayes / ANN.	Precisión 97 %
[Pantazi et al., 2016] Reconocimiento y discriminación de maíz y especies de maleza	Características de imágenes multiespectrales	ANN / one-class SOM and Clustering / one-class MOG	Precisión SOM = 53-94 %, Precisión MOG = 31-98 %

**Tabla 3-1:** Trabajos en detección o clasificación de malezas y cultivos utilizando aprendizaje automático

Autor - Problema	Datos usado	Técnica	Rendimiento
[Pantazi et al., 2017] Identificar la maleza <i>S. marianum</i> entre otra vegetación en un campo	imágenes multiespectrales obtenidas por UAS.	La Red supervisada de Kohonen (SKN), la Red neuronal artificial de propagación (CP-ANN) y la Red de fusión XY (XY-F)	SKN 98,64 % precisión, CP-ANN 98,87 % precisión, XY-F 98,64 % precisión.
[Partel et al., 2018] Spray de malezas con detección de maleza en tiempo real con inteligencia artificial desde un vehículo tripulado	3 cámaras web en tiempo real recolectan las imágenes	CNN YOLOv3 / Tiny YOLOv3	89 % - 95 % precisión dependiendo del experimento y el hardware que realizó la clasificación.
[Peña et al., 2013] Realizar una clasificación que permita el cálculo de los requisitos de herbicidas y la estimación del costo general de la maleza en cultivos de maíz.	Cámara multiespectral en UAV de 6 bandas	OBIA (object-based image analysis)	Precisión 86 %
[Potena et al., 2016] Detección de plantas de remolacha azucarera y malezas.	1600 imágenes de 4 canales RGB + NIR	CNN definida por el autor	Precisión 98 %
[Raja et al., 2020] Clasificación de malezas y cultivos en campos de lechuga	2 cámaras RGB en tiempo real	Algoritmo de visión artificial diseñado por el autor	Precisión maleza 99.75 %, cultivo 98.11 %
[Rumpf et al., 2012] Identificar las especies de malezas y cultivos con el fin de mejorar la administración de la cantidad de herbicidas que se utilizan en los cultivos	Imágenes multiespectrales de cultivos de maíz y remolacha azucarera	SVM (Support vector machine)	Precisión 97.70 %
[Sa et al., 2018a] Detección de plantas de remolacha azucarera y malezas con sistema embebido GPU.	Imágenes multiespectrales capturadas en UAV a 2 metros.	SegNet	Suelo = 0.948 AUC Cultivo = 0.945 AUC maleza = 0.787 AUC
[Sa et al., 2018b] Detección de plantas de remolacha azucarera y malezas.	Imágenes (ortomosaico) multiespectrales capturadas en UAV a 10 metros.	FCNN	Suelo = 0.839 AUC Cultivo = 0.863 AUC maleza = 0.782 AUC
[Shaun M. Sharpe and Boyd, 2019] Detección de tres clases de vegetación	RGB imágenes de 6000 x 4000 px	YOLOv3	Valor F 95 %

**Tabla 3-1:** Trabajos en detección o clasificación de malezas y cultivos utilizando aprendizaje automático

Autor - Problema	Datos usado	Técnica	Rendimiento
[Suh et al., 2018] Identificar la plaga de plantas de crecimiento tardío de papa no deseadas en cultivos de remolacha	Imágenes RGB de 1280x580px capturadas por robot terrestre	AlexNet, VGG-19, GoogLeNet, ResNet-50, ResNet-101 e Inception-v3	Precisión AlexNet 97.7%, VGG-19 98.7%, GoogLeNet 97.3%, ResNet-50 97.2%, ResNet-101 98.5%, Inception-v3 94.8%
[Sun et al., 2018] Identificación de flores, frutos maduros e inmaduros de tomate	5624 imágenes RGB	Faster R-CNN, Resnet-50, Soft-NMS	85.2% - 90.7% mean average precisión
[Tellaache et al., 2008] Determinar la cantidad y la distribución de las malezas en los campos de cultivo y aplicar una estrategia de toma de decisiones para la fumigación selectiva	Imágenes RGB de 1152 x 864 píxeles capturadas a las hileras del cultivo manualmente	Segmentación de imágenes.	Precisión 92%
[Yunong Tian, 2019] Detección de manzanas en diferentes etapas de crecimiento	320 imágenes RGB	YOLOv3-Dense	Valor-F 81%
[Xinshao and Cheng, 2015] Clasificar 91 tipos de semillas de malezas	3980 Imágenes RGB	CNN PCANet + LMC	Precisión 64.80%

En cuanto a los algoritmos o métodos de clasificación empleados, se concluye que los SVM siguen vigentes por su buen desempeño y bajo consumo de recursos computacionales, siendo más atractivos en proyectos que involucren sistemas embebidos [Binch and Fox, 2017, Puerto, 2019, Rumpf et al., 2012], por otra parte, las redes neuronales artificiales siguen siendo el método más utilizado para la detección de maleza por su rendimiento y flexibilidad a la hora de elegir entre topologías, algoritmos de entrenamiento o simplemente modificaciones que el autor requiera realizar según el reto que esté enfrentado.

Por supuesto, esto también aplica a las redes neuronales convolucionales CNN (Por sus siglas en inglés Convolutional Neural Network) que están marcando una tendencia fuerte en la clasificación e identificación de patrones basados en imágenes. En los trabajos presentados en el Anexo A se encuentran algunas de las arquitecturas de redes neuronales convolucionales que tienen buena acogida para la identificación de malezas como lo son: AlexNet, ResNet, RCNN (Siglas en inglés Region Based Convolutional Neural Networks), VGG (Siglas en inglés para la arquitectura de [Simonyan and Zisserman, 2015]), GoogLeNet, FCN (Por sus siglas en inglés Fully Convolutional network) y YOLO (Siglas en inglés para You Look Only Once arquitectura de [Redmon J. and A., 2016]).

Toshevskaa *et al.* [Lameski et al., 2018] asegura que las redes neuronales convolucionales CNN son un método muy poderoso, por ejemplo, Potena *et al.* [Potena et al., 2016] desarrollaron

un método para la detección de malezas y plantas con cámara multiespectral en tiempo real realizada por un robot terrestre. La técnica de clasificación utilizada se basa en dos redes neuronales convolucionales, la primera realiza la segmentación binaria de la imagen por píxeles extrayendo una representación en 3D de los píxeles que muestran la vegetación verde, la segunda es una red previamente entrenada la cual realiza la clasificación.

La principal ventaja de este método es que permite agilizar y acelerar el proceso manual de etiquetado de conjuntos de datos al tiempo que conserva un buen rendimiento de clasificación, el enfoque propuesto supera otros convencionales basados en índices como NDVI con una exactitud de 98.7%, además, que al ser la entrada la misma imagen los inconvenientes mencionados en las SVM y ANN con la selección y extracción de características disminuyen, por lo cual es tendencia en la actualidad para el aprendizaje automático y reconocimiento de patrones, a esto se le suma su gran desempeño con todo tipo de imágenes por lo que las CNN se utilizan cada vez más para la detección de maleza [Kamilaris and Prenafeta-Boldú, 2018]. En Colombia los primeros registros que se tienen en cuanto a la detección y control de maleza son de empresas, asociaciones o entidades con algún tipo de vínculo con el instituto colombiano agropecuario ICA durante la década de los setenta, las cuales evidencian esfuerzos por explotar la agricultura colombiana conociendo el potencial de los recursos que se tienen. Entre estos registros encontramos por ejemplo los documentos escritos por Doll y Piedrahita sobre el control de la maleza en los cultivos de yuca [Doll and Piedrahita, 1978], o el escrito por el ingeniero Gómez sobre control de malezas en cultivos de caña [Gómez, 1995]. El control de la maleza en Colombia se resume en tres métodos: el control manual, el cual es costoso en tiempo debido a que se realiza con palas y azadones por lo que requiere demasiada mano de obra, el control mecánico con ayuda de elementos como rastrillos de discos, que es mucho más eficiente que el anterior pero puede maltratar la tierra y en muchas ocasiones los brotes de maleza crecen nuevamente y por último el control químico el cual es el más usado por sus resultados y eficacia a pesar de tener graves consecuencias ambientales.

Durante las tres últimas décadas de siglo XX los esfuerzos se concentraron en la identificación y asociación de plantas arvenses nobles que son aquellas que ayudan al cultivo protegiéndolo de plagas no deseadas o previniendo la erosión del suelo y las plantas arvenses agresivas o maleza que en definitiva afectan el cultivo negativamente, ya que compiten directamente por recursos y pueden traer plagas o enfermedades. También se centraron en la clasificación de los tipos de maleza existente en el territorio, lo cual es una tarea extensa debido a los diferentes tipos de tierra y climas que tiene nuestro país, esto con el fin de estimar qué herbicidas funcionan mejor en determinados tipos de maleza teniendo en cuenta la ubicación del cultivo [Doll and Piedrahita, 1978, García and A., 1997, Fuentes and Romero, 1991].

Como lo menciona Puerto en el 2017 [Puerto, 2019] el 70% de la agricultura en Colombia no está tecnificada siendo el muestreo convencional la técnica más empleada para la localización de maleza en el país, presentando problemas por su poca precisión ya que puede existir subjetividad o sesgo entre los evaluadores dependiendo de su experiencia y grado de conoci-

miento, por otra parte en cultivos de gran extensión el muestreo puede durar días o realizarse de forma aleatoria para reducir tiempo y costos. Teniendo en cuenta que la aplicación de herbicidas es un proceso que al realizarse óptimamente puede disminuir los costos, aumentar la productividad y disminuir el impacto ambiental, es de resaltar que en este modelo existen varios componentes estocásticos que hacen que la detección y el control de las malezas no sea el óptimo.

En los últimos años se evidencian varios estudios que aportan al campo de la agricultura de precisión en el control y detección de maleza como por ejemplo el trabajo de Corredor [Corredor, 2011] en el 2011, el cual con ayuda de una cámara y un algoritmo de clasificación para crear un sistema adjunto a un vehículo de motor que por medio de incineración elimina las malezas encontradas. Betancourt [Betancourt, 2014] plantea un sistema que detecta malezas en ambientes controlados usando una cámara web y un software desarrollado en Matlab, Montenegro *et al.* [Montenegro and Parada, 2015] proponen un sistema de detección de maleza comparando varios modelos de aprendizaje automático como KNN (Por sus siglas en inglés k-nearest neighbors), Bayes, SVM, y ANN. En 2015 Sogamoso *et al.* [Sogamoso González, 2015] describen un método mecánico que con ayuda de una cámara y un mecanismo con cierras eliminan las malezas previamente detectadas por software. Barrero *et al.* [Barrero et al., 2016] utilizan redes neuronales para realizar detección de maleza en campos de arroz en el Tolima con ayuda de vehículos aéreos no tripulados. Los sensores multiespectrales también se han empezado a utilizar en trabajos como los de Hernández [Hernández, 2017] y Puerto [Puerto, 2019] en el 2017, los cuales utilizan imágenes de cámaras multiespectrales y vehículos aéreos no tripulados para detectar malezas.

Estos trabajos nos dan una buena perspectiva de lo que se está realizando en el país para enfrentar la problemática de la detección de malezas en los cultivos, pero aún existe un rezago en proponer, desarrollar e implementar métodos computacionales más modernos y eficientes que generen impacto y tendencias en la agricultura de precisión para aplicar y difundir en el territorio nacional.

## 4 Metodología

Se plantea un marco de trabajo partiendo de la selección de un método de aprendizaje automático de los artículos revisados en el estado del arte, teniendo en cuenta el método seleccionado se escogen y etiquetan las imágenes creando así el conjunto de datos a emplear. Seguidamente, se preprocesan dichas imágenes y se utilizan las diferentes bandas espectrales para generar distintas combinaciones de imagen multiespectral. A continuación, se diseña el método base con el objeto de seleccionar un solo tipo de imagen multiespectral que tenga el mejor rendimiento en cuanto a exactitud y precisión. Posteriormente, se comienza un proceso cíclico donde se evalúa el método base y se comparan sus medidas de rendimiento, las cuales se obtienen a través de las matrices de confusión, con el fin de mejorar el método aplicando los cambios pertinentes. Lo anterior, con el propósito de encontrar un modelo que supere el 80% de precisión para la detección y nos brinde un buen escenario para la estimación porcentual de maleza. Por último, con un análisis comparativo se determina si el modelo final tiene resultados relevantes con respecto a las evaluaciones obtenidas por expertos en la tarea de estimación porcentual de maleza (Figura 4-1).

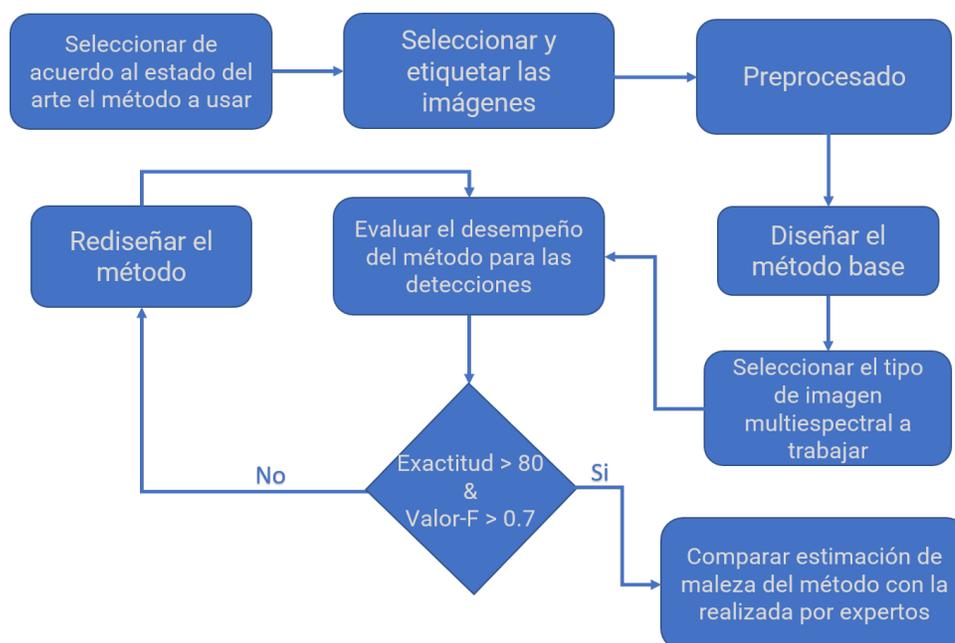


Figura 4-1: Metodología

## 4.1. Conjunto de datos

Las fotografías empleadas fueron tomadas por el ingeniero Andrés Puerto utilizadas en su trabajo [Puerto, 2019], se capturaron en un cultivo comercial de lechuga ubicado en el Centro Agropecuario Marengo de la Universidad Nacional de Colombia a 14 kilómetros de la ciudad de Bogotá en el municipio de Mosquera Cundinamarca, 60 días después de la siembra y 20 días después de la primera desyerba manual. Fue utilizado el vehículo aéreo no tripulado (UAV) Dji Mavic Pro el cual fue equipado con la cámara multispectral Parrot Sequoia (Figura 4-2), esta nos brinda cuatro imágenes en diferentes bandas multispectrales (verde 550 nanómetros, rojo 660 nanómetros, borde de rojo 735 nanómetros e infrarrojo cercano 790 nanómetros) y una imagen en RGB (Figura 4-3), cada una con un tamaño en píxeles de 1280 x 960 y una proporción de 0.22cm/px.



Figura 4-2: Mavic Pro equipado con la cámara multispectral Parrot Sequoia.

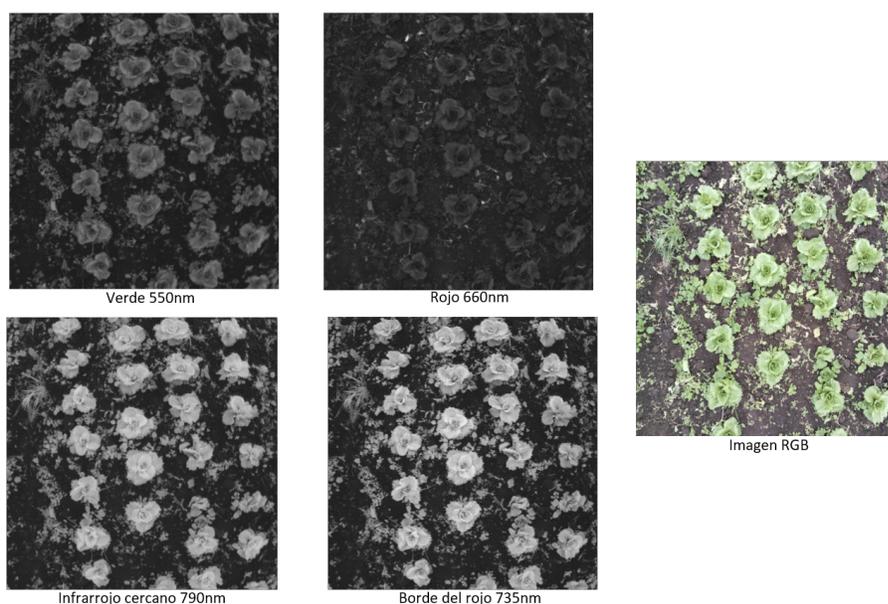


Figura 4-3: Imágenes obtenidas con la cámara multispectral Parrot Sequoia.

## 4.2. Selección de imágenes y etiquetado

Las imágenes del conjunto de datos se evaluaron una a una, eliminando las desenfocadas, aquellas que contenían objetos incompletos y las capturadas en ángulos difíciles de procesar, con el fin de obtener un buen desempeño en el proceso de entrenamiento. Luego se ordenaron en tres categorías según la altura de su captura: elevada, media y baja con el objetivo de escoger 100 imágenes que variaran en altura, número de muestras y entorno.

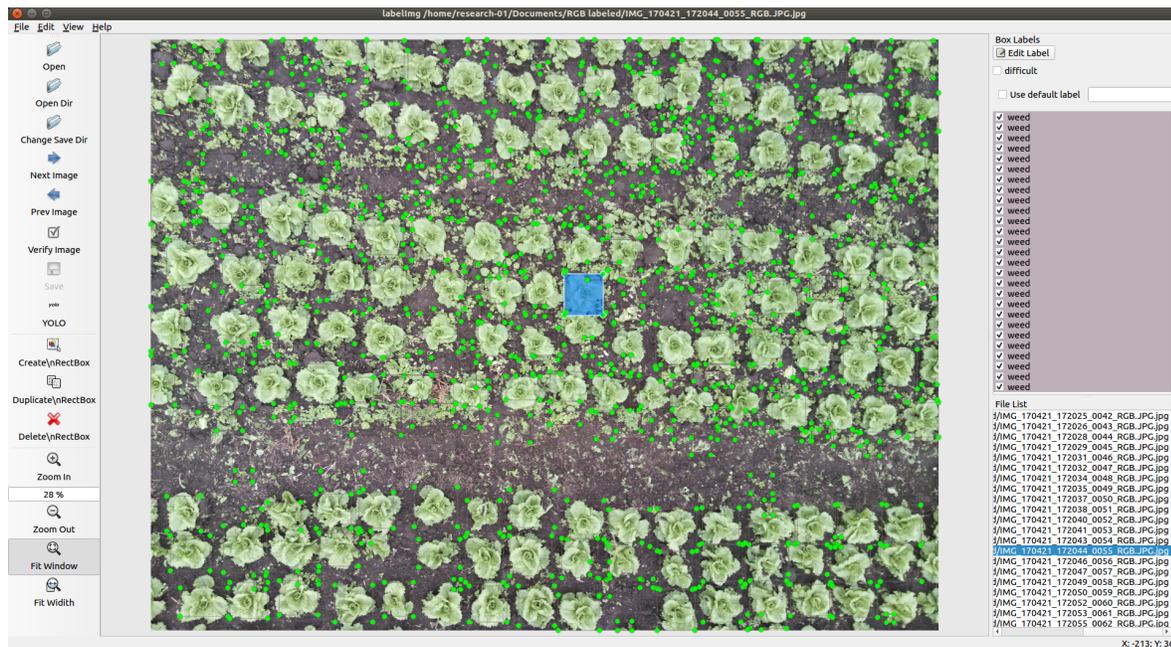


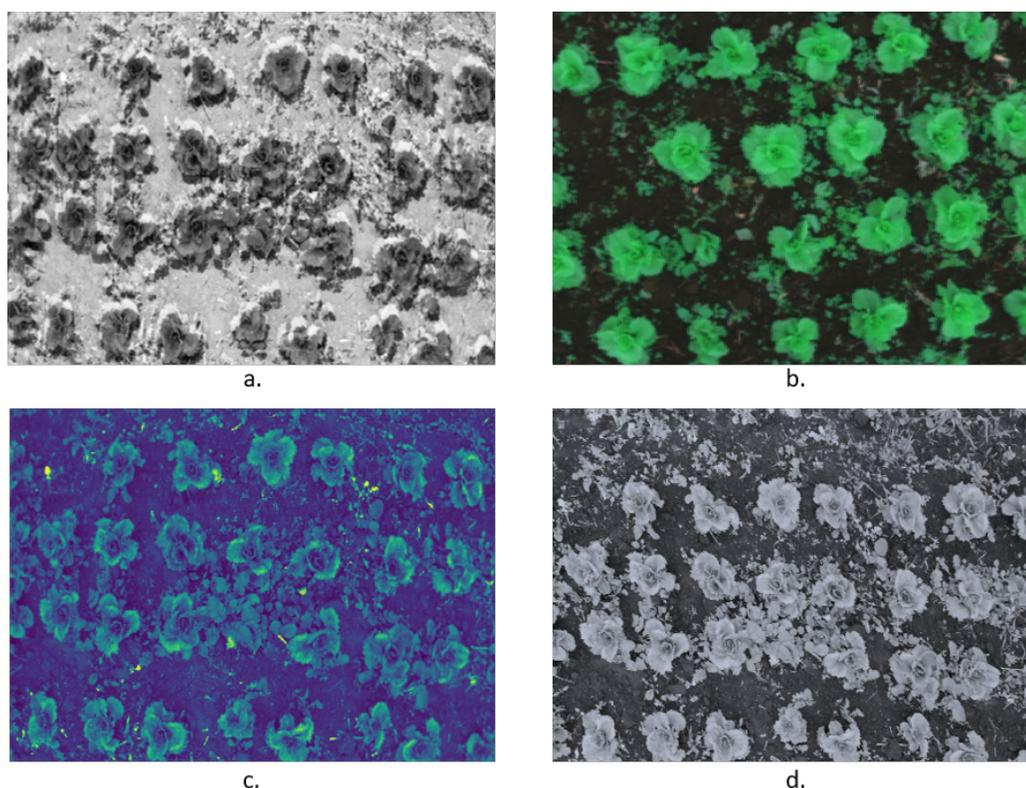
Figura 4-4: Etiquetado de imagen - Altura elevada

Las 100 imágenes seleccionadas que corresponden aproximadamente a  $600m^2$  se encontraban en formato TIFF así que se realizó un código en python para convertirlas a JPEG sin perder calidad. El número de imágenes se escogió teniendo en cuenta los procesos de etiquetado y entrenamiento de la CNN lo cuales demandan bastante tiempo. Como se puede observar en la figura 4-4, el etiquetado de las clases se realiza de manera manual con el software LabelImg de código abierto desarrollado en python por [Tzutalin, 2015]. El etiquetado consiste en generar con el cursor cajas rectangulares que encierren el objeto que se desea etiquetar, en este caso con 2 clases “lechuga” y “maleza” al ser un proceso manual con 100 imágenes se invirtieron cerca de 120 horas de trabajo, es de resaltar que este proceso fue supervisado por un experto en malherbología el cual dio las pautas de etiquetado. Este procedimiento genera un archivo de tipo .xml o .txt por imagen, con formato de etiquetado PascalVoc o YOLO, los cuales registran la clase y las coordenadas correspondientes a cada cuadro delimitador especificado, estos archivos junto con sus imágenes correspondientes hacen parte del conjunto de datos que utilizará el algoritmo de entrenamiento de la red neuronal para la

etapa de aprendizaje. El total de las muestras identificadas en el etiquetado corresponde a 6488 muestras de lechuga y 11670 muestras de maleza.

### 4.3. Preprocesado

Una vez se tuvo el conjunto de datos etiquetados se generaron varios tipos de imagen multi-espectral, el primero se denomina NDVI-32 y se crea en escala de grises calculando el índice NDVI usando 32 bits y realizando un estiramiento de contraste basado en percentiles (Fig. 4-5 a.), el segundo tipo es el Falso verde el cual fue planteado por [Puerto, 2019] y utiliza las bandas verde, rojo e infrarrojo y valores de irradiancia (Fig. 4-5 b.), el tercer tipo es el NDVI-64 en el que se utilizan 64 bits para calcular el NDVI agregando una ganancia de verdes (Fig. 4-5 c.), por último se tiene los rojos filtrados en donde se utilizan las bandas rojo, borde de rojo e infrarrojo y se aplica un filtro pasa altos para resaltar la vegetación (Fig. 4-5 d.).



**Figura 4-5:** a. NDVI-32, b. Falso Verde, c. NDVI-64, d. Rojos filtrados

## 4.4. Selección del Método

De acuerdo al estado del arte se tuvieron en cuenta tres tipos de método de los cuales dos fueron descartados. Estos fueron el método OBIA el cual ha sido más utilizado para cultivos extensos con imágenes capturadas a una altura mayor y enfocándose en medidas relevantes para la salud del cultivo. Y el método SVM, estas máquinas de soporte vectorial pueden llegar a ser rígidas en cuanto a las propiedades del conjunto de datos y dependen mucho de la extracción de características de los datos a entrenar. En lo que respecta al tercer método, se tienen las redes neurales y dentro de estas se encuentran las CNN o redes neuronales convolucionales que actualmente son tendencia por sus buenos resultados trabajando con imágenes.

A raíz de trabajos como los de [Abdulsalam and Aouf, 2020], [Liu, 2020], [Partel et al., 2018], [Shaun M. Sharpe and Boyd, 2019] y [Yunong Tian, 2019] se seleccionó como método base para el desarrollo de este proyecto el algoritmo de detección YOLOv3, el cual hace uso de redes neuronales convolucionales para la extracción de características y el aprendizaje. YOLO ha demostrado buenos resultados superando un 85 % de precisión y siendo utilizado en tiempo real [Redmon and Farhadi, 2018]. Además de casos de éxito como el de [Liu, 2020] en los que se utiliza para el mismo tipo de cultivo del presente trabajo.

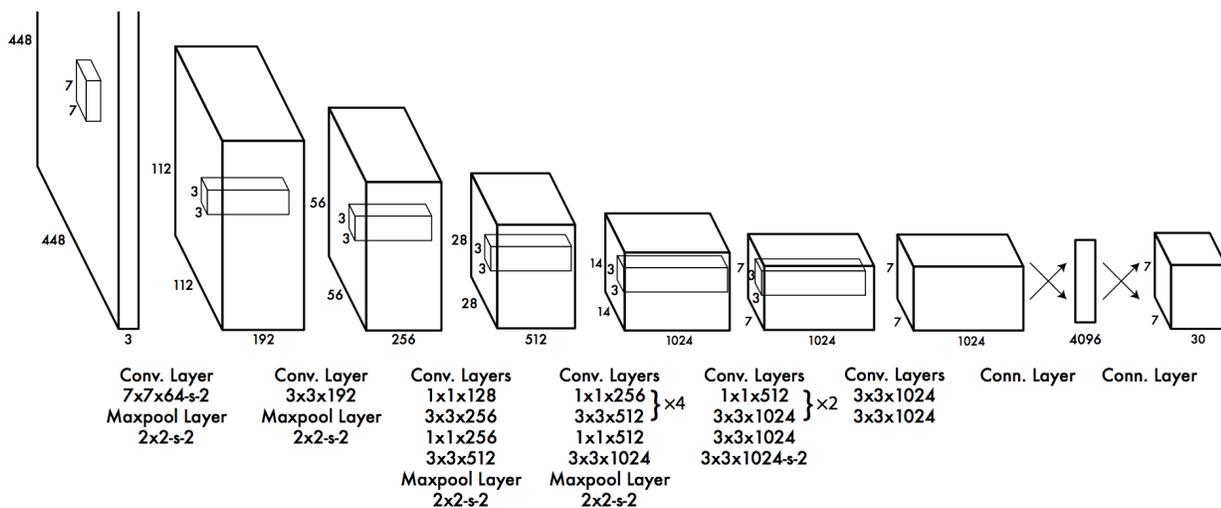


Figura 4-6: Arquitectura YOLOv1. Tomado de [Redmon J. and A., 2016]

YOLO es un tipo de red neuronal convolucional inspirada en la arquitectura de GoogleNet, y es capaz de detectar múltiples objetos de una imagen usando los cuadros delimitadores y la probabilidad de pertenencia de estos a una clase con solo un recorrido. YOLO ha demostrado un buen desempeño en el reconocimiento de objetos y patrones lo que le ha dado recientemente una buena reputación en tareas como el reconocimiento de medios de transporte, animales y el seguimiento de objetos en movimiento.

La primera versión de YOLO salió en el 2016 [Redmon J. and A., 2016], su arquitectura consta de 24 capas convoluciones que trabajan como extractores de características y 2 capas densas o totalmente conectadas que realizan la predicción (Figura 4-6), actualmente se trabaja con YOLOv3 [Redmon and Farhadi, 2018] versión que incluye mejoras significativas y las capas de extracción de características fueron reemplazadas por la arquitectura Darknet-53 (Figura 4-7).

Type	Filters	Size/Stride	Output
Convolutional	32	$3 \times 3$	$224 \times 224$
Maxpool		$2 \times 2/2$	$112 \times 112$
Convolutional	64	$3 \times 3$	$112 \times 112$
Maxpool		$2 \times 2/2$	$56 \times 56$
Convolutional	128	$3 \times 3$	$56 \times 56$
Convolutional	64	$1 \times 1$	$56 \times 56$
Convolutional	128	$3 \times 3$	$56 \times 56$
Maxpool		$2 \times 2/2$	$28 \times 28$
Convolutional	256	$3 \times 3$	$28 \times 28$
Convolutional	128	$1 \times 1$	$28 \times 28$
Convolutional	256	$3 \times 3$	$28 \times 28$
Maxpool		$2 \times 2/2$	$14 \times 14$
Convolutional	512	$3 \times 3$	$14 \times 14$
Convolutional	256	$1 \times 1$	$14 \times 14$
Convolutional	512	$3 \times 3$	$14 \times 14$
Convolutional	256	$1 \times 1$	$14 \times 14$
Convolutional	512	$3 \times 3$	$14 \times 14$
Maxpool		$2 \times 2/2$	$7 \times 7$
Convolutional	1024	$3 \times 3$	$7 \times 7$
Convolutional	512	$1 \times 1$	$7 \times 7$
Convolutional	1024	$3 \times 3$	$7 \times 7$
Convolutional	512	$1 \times 1$	$7 \times 7$
Convolutional	1024	$3 \times 3$	$7 \times 7$
Convolutional	1000	$1 \times 1$	$7 \times 7$
Avgpool		Global	1000
Softmax			

Figura 4-7: Arquitectura extractor de características YOLOv3.[Redmon and Farhadi, 2018]

## 4.5. Método base y selección de tipo de imagen multiespectral

Para la implementación de YOLOv3 se hace uso de framework Darknet [Redmon, 2016] el cual es un marco de trabajo para redes neuronales de código abierto y desarrollado en C empleando CUDA. Este incluye arquitecturas de redes neuronales convolucionales reconocidas como ResNet, AlexNet y YOLO. Además ofrece la facilidad de realizar procesamiento con GPU o CPU. En relación al hardware, los métodos fueron entrenados y testeados usando un computador con procesador Xeon de ocho núcleos, 16 gigas de memoria RAM y una tarjeta gráfica Nvidia GTX 1060 de 6GB, empleando el sistema operativo Ubuntu 16. Para el método base se seleccionó la arquitectura yolov3 disponible en el framework Darknet. Y se siguieron los siguientes pasos para su configuración y uso:

1. Se instala en el sistema operativo el driver de la tarjeta gráfica correspondiente junto con GCC4.9, CUDA10.0, OpenCV2.4 y la librería cuDNN.

2. Se compila en framework modificando los siguientes valores a “1” en el archivo Makefile para indicarle al framework que se hará uso de estos recursos GPU, CUDNN, OPENCV, AVX, OPENMP, LIBSO
3. Se crea una copia del archivo que contiene la configuración de la arquitectura ubicada en `/build/darknet/x64/cfg/yolov3.cfg` en la cual se modifican las variables:
  - a) `batch=8` que indica el número de muestras usadas para avanzar calculando el gradiente y para actualizar los pesos de la red por medio del algoritmo backpropagation.
  - b) `subdivisions=8` que se refiere al número de bloques en los que se divide cada batch para ser ejecutados en paralelo por la GPU, este debe corresponder a múltiplos de 8 y depende en gran medida de la capacidad computacional de la GPU.
  - c) `max_batches=6000` variable que establece el número máximo de batchs a ejecutar. Para establecer su valor se usa el cálculo recomendado por el autor (`# de clases * 2000`) sin que el resultado sea menor al número de imágenes utilizadas para el entrenamiento ni menor al número 6000.
  - d) `steps=4800,5400` estos valores definen la velocidad de aprendizaje del modelo y se establecen tomando los valores del 80 % y 90 % de la variable `max_batches`.
  - e) `classes=2` la cual establece el número de clases que se desean detectar, para este trabajo son dos: lechuga y maleza. Así que se cambia su valor en las capas [yolo].
  - f) `filters=21` para calcular la variable `filters` se usa la operación (número de clases + 5)\*3, en este caso al tener dos clases:  $(2+5) * 3 = 21$ , esta variable será cambiada en cada capa [convolutional] declarada siempre antes de la capa [yolo].
4. Crear el archivo `obj.names` en `/build/darknet/cfg/data/` con los nombres de las clases a entrenar, cada uno de los archivos en una línea nueva del documento.
5. Crear el archivo `obj.data` en `build/darknet/x64/data/` con las siguientes variables en líneas separadas sin comas: `classes=2`, `train=data/train.txt`, `valid=data/test.txt`, `names = data/obj.names`, `backup = backup/`
6. Copiar los archivos del conjunto de datos (imágenes y archivos de etiquetado .txt) en la carpeta `/build/darknet/x64/data/obj/`.
7. Crear el archivo `train.txt` en `/build/darknet/cfg/data/` con las rutas y nombres de las imágenes que se usaran para el entrenamiento, cada ruta en una nueva línea del archivo (`data/obj/img1.jpg`).

8. Crear el archivo `test.txt` en `/build/darknet/cfg/data/` con las rutas y nombres de las imágenes que se usaran para probar el modelo, cada ruta en una nueva línea del archivo (`data/obj/img50.jpg`).
9. Para empezar el entrenamiento se ejecuta el archivo `darknet` en la raíz del framework y en el comando se escriben los siguientes los parámetros: “detector train” el cual indica qué se va a entrenar, la ruta de la carpeta donde se dejó el conjunto de datos, la ruta del archivo de arquitectura modificado, el archivo de los pesos preentrenados de las capas convolucionales y por último se agrega el parámetro `-map` para que el promedio medio de precisión sea calculado cada 4 épocas. El comando en linux queda de esta forma `./darknet detector train /build/darknet/x64/data/obj.data /build/darknet/x64/cfg/yolo-obj.cfg /build/darknet/x64/darknet53.conv.74 -map`
10. Una vez se finaliza el entrenamiento los pesos quedan guardados en archivos con extensión `.weights` en la carpeta `/build/darknet/x64/backup/`
11. Para probar el modelo entrenado de forma manual usamos el mismo comando mencionado anteriormente cambiando el parámetro “detector train” por “detector test” y agregando la ruta del archivo `.weight` que contiene los pesos de la red y la ruta de la imagen a probar. (`./darknet detector test /build/darknet/x64/data/obj.data /build/darknet/x64/cfg/yolo-obj.cfg /backup/yolo-obj-final.weights test/imagen42.jpg`).

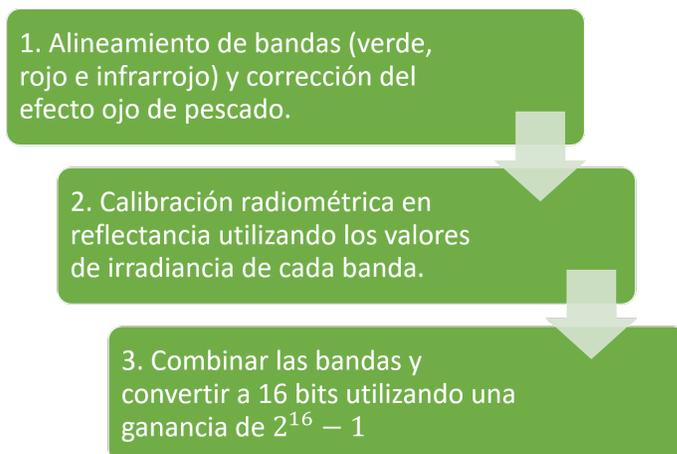
## 4.6. Selección del tipo de imagen multiespectral

Se crearon 4 diferentes conjuntos de datos con las imágenes multiespectrales presentadas anteriormente (Sección 4.3) y se entrenó el mismo modelo usando la configuración previamente descrita con cada uno, evaluando el promedio medio de precisión o MAP (Por su siglas en inglés Mean Average Precision) obteniendo los siguientes resultados :

**Tabla 4-1:** Evaluación del desempeño de las imágenes multiespectrales.

Imagen multiespectral	MAP Cultivo	MAP Maleza
a. NDVI-32	76 %	22 %
b. Falso Verde	80 %	43 %
c. NDVI-64	83 %	36 %
d. Rojos filtrados	81 %	29 %

Teniendo en cuenta estos resultados y evaluando la detección realizada con cada tipo de imagen se decidió usar el tipo b. Falso verde, el cual usa las bandas verde, rojo e infrarrojo cercano. Una vez decidido el tipo de imagen multiespectral, se establece el preprocesado de nuestro método como lo muestra la figura 4-8.



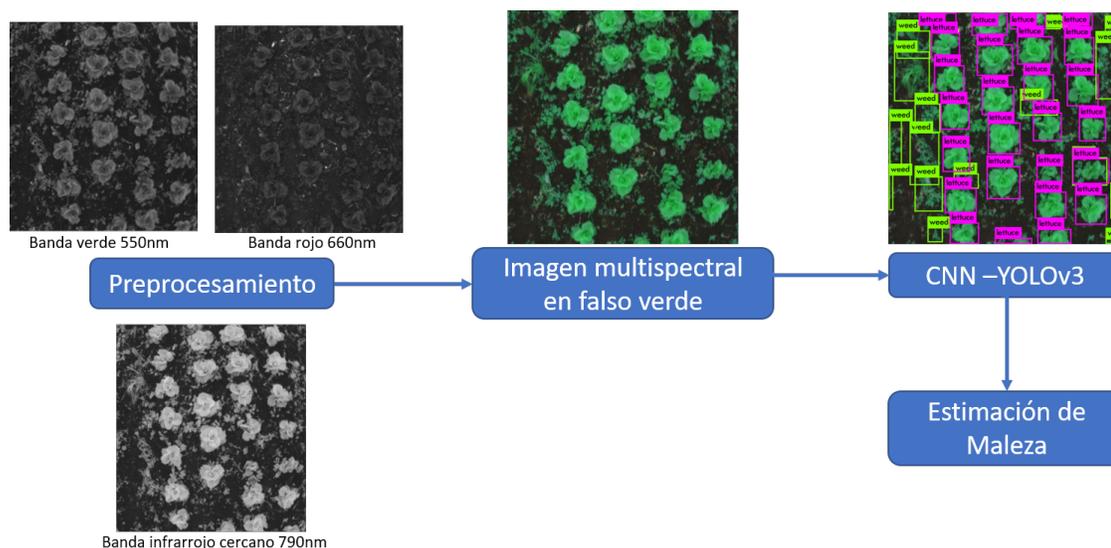
**Figura 4-8:** Diagrama del preprocesado para obtener imagen multiespectral en falso verde.

## 4.7. Métodos propuestos

En esta sección se presentan dos métodos desarrollados por el autor para la estimación de maleza en cultivos de lechuga usando imágenes multiespectrales y YOLOv3, en el primer método se presentan dos modelos (modelo A y modelo B) con el mejor desempeño de entre 10 modelos entrenados a partir del método base, el segundo método presenta un rediseño del método 1 que fortalece su buen desempeño en la detección del cultivo y ofrece una mejor solución a la coalición de maleza para su estimación.

### 4.7.1. Método 1 Detección dos clases con Yolo V3

Este primer método tiene 4 fases claramente identificadas como se puede observar en la figura 4-9. La primera fase corresponde al preprocesamiento, donde se arreglan las imágenes multiespectrales y se genera la imagen en falso verde a partir de estas. En la segunda etapa se alimenta la red neuronal convolucional con la imagen en falso verde. En la tercera etapa la imagen es procesada por YOLO dando como resultado las cajas delimitadoras de cada clase detectada. Finalmente, en la cuarta etapa se utiliza un algoritmo escrito en Python para estimar el porcentaje de maleza en la imagen a partir de las secciones detectadas como maleza.



**Figura 4-9:** Diagrama método 1.

Para seleccionar este primer método se entrenaron 10 modelos en total. A continuación se muestran los resultados de los dos mejores modelos teniendo en cuenta dos aspectos: que la exactitud fuera igual o mayor a 0.8 puesto que, según el estado del arte es un puntaje de exactitud aceptable para modelos con el mismo objetivo. Y que el valor-F fuese de 0.7 puesto que el etiquetado total para el entrenamiento fue de 2221 muestras para la lechuga y de 3481 para la maleza, lo que indica un claro desbalance de clases. También se trató de reducir al mínimo el número de imágenes sin perder desempeño en el modelo, con el fin de tener más imágenes para la validación y las pruebas de los modelos. Para estos dos modelos presentados el número de muestras para la clase lechuga fue de 810 (36 %) y para la clase maleza fue de 1482 (42 %).

**Tabla 4-2:** Configuración de valores etapa de entrenamiento.

	Modelo A	Modelo B
batch	16	16
subdivisions	8	16
max_batches	4000	12000
step 1	3200	9600
step 2	3600	10800

Se denominan estos dos modelos como Modelo A y Modelo B, los cuales duraron en etapa de entrenamiento aproximadamente 24 y 60 horas respectivamente, esto en parte a los recursos de hardware disponibles y a la variable de configuración batch, el hardware empleado no soportaba un valor mayor a 16. El modelo A no presenta cambios en las capas con respecto

**Tabla 4-3:** Métricas de desempeño por modelo

	Exactitud	VPN	Valor-F	Sensibilidad
Modelo A - Lettuce	0.84	0.80	0.74	0.58
Modelo A - Weed	0.50	0.43	0.33	0.20
Modelo B - Lettuce	<b>0.88</b>	<b>0.91</b>	<b>0.90</b>	<b>0.85</b>
Modelo B - Weed	<b>0.74</b>	<b>0.60</b>	<b>0.47</b>	<b>0.60</b>

a la arquitectura YOLOv3, mientras que el modelo B presenta una capa de convolución extra ubicada antes de la última capa YOLO, en cuanto a los valores de configuración que se modificaron en el archivo .cfg estos se muestran en la tabla 4-2.

En cuanto a los resultados presentados en la Tabla 4-3, se infiere que la predicción para cuando la clase es negativa es buena para ambos modelos, lo mismo sucede cuando predice clases de manera positiva, lo cual indica que los modelos se equivocan muy poco a la hora de clasificar positivos y negativos, sin embargo cuando los modelos clasifican negativos el desempeño es mejor para la clase lechuga en ambos modelos, mientras que para la clase maleza es bastante mediocre. A lo sumo, se evidencia que el Modelo B obtuvo un mejor desempeño clasificando ambas clases lechuga y maleza, incluyendo cuando la clase es positiva, dado que el porcentaje de clasificación también es mucho mejor en el Modelo B en ambas clases.

**Figura 4-10:** Imagen de salida YOLOv3 Modelo B

Analizando lo mencionado anteriormente, es claro que el Modelo B es mejor, pero también

los valores evidencian que aunque hay valores de exactitud y precisión altos, el VPN (valor de predicción negativo) y el valor-F muestran que ambos modelos tienen desempeños muy bajos en cuanto a la clase maleza, puesto que ni siquiera superaron el umbral propuesto de 0.7 siendo los de mejor desempeño en todos los entrenados y testeados. Esto se evidencia en la figura 4-10 evaluada por Modelo B, en donde se ve claramente que el mejor modelo obtenido trabaja muy bien para la clase lechuga, pero con malos resultados para la clase maleza dejando parches grandes y muestras pequeñas sin etiquetar.

#### 4.7.2. Método 2 Detección una clase con segmentación NDVI

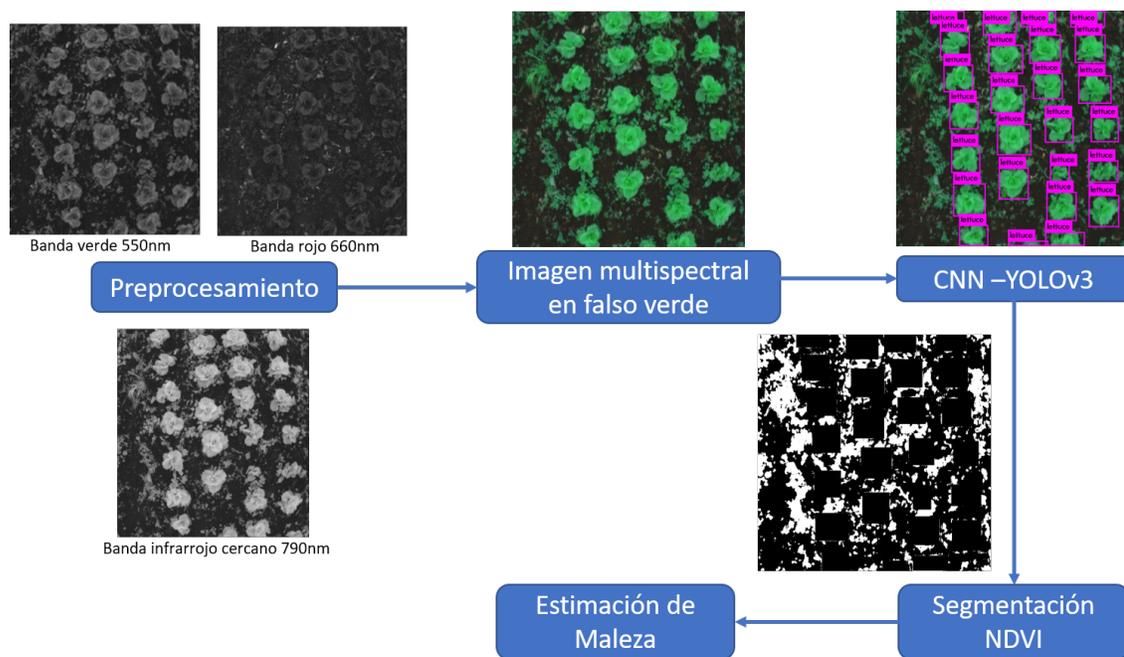


Figura 4-11: Diagrama método 2

El método 2 se diseña partiendo de la experiencia de desarrollo del método 1. Basándose en el hecho de que los métodos entrenados tuvieron mejor desempeño para la clase lechuga, se decidió cambiar la tercera etapa y entrenar un modelo mejorado para esta única clase. Además de agregar una etapa más, como se puede ver en la figura 4-11, en esta etapa se toman todas las lechugas detectadas por YOLO y se retiran de la imagen, luego se realiza una segmentación de la imagen utilizando el índice de vegetación normalizado (NDVI) para resaltar todo aquello que sea vegetación. Una vez retirado el cultivo de la imagen, se resalta la vegetación restante y se procede a generar una imagen binarizada, donde la vegetación está representada por el color blanco, lo que facilita la estimación de la maleza calculando el porcentaje de píxeles blancos en el total de la imagen. Este proceso se automatizó con

un script en python que recibe como entradas las coordenadas de los cuadros delimitadores arrojados por el modelo de YOLOv3 entrenado y la imagen a evaluar.

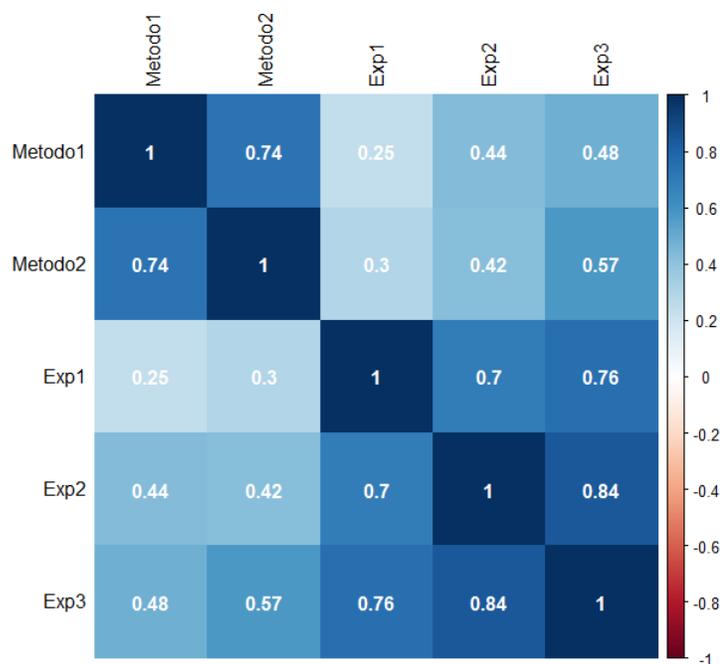
**Tabla 4-4:** Métricas de desempeño método 2

Métrica	Valor Obtenido
Exactitud	0.89
Sensibilidad	0.98
Precisión	0.91
Valor-F	0.94

Se entrenaron varias redes utilizando la misma configuración del Modelo B presentado anteriormente y se agrandó el conjunto de datos de entrenamiento a 39 %, 41 %, 43 % y 45 %. No obstante se utilizó el 41 % de las muestras ya que no se observó gran mejoría en el rendimiento por encima de este porcentaje. Con lo que se logró mejorar las medidas de desempeño para la detección del cultivo. Como se puede observar en la tabla 4-4, aunque la exactitud del método 2 superó en solo un 0.01 al Método 1(B) con respecto a la sensibilidad y la precisión, se demuestra que el porcentaje de lechugas detectadas satisfactoriamente mejoró notablemente con respecto a los modelos del método 1 y el incremento en el valor-F indica una mejora en el método 2 al disminuir el número de lechugas sin detectar.

## 5 Análisis y comparación

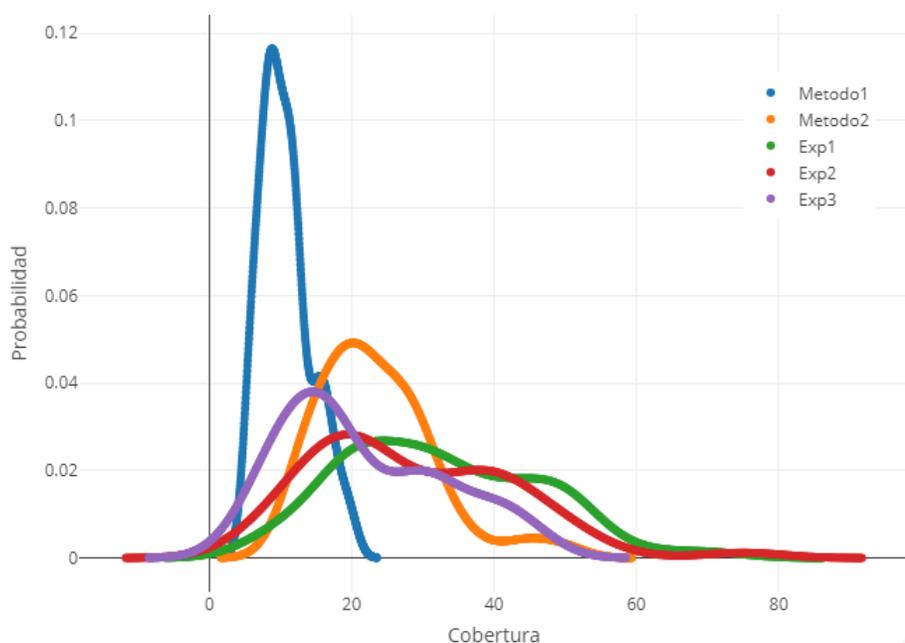
Tres expertos en malherbología estimaron de forma manual la cobertura de maleza en cada imagen. Es de resaltar que los profesionales tienen grados diferentes de formación: El experto 1 es BSc en malherbología, el experto 2 es MSc en malherbología y el experto 3 es PhD en la misma área. Cada uno de los expertos evaluó 100 imágenes dando su estimación porcentual de maleza, en donde el 0% denota que no hay maleza en la imagen y el 100% indica que la totalidad de la imagen es maleza.



**Figura 5-1:** Matriz de correlación métodos y expertos.

Analizando la matriz de correlación (Figura 5-1) se puede apreciar que las evaluaciones de expertos tienen una correlación fuerte entre sí, así mismo las de los métodos, que en parte se debe al factor humano que al momento de evaluar una imagen tiende a redondear cifras dando porcentajes con múltiplos de diez y cinco dentro de las evaluaciones, mientras que los modelos desarrollados dan cifras exactas con más de 7 decimales. Los valores de correlación de los expertos nos muestran como la experiencia y el conocimiento se reflejan claramente, puesto que el experto 1 que tiene menos preparación también tiene un valor de correlación

menor con el experto 3 quien es el más experimentado en comparación al experto 2 que al tener un nivel de conocimiento y formación medio tiene más correlación con el experto 3, lo que nos permite concluir que las evaluaciones de los expertos tienden a tener una correlación más alta con el experto 3 lo que hace posible que lo tomemos como un buen punto de comparación para una buena evaluación porcentual de cobertura de maleza con respecto a los métodos. Teniendo en cuenta lo anterior, el método 1 el cual tuvo un desempeño débil en la clasificación de malezas tiene una correlación débil con respecto a la evaluación de los expertos mientras que el método 2 mejora teniendo una correlación moderada en la evaluación del experto 3.



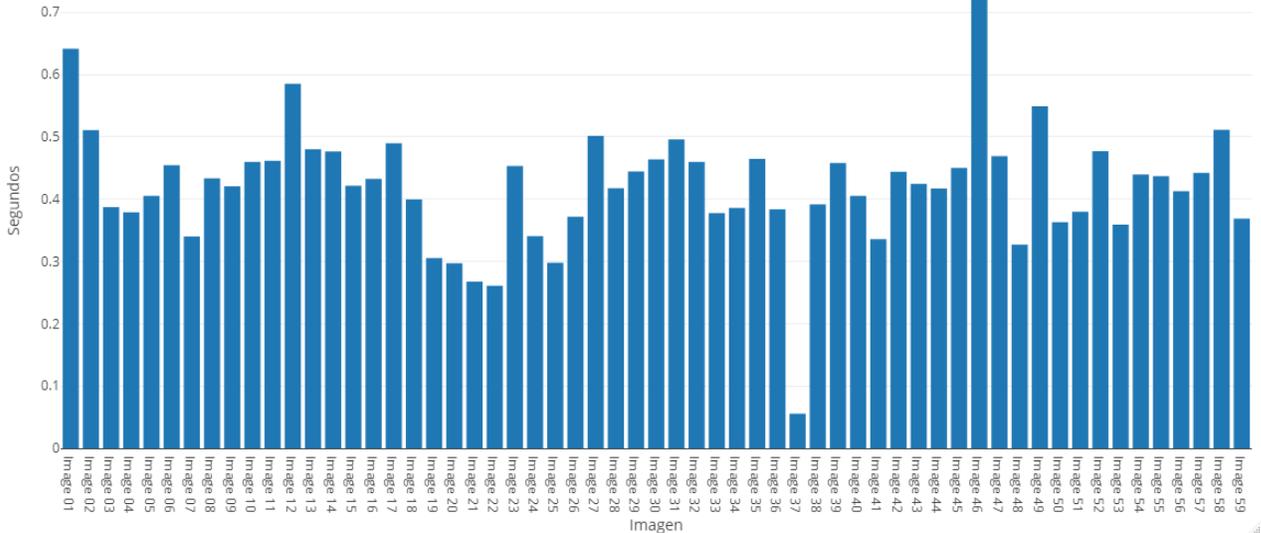
**Figura 5-2:** Distribución de probabilidad para las evaluaciones de maleza.

En relación con la distribución de probabilidad de la estimación de malezas que muestran los métodos (Fig. 5-2), la cual según Ambrosio debe mostrar características de una distribución de probabilidad binomial negativa se observa que tanto los métodos como los expertos lo cumplen sin embargo se puede apreciar en la figura 5-2 que el método 1 se aleja por completo del patrón de las demás evaluaciones. Mientras que el método 2 muestra ciertas tendencias similares con respecto a la evaluación de cobertura realizada por los expertos [Ambrosio et al., 2004].

Por otra parte método 1 presenta una subestimación altísima en comparación a las demás apreciaciones sin tener valores por encima del 25 % tendiendo a dar valores pequeños entre 7 % y el 15 %. En cuanto al método 2 tiene un rango de evaluación más parecido al del experto 3 entre el 10 % y el 55 %, lo cual deja ver claramente como los expertos 1 y 2 tienden

a sobrestimar más la maleza teniendo más valores por encima del 40%. Por otra parte, la estimación realizada por el método 2 también se asemeja en la evaluación de los expertos en que la mayoría de apreciaciones está concentrada entre el 10% y el 35% lo que denota un buen desempeño del método.

En cuanto al tiempo de procesamiento del método final (método 2) se tiene un tiempo promedio de 0.42 segundos por imagen, esta medición se realizó sin uso de GPU en un computador con procesador Xeon de 4 núcleos y 8 GB de RAM. Se realizaron 10 mediciones de tiempo por imagen en 59 imágenes de prueba promediando los tiempos tomados, los resultados se pueden observar en la figura 5-3. Revisando cada imagen y su tiempo de procesamiento se encontró una relación directamente proporcional entre el número de lechugas que debe detectar el método y el tiempo empleado, como es el caso en la imagen 37 donde solo se detectaron 2 lechugas y en los altos picos de las imágenes 1, 12 y 46 que corresponden a imágenes que tenían más de 25 lechugas detectadas por el método. Referente a la estimación de maleza no se encontró una relación importante que vincule de algún modo el tiempo de procesamiento con el porcentaje de maleza generado por el método.



**Figura 5-3:** Tiempo promedio de procesamiento por imagen.

En comparación con otros métodos se tienen los publicados por [Elstone et al., 2020] y [Raja et al., 2020] que aunque no cuantifican la maleza sí enfrentan el problema de la identificación y clasificación de maleza en cultivos de lechuga respectivamente. Estos presentan diferencias importantes con el presente trabajo, la primera y más relevante: la detección de ellos se realiza en tiempo real en entornos con luz artificial controlada, lo que facilita la calidad de las imágenes, como segunda diferencia relevante se tiene la disimilitud de cultivos, puesto que los parches de maleza en zonas de trópico alto como las presentadas en

el presente trabajo son muy desemejantes a las zonas por fuera del trópico como Estados Unidos e Inglaterra y por último, dichos métodos son enfocados al uso de la robótica para sistemas de fumigación automáticos. A pesar de lo anterior, el método 2 propuesto en este trabajo, logró una exactitud del 89 % en la detección de lechugas comparado con el 99.75 % de [Elstone et al., 2020] y el 88 % de [Raja et al., 2020]. Se concluye que se obtuvo un buen desempeño a partir de imágenes aéreas multiespectrales con luz natural.

# 6 Conclusiones y trabajo futuro

## 6.1. Conclusiones

En virtud del análisis realizado a partir de la literatura, se considera como una buena decisión el haberse decantado por métodos de IA que involucraran CNNs, dada su versatilidad, rapidez y facilidad para realizar cambios en la red con el fin de mejorar los resultados entre cada modelo. Lo cual permitió enfocarse en el objetivo principal, la evaluación porcentual de maleza dando como resultado la mejora del método 1 rediseñándolo y obteniendo el método 2, el cual claramente es más competente en la detección del cultivo y en la evaluación de la cobertura de maleza.

Teniendo en cuenta la comparación con otros métodos que trabajan el mismo tipo de cultivo, se recomienda fuertemente el uso de CNNs en este tipo de trabajos debido a que sus extractores de características ayudan a entrenar mejor los modelos que ven mejorada su detección del cultivo independientemente de la etapa de crecimiento de este, mientras que métodos que implican procesamiento de la imagen como thresholding, reflectivity entre otros o características fijas como tamaños tienden a debilitar la detección forzando ciertas condiciones de altura o iluminación.

En cuanto a YOLO como CNN y Darknet como framework se rescata su facilidad de realizar cambios en la arquitectura y la variedad de estas que se encuentran disponibles, al igual que su rapidez no solo en entrenar si no, en evaluar una imagen con un método ya entrenado, eso y sumado a su capacidad para hacerlo sin GPU hace que sean herramientas muy buenas para trabajos que impliquen detección en tiempo real y control automatizado de malezas.

Aunque el método planteado no tiene en cuenta las malezas subyacentes al cultivo debido a las cajas delimitadoras en las que se detecta la lechuga, en la comparación con las estimaciones de los expertos no se identifica una subestimación de maleza por parte del método, lo que puede indicar que estas malezas no afectan en gran medida la estimación realizada por el método, sin embargo aunque la media del método 2 presenta una distribución similar a la del experto 3 se puede ver que la diferencia radica en que los expertos tienden a sobrestimar la maleza por lo que sus rangos de evaluación son más amplios, mientras que los métodos al ser precisos tienen rangos de evaluación menores. Este rango de variabilidad entre las evaluaciones deberá ser estudiado en trabajos futuros que involucren costos y tiempo en el proceso de erradicación o control e indiquen qué tan relevante puede ser a la hora de manejar la maleza.

Por último, se resalta que el uso de redes neuronales convoluciones como eje central para crear métodos que ayuden a mejorar la optimización de procesos en la agricultura, y para el caso específico de la evaluación de cobertura de malezas son poderosas herramientas que generan excelentes resultados, mejorando la exactitud de la evaluación, pero sin alejarse del conocimiento y la experiencia del experto, el cual debe ser involucrado en labores claves del desarrollo del método como el proceso de etiquetado de las imágenes de entrenamiento.

## 6.2. Publicación

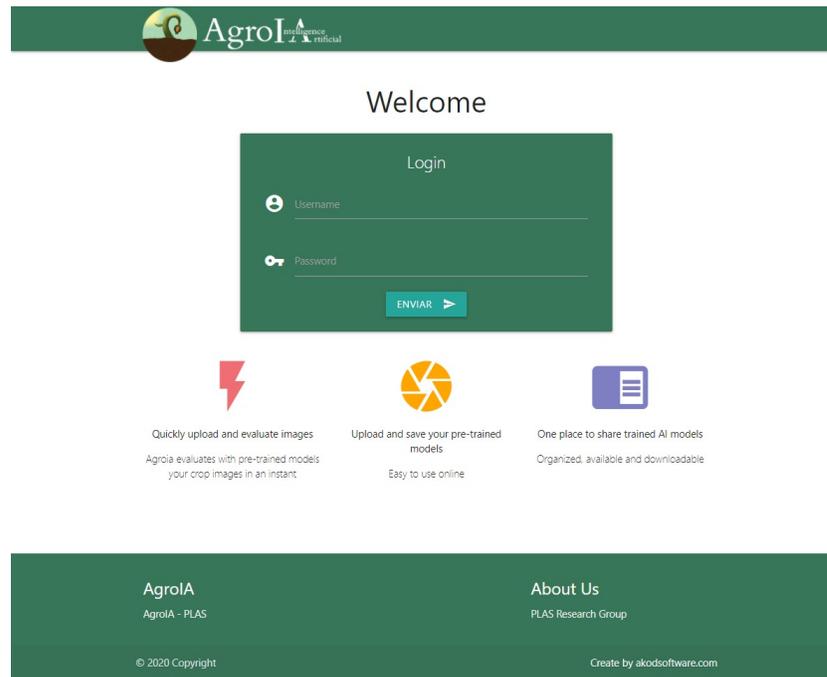
El trabajo aquí presentado sirvió como base para la publicación del artículo “A Deep Learning Approach for Weed Detection in Lettuce Crops Using Multispectral Images” [Osorio et al., 2020].

The screenshot shows the MDPI website interface. At the top, there is a navigation bar with the MDPI logo and links for '25th Anniversary', 'Journals', 'Information', 'Author Services', 'Initiatives', and 'About'. On the right side of the navigation bar are buttons for 'Profile', 'Sign Out', and 'Submit'. Below the navigation bar is a search bar with the text 'Search for Articles:' and several input fields: 'Title / Keyword', 'Author / Affiliation', a dropdown menu set to 'AgriEngineering', and another dropdown menu set to 'All Article Types'. There are 'Search' and 'Advanced' buttons to the right of the search bar. Below the search bar, the breadcrumb path reads 'Journals / AgriEngineering / Volume 2 / Issue 3 / 10.3390/agriengineering2030032'. The main content area features the AgriEngineering logo on the left, with buttons for 'Submit to this Journal', 'Review for this Journal', and 'Edit a Special Issue'. Below these is an 'Article Menu' section with an 'Article Overview' link and a list of options: 'Abstract', 'Open Access and Permissions', 'Share and Cite', 'Article Metrics', 'Related Articles', and 'Order Article Reprints'. The central part of the page displays the article title 'A Deep Learning Approach for Weed Detection in Lettuce Crops Using Multispectral Images' with 'Open Access' and 'Article' tags. The authors listed are Kavir Osorio, Andrés Puerto, Cesar Pedraza, and David Jamaica, with Leonardo Rodriguez as the corresponding author. Their affiliations are provided: Faculty of Engineering at Universidad Nacional de Colombia (Bogotá), External Consultant (Bogotá), and Faculty of Engineering at Universidad de Cundinamarca (Fusagasuga). The article is identified as 'AgriEngineering 2020, 2(3), 471-488; https://doi.org/10.3390/agriengineering2030032'. It includes submission dates: 'Received: 30 June 2020 / Revised: 19 August 2020 / Accepted: 20 August 2020 / Published: 28 August 2020'. A note states '(This article belongs to the Special Issue Precision Agriculture Technologies for Management of Plant Diseases)'. At the bottom of the article information are buttons for 'View Full-Text', 'Download PDF', 'Browse Figures', and 'Citation Export'. On the right side of the article, there are social media sharing icons (Facebook, Twitter, LinkedIn, etc.) and a '0' next to each, indicating no shares or likes yet.

Figura 6-1: Captura artículo publicado en MDPI por la revista AgriEngineering

## 6.3. Trabajo futuro

Se tiene la iniciativa de mejorar el método 2 usando máscaras para la identificación del contorno del cultivo, lo cual mejoraría la precisión en la evaluación de cobertura de maleza y se tendrían en cuenta las malezas subyacentes al cultivo.



**Figura 6-2:** AgroIA inicio



**Figura 6-3:** AgroIA tablero

Considerando que el uso de los métodos presentados en este trabajo y en muchos otros como los mencionados en la tabla del Anexo A requieren al menos conocimiento básico de manejo de terminales o lenguajes de programación para realizar una estimación, por lo cual se planteó diseñar y crear una plataforma web que le diera al usuario final la posibilidad de realizar las estimaciones de maleza a partir de imágenes cargadas con una interfaz fácil de

usar, de modo que personas que no están familiarizadas con la ingeniería o la inteligencia artificial puedan usarla. Teniendo en cuenta lo anterior, se desarrolló AgroIA (Figura 6-2) una plataforma web en la cual el usuario puede subir imágenes de cultivos, escoger el método de evaluación de maleza que desea utilizar y en minutos tener una estimación aproximada.

Actualmente, AgroIA tiene solo dos métodos de estimación porcentual de maleza para cultivos de lechuga, pero se diseñó para que existan dos tipos de usuarios, el primero que solo tiene acceso a los métodos publicados y a usarlos para sus estimaciones y el segundo usuario que tiene los mismos accesos, pero también tiene la posibilidad de subir métodos de su autoría con el fin de enriquecer el catálogo de métodos para diferentes cultivos (6-3).

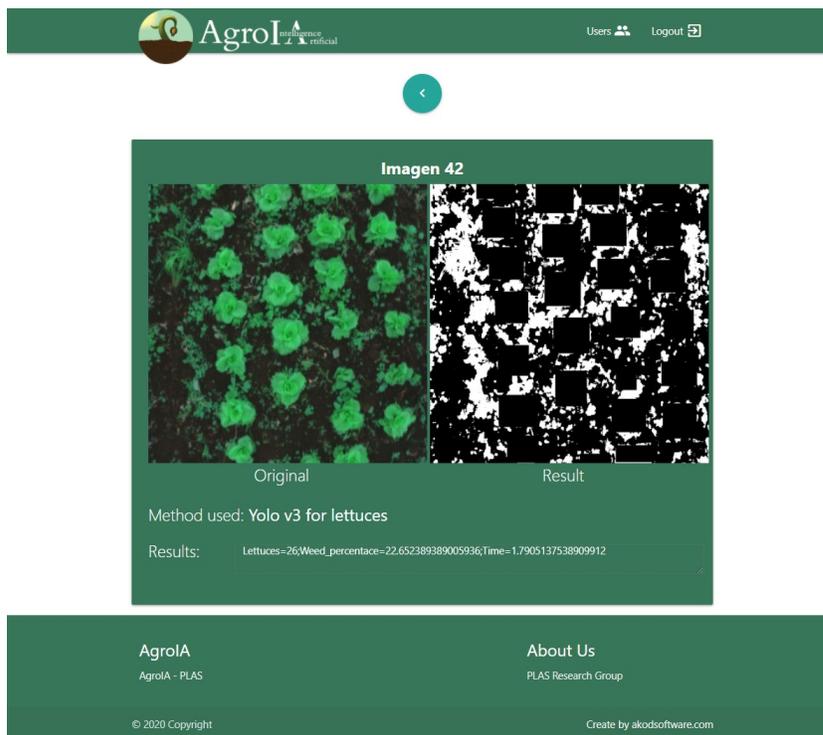
En la figura 6-4 se puede ver el formulario en el cual se carga la imagen a evaluar asignándole un nombre, una descripción y seleccionando el método que se desea usar, una vez se envía el formulario, la plataforma registra todo en una base de datos y pasa la imagen al método para que sea evaluada. Luego los resultados son guardados en la base de datos y se muestra al usuario la pantalla en la figura 6-5, en donde se visualiza la imagen cargada original, la imagen resultante, el método empleado para la relación y el resultado arrojado por el método. En este caso nos indica que identificó 26 lechugas, un 22.6 % de maleza y 1.79 segundos de tiempo de ejecución.

The image shows a web interface for uploading an image for analysis. The form is titled "Upload your image" and is set against a dark green background. It contains the following fields and elements:

- Title:** A text input field containing "Imagen 42".
- Detail:** A text input field containing "Imagen del cultivo 72".
- Image:** A field showing a file named "imagen51.jpg" with a small image icon to its left.
- Method:** A dropdown menu currently showing "Yolo v3 for lettuces".
- Submit:** A blue button labeled "ENVIAR" with a right-pointing arrow.

The page header features the AgroIA logo (a globe with a leaf) and the text "AgroIA Intelligence Artificial". To the right are links for "Users" and "Logout". The footer contains the text "AgroIA - PLAS", "About Us - PLAS Research Group", "© 2020 Copyright", and "Create by akodssoftware.com".

Figura 6-4: AgroIA formulario de carga



**Figura 6-5:** AgroIA resultados

Todas las imágenes evaluadas por AgroIA van quedando en el repositorio de cada usuario para que pueda consultarlas cuando desee. Esta es la primera versión estable de AgroIA, por ello se quiere mejorar aun más, como el hecho de que puedan cargarse paquetes de imágenes u ortomosaicos administrables, para que a su vez se generen reportes y estadísticas entre los métodos y cultivos, estas y otras mejoras en pro de ofrecer la solución a un público más diverso de forma accesible.

# Bibliografía

- [Abdulsalam and Aouf, 2020] Abdulsalam, M. and Aouf, N. (2020). Deep weed detector/classifier network for precision agriculture. *Mediterranean Conference on Control and Automation*.
- [Ahmed et al., 2017] Ahmed, O. S., Shemrock, A., Chabot, D., Dillon, C., Williams, G., Wasson, R., and Franklin, S. E. (2017). Hierarchical land cover and vegetation classification using multispectral data acquired from an unmanned aerial vehicle. *International Journal of Remote Sensing*, 38(8):2037–2052.
- [Ambrosio et al., 2004] Ambrosio, L., Iglesias, L., Marin, C., and Del Monte, J. (2004). Evaluation of sampling methods and assessment of the sample size to estimate the weed seedbank in soil, taking into account spatial variability. *Weed Research*, 44(3):224–236.
- [Barrero et al., 2016] Barrero, O. Rojas, D., Gonzalez, C., and Perdomo, S. (2016). Weed detection in rice fields using aerial images and neural networks. *IEEE Xplore. Universidad de Ibagué*.
- [Behmann et al., 2015] Behmann, J., Mahlein, A. K., Rumpf, T., Römer, C., and Plümer, L. (2015). A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. *Precision Agriculture*, 16(3):239–260.
- [Bell et al., 2004] Bell, G., Howell, B., Johnson, G., Raun, W., Solie, J., and Stone, M. (2004). Optical sensing of turfgrass chlorophyll content and tissue nitrogen. *HortScience HortSci*, 39(5):1130–1132.
- [Betancourt, 2014] Betancourt, G. D. (2014). Sistema de visión por computador para detectar hierba no deseada en prototipo de cultivo de frijol usando ambiente controlado. Master’s thesis, Universidad Católica de Colombia.
- [Binch and Fox, 2017] Binch, A. and Fox, C. W. (2017). Controlled comparison of machine vision algorithms for rumex and urtica detection in grassland. *Comput. Electron*, 140:123–138.
- [Brown and Noble, 2005] Brown, R. B. and Noble, S. D. (2005). Site-specific weed management : Sensing requirements : What do we need to see ? *Weed Science*, 53(2):252–258.

- [CCB, 2015] CCB, C. d. C. d. B. (2015). *Manual Lechuga: Programa de apoyo agrícola y agroindustrial vicepresidencia del fortalecimiento empresarial*.
- [Chavan and Nandedkar, 2018] Chavan, T. R. and Nandedkar, A. V. (2018). Agroavnet for crops and weeds classification: A step forward in automatic farming. *Computers and Electronics in Agriculture*, 154:361–372.
- [Cheng and Matson, 2015] Cheng, B. and Matson, E. T. (2015). A feature-based machine learning agent for automatic rice and weed discrimination. *Lecture Notes in Computer Science*, pages 517–527.
- [Corredor, 2011] Corredor, G. P. (2011). Desarrollo de un sistema de control en la aplicación de técnicas selectivas de eliminación de maleza. Master’s thesis, Universidad Nacional de Colombia.
- [Doll and Piedrahita, 1978] Doll, J. D. and Piedrahita, W. (1978). *Métodos de control de maleza en yuca*. Centro internacional de agricultura tropical Santiago de Calí, Colombia.
- [Dyrmann et al., 2017] Dyrmann, M., Jørgensen, R. N., and Midtiby, H. S. (2017). Roboweedsupport – detection of weed locations in leaf occluded cereal crops using a fully convolutional neural network. *11th European Conference on Precision Agriculture (ECPA)*.
- [Dyrmann et al., 2016a] Dyrmann, M., Karstoft, H., and Midtiby, H. S. (2016a). Plant species classification using deep convolutional neural network. *Biosystems Engineering*, 151:72–80.
- [Dyrmann et al., 2016b] Dyrmann, M., Mortensen, A. K., Midtiby, H. S., and Jørgensen, R. N. (2016b). Pixel-wise classification of weeds and crops in images by using a fully convolutional neural network. In *International Conference on Agricultural Engineering*.
- [Elstone et al., 2020] Elstone, L., How, K. Y., Brodie, S., Ghazali, M. Z., Heath, W. P., and Grieve, B. (2020). High speed crop and weed identification in lettuce fields for precision weeding. *Sensors*, 20(2).
- [Fuentes and Romero, 1991] Fuentes, L. and Romero, C. (1991). Una visión del problema de las malezas en colombia. *Agronomía Colombiana.*, 8(2):364–378.
- [García and A., 1997] García, B. and A., L. (1997). Malezas más comunes en colombia. *Produmedios Bogotá-Colombia*, 149.
- [Gómez, 1995] Gómez, J. F. (1995). Control de malezas. *Ceñicaña. El cultivo de la caña en la zona azucarera de Colombia*, pages 143–152.

- [Hamuda et al., 2018] Hamuda, E., Ginley, M., B., G. M., and Jones, E. (2018). Improved image processing-based crop detection using kalman filtering and the hungarian algorithm. *Computers and Electronics in Agriculture*, 148:37 – 44.
- [Hernández, 2017] Hernández, S. (2017). Metodología para la discriminación de malezas basada en la respuesta espectral de la vegetación. Master’s thesis, Universidad Nacional de Colombia.
- [Huang et al., 2018a] Huang, H., Deng, J., Lan, Y., Yang, A., Deng, X., Wen, S., and Zhang, Y. . (2018a). Accurate weed mapping and prescription map generation based on fully convolutional networks using uav imagery. *Sensors (Switzerland)*, 18(10).
- [Huang et al., 2018b] Huang, H., Lan, Y., Deng, J., Yang, A., Deng, X., Zhang, L., and Wen, S. (2018b). A semantic labeling approach for accurate weed mapping of high resolution uav imagery. *Sensors (Switzerland)*, 18(7).
- [Huang et al., 2018c] Huang, H. Deng, J., Lan, Y. Yang, A. D. X., and Zhang, L. (2018c). A fully convolutional network for weed mapping of unmanned aerial vehicle (uav) imagery. *PLoS ONE*, 13(4).
- [Hung et al., 2014] Hung, C., Xu, Z., and Sukkarieh, S. (2014). Feature learning based approach for weed classification using high resolution aerial images from a digital camera mounted on a uav. *Remote Sensing*, 6.
- [INDAP, 2017] INDAP, I. d. d. a. C. (2017). *Manual de producción de Lechuga*.
- [Kamilaris and Prenafeta-Boldú, 2018] Kamilaris, A. and Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147:70–90.
- [Kharuf et al., 2018] Kharuf, G., Hernández, S., Orozco, M., cAday, D., de la C, O., and Delgado, M. (2018). Análisis de imágenes multispectrales adquiridas con vehículos aéreos no tripulados. *Ingeniería Electrónica, Automática y Comunicaciones*, 39(2):79–91.
- [Koger et al., 2003] Koger, C. H., Shaw, D. R., Watson, C. E., and Reddy, K. N. (2003). Detecting late- season weed infestations in soybean (glycine max). *Weed Technol*, 17:696–704.
- [Lameski et al., 2018] Lameski, P., Zdravevski, E., and Kulakov, A. (2018). Review of automated weed control approaches: An environmental impact perspective. *ICT Innovations*, 940:132–147.
- [Liakos et al., 2018] Liakos, K. G., Busato, P., Moshou, D., Pearson, S., and Bochtis, D. . (2018). *Machine learning in agriculture: A review*.

- [Liu and Bruch, 2020] Liu, B. and Bruch, R. (2020). Weed detection for selective spraying: a review. *AGRICULTURE ROBOTICS*.
- [Liu, 2020] Liu, B., B. R. (2020). Weed detection for selective spraying: a review. *Current Robotics Reports*, 1.
- [López-Granados, 2011] López-Granados, F. (2011). Weed detection for site-specific weed management: mapping and real-time approaches. *Weed Research*, 51:1–11.
- [López-Granados et al., 2016] López-Granados, F., Torres-Sánchez, J., De Castro, A.-I., Serrano-Pérez, A., Mesas-Carrascosa, F.-J., and Peña, J.-M. (2016). Object-based early monitoring of a grass weed in a grass crop using high resolution uav imagery. *Agronomy for Sustainable Development*, 36:4.
- [López-Granados et al., 2015] López-Granados, F., Torres-Sánchez, J., Serrano-Pérez, A., de Castro, A. I., Mesas-Carrascosa, F. J., and Peña, J. M. (2015). Early season weed mapping in sunflower using uav technology: variability of herbicide treatment maps against weed thresholds. *Precision Agriculture*, 17(2):183–199.
- [McCool et al., 2017] McCool, C., Pérez, T., and Upcroft, B. (2017). Mixtures of light-weight deep convolutional neural networks: applied to agricultural robotics. *IEEE Rob*, 2(3):1344–1351.
- [Milioto et al., 2017] Milioto, A., Lottes, P., and Stachniss, C. (2017). Real-time blob-wise sugar beets vs weeds classification for monitoring fields using convolutional neural networks. In *Proceedings of the International Conference on Unmanned Aerial Vehicles in Geomatics*.
- [Montenegro and Parada, 2015] Montenegro, B. A. and Parada, R. C. (2015). Diseño e implementación de un sistema de detección de malezas en cultivos cundiboyacenses. Master’s thesis, Universidad Católica de Colombia.
- [Nieuwenhuizen et al., 2007] Nieuwenhuizen, A. T., Tang, L., Hofstee, J. W., Müller, J., and van Henten, E. J. (2007). Colour based detection of volunteer potatoes as weeds in sugar beet fields using machine vision. *Precision Agriculture*, 8(6):267–278.
- [Osorio et al., 2020] Osorio, K., Puerto, A., Pedraza, C., Jamaica, D., and Rodríguez, L. (2020). A deep learning approach for weed detection in lettuce crops using multispectral images. *AgriEngineering*, 2(3):471–488.
- [Pantazi et al., 2016] Pantazi, X.-E., Moshou, D., and Bravo, C. (2016). Active learning system for weed species recognition based on hyperspectral sensing. *Biosyst. Eng*, 146:193–202.

- [Pantazi et al., 2017] Pantazi, X. E., Tamouridou, A. A., Alexandridis, T. K., Lagopodi, A. L., Kashefi, J., and Moshou, D. (2017). Evaluation of hierarchical self-organising maps for weed mapping using uas multispectral imagery. *Computers and Electronics in Agriculture*, 139:224–230.
- [Partel et al., 2018] Partel, V., Charan Kakarla, S., and Ampatzidis, Y. (2018). Development and evaluation of a low-cost and smart technology for precision weed management utilizing artificial intelligence. *Computers and Electronics in Agriculture*, 157:339–350.
- [Peña et al., 2013] Peña, J. M., Torres-Sánchez, J., de Castro, A. I., Kelly, M., and López-Granados, F. (2013). Weed mapping in early-season maize fields using object-based analysis of unmanned aerial vehicle (uav) images. *PLoS ONE*, 8:10.
- [Potena et al., 2016] Potena, C., Nardi, D., and Pretto, A. (2016). Fast and accurate crop and weed identification with summarized train sets for precision agriculture. In *International Conference on Intelligent Autonomous Systems.*, page 105–121.
- [Puerto, 2019] Puerto, L. (2019). Clasificación y cuantificación de maleza en cultivos de hortalizas por medio de procesamiento de imágenes digitales multiespectrales. Master’s thesis, Universidad Nacional de Colombia.
- [Raja et al., 2020] Raja, R., Nguyen, T. T., Slaughter, D. C., and Fennimore, S. A. (2020). Real-time weed-crop classification and localisation technique for robotic weed control in lettuce. *Biosystems Engineering*, 192:257–274.
- [Redmon, 2016] Redmon, J. (2013–2016). Darknet: Open source neural networks in c. <http://pjreddie.com/darknet/>.
- [Redmon and Farhadi, 2018] Redmon, J. and Farhadi, A. (2018). Yolov3: An incremental improvement. *arXiv*.
- [Redmon J. and A., 2016] Redmon J., Divvala S., G. R. and A., F. (2016). You only look once: Unified, real-time object detection. *arXiv*.
- [Rumpf et al., 2012] Rumpf, T., Römer, C., Weis, M., Sökefeld, M., Gerhards, R., and Plümer, L. (2012). Sequential support vector machine classification for small-grain weed species discrimination with special regard to *cirsium arvense* and *galium aparine*. *Computers and Electronics in Agriculture*, 80:89–96.
- [Sa et al., 2018a] Sa, I., Chen, Z., Popovic, M., Khanna, R., Liebisch, F., Nieto, J., and Siegwart, R. (2018a). Weednet: Dense semantic weed classification using multispectral images and mav for smart farming. *IEEE Robotics and Automation Letters*, 3(1):588–595.

- [Sa et al., 2018b] Sa, I., Popovic, M., Khanna, R., Chen, Z., Lottes, P., Liebisch, F., and Siegwart, R. (2018b). Weedmap: A large-scale semantic weed mapping framework using aerial multispectral imaging and deep neural network for precision farming.
- [Shaun M. Sharpe and Boyd, 2019] Shaun M. Sharpe, Arnold W. Schumann, J. Y. and Boyd, N. S. (2019). Vegetation detection and discrimination within vegetable plasticulture row-middles using a convolutional neural network. *Precision Agriculture*.
- [Simonyan and Zisserman, 2015] Simonyan, K. and Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *CoRR*, abs/1409.1556.
- [Sogamoso González, 2015] Sogamoso González, D. S., A. R. J. A. . S. G. L. E. (2015). Integración de la mecatrónica al desarrollo de la agricultura de precisión aplicada al control mecánico de maleza. Master's thesis, Universidad Militar Nueva Granada. Bogotá-Colombia.
- [Srinivasan, 2006] Srinivasan, A. (2006). Precision agriculture: An overview a srinivasan. In *Handbook of Precision Agriculture: Principles and Applications.*, pages 3–18.
- [Suh et al., 2018] Suh, H. K., IJsselmuiden, J., Hofstee, J. W., and van Henten, E. J. (2018). Transfer learning for the classification of sugar beet and volunteer potato under field conditions. *Biosystems Engineering*, 174:50–65.
- [Sun et al., 2018] Sun, J., He, X., Ge, X., Wu, X., Shen, J., and Song, Y. (2018). Detection of key organs in tomato based on deep migration learning in a complex background. *Agriculture*, 8(12):196.
- [Tao et al., 2018] Tao, T., Wu, S., Li, L., Li, J., Bao, S., and Wei, X. (2018). Design and experiments of weeding teleoperated robot spectral sensor for winter rape and weed identification. *Advances in Mechanical Engineering*, 10:5.
- [Tellaeché et al., 2008] Tellaeché, A., Artizzu, B., P., X., Pajares, G., Ribeiro, A., and Fernández-Quintanilla, C. (2008). A new vision-based approach to differential spraying in precision agriculture. *Computers and Electronics in Agriculture*, 60(2):144–155.
- [Thorp and Tian, 2004] Thorp, K. R. and Tian, L. F. (2004). A review on remote sensing of weeds in agriculture. *Precision Agriculture*, 5(5):477–508.
- [Tzutalin, 2015] Tzutalin (2015). Labelimg. <https://github.com/tzutalin/labelImg>. Accessed: 2020-03-30.
- [Wang et al., 2019] Wang, A., Zhang, W., and Wei, X. (2019). A review on weed detection using ground-based machine vision and image processing techniques. *Computers and Electronics in Agriculture*, 158:226–240.

- [Xinshao and Cheng, 2015] Xinshao, W. and Cheng, C. (2015). Weed seeds classification based on pcanet deep learning baseline. *IEEE Signal and Information Processing Association Annual Summit and Conference (APSIPA)*, pp, page 408–415.
- [Yunong Tian, 2019] Yunong Tian, Guodong Yang, Z. W. H. W. E. L. Z. L. (2019). Apple detection during different growth stages in orchards using the improved yolo-v3 model. *Computers and Electronics in Agriculture*, 157:417–426.