



**Educación**  
Secretaría de Educación Pública



TECNOLÓGICO  
NACIONAL DE MÉXICO

**INSTITUTO TECNOLÓGICO DE  
DURANGO**

**INSTITUTO TECNOLÓGICO DEL  
VALLE DEL GUADIANA**

**DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN**



**“Análisis cronológico de las características de la cebolla  
mediante imágenes para determinar la madurez  
fisiológica.”**

**TESIS**

Que como parte de los requisitos para obtener el grado de

**Maestría en Ingeniería**

**Presenta:**

Patricia Ayala Verdín

**Director de tesis:**

Rubén Guerrero Rivera

**Co-Director:**

Oscar Gilberto Alaniz Villanueva

Durango, Dgo. México, noviembre, 2024.



**Análisis cronológico de las características de la cebolla mediante imágenes para  
determinar la madurez fisiológica**

**Presenta:**

**Ing. Patricia Ayala Verdín**

**COMITÉ TUTORIAL**

|  |  |
|--|--|
| <b>Dr. Rubén Guerrero Rivera</b><br>Director       |  |
| <b>M.C. Oscar Alaniz Villanueva</b><br>Codirector  |  |
| <b>M.C. José Antonio Martínez Rivera</b><br>Asesor |  |
| <b>M.C. Norma Alicia García Vidana</b><br>Asesor   |  |

**M.C. Norma Alicia García Vidana**

**Coordinador del programa de la maestría  
en ingeniería.**

**Dr. Francisco Javier Godínez García**

**Jefe de la División de Estudios de  
Posgrado e Investigación**



TECNOLÓGICO  
NACIONAL DE MÉXICO



Instituto Tecnológico de Durango  
División de Estudios de Posgrado e Investigación

Victoria de Durango, Dgo., a **29 / Noviembre / 2024**

DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN  
DEPI / C / 653 / 2024.  
ASUNTO: Autorización de Tema de Tesis de Maestría.

**C. PATRICIA AYALA VERDÍN**  
No. DE CONTROL G22040323  
**PRESENTE.**

Con base en el Reglamento en vigor y teniendo en cuenta el dictamen emitido por el Jurado que le fue asignado, se le autoriza a desarrollar el tema de tesis para obtener el **Grado de Maestra en Ingeniería** cuyo título es:

**"Análisis cronológico de las características de la cebolla mediante imágenes para determinar la madurez fisiológica"**

**CONTENIDO:**

- RESUMEN
- CAPÍTULO I DEFINICIÓN DEL PROBLEMA DE INVESTIGACIÓN
- CAPÍTULO II MARCO TEÓRICO
- CAPÍTULO III METODOLOGÍA
- CAPÍTULO IV RESULTADOS
- CAPÍTULO V CONCLUSIONES
- CAPÍTULO VI REFERENCIAS BIBLIOGRÁFICAS
- ANEXOS

**ATENTAMENTE.**

Excelencia en Educación Tecnológica\*  
"La Técnica al Servicio de la Patria"

**C. FRANCISCO JAVIER GODÍNEZ GARCÍA**  
JEFE DE LA DIVISIÓN DE ESTUDIOS DE  
POSGRADO E INVESTIGACIÓN



FIGGammc.





TECNOLÓGICO  
NACIONAL DE MÉXICO



Instituto Tecnológico de Durango  
División de Estudios de Posgrado e Investigación

Victoria de Durango, Dgo., a **29 / Noviembre / 2024**

DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN  
DEPI / C / 654 / 2024.

ASUNTO: Autorización de impresión de Tesis de Maestría.

**C. PATRICIA AYALA VERDÍN**  
No. DE CONTROL G22040323  
**PRESENTE.**

De acuerdo al reglamento en vigor y tomando en cuenta el dictamen emitido por el jurado que le fue asignado para la revisión de su trabajo de tesis para obtener el **Grado de Maestra en Ingeniería**, esta División de Estudios de Posgrado e Investigación le autoriza la impresión del mismo, cuyo título es:

**"Análisis cronológico de las características de la cebolla mediante imágenes para determinar la madurez fisiológica"**

Sin otro particular de momento, quedo de Usted.

**ATENTAMENTE.**

Excelencia en Educación Tecnológica\*  
"La Técnica al Servicio de la Patria"

**C. FRANCISCO JAVIER GODÍNEZ GARCÍA**  
JEFE DE LA DIVISIÓN DE ESTUDIOS DE  
POSGRADO E INVESTIGACIÓN



FJGGammc.





## Agradecimientos

Con profundo agradecimiento quiero expresar mi gratitud a CONAHCYT por brindarme un apoyo económico que significó un apoyo invaluable en mi camino académico y personal. Este apoyo no solo representó una ayuda financiera, sino una motivación para seguir avanzando en mis metas y aspiraciones. Gracias a esto, he tenido la oportunidad de dedicarme de lleno a mi formación, sabiendo que contaba con un respaldo sólido.

En este camino, hay un grupo de personas fundamentales a quienes también quiero expresar mi más profundo agradecimiento: mi familia. Ellos han sido mi fuerza y mi mayor fuente de inspiración.

Mi esposo, mi compañero de sueños, ha estado siempre a mi lado, apoyándome incondicionalmente en cada paso de este viaje. En los días de agotamiento, él ha sido mi pilar, recordándome que soy capaz de superar cualquier desafío. Su apoyo constante no solo me impulsa a seguir adelante, sino que me llena de orgullo por todo lo que estamos construyendo juntos como equipo. A mi hija, mi más grande motivación. Ella, con su amor puro, me recuerda cada día por qué vale la pena esforzarse tanto. Mi deseo de brindarle un futuro lleno de oportunidades es lo que me impulsa a dar lo mejor de mí. Este logro es tanto para ellos como para mí, porque cada paso que doy lo hago pensando en el bienestar de nuestra familia.

No puedo dejar de mencionar a los demás miembros de mi familia, quienes también han sido un soporte crucial en este proceso. Sus palabras de aliento, sus sacrificios y su fe en mí me han llenado de energía en los momentos más complicados. Cada uno de ellos ha contribuido de alguna manera para que hoy este aquí.

También deseo agradecer de manera especial a mis maestros, quienes han sido guías en mi camino. Sus palabras de aliento, sus exigencias y su dedicación han sido clave para que hoy pueda mirar hacia el futuro con confianza y determinación. Estoy profundamente agradecida por la paciencia, el compromiso y la pasión que han depositado en cada momento compartido en las aulas.

De todo corazón, gracias por ser parte de este camino.

Atentamente,

Patricia Ayala Verdín

## Resumen

Para poder llevar a cabo una investigación acerca de un cultivo es necesario implementar técnicas o tecnologías que ayuden a identificar información y características que interfieran en los procesos fisiológicos de las plantas. Las redes neuronales convolucionales de tipo U-Net son las más utilizadas para poder detectar características específicas dentro de una imagen, ya que estas trabajan con imágenes segmentadas, lo que ayuda a su fácil interpretación. El presente trabajo de investigación plantea el uso de una red neuronal convolucional de tipo U-Net dentro de un cultivo de cebolla. La red neuronal fue entrenada con fotografías que se obtuvieron de diversas plantas de cebolla que se seleccionaron dentro del cultivo. La toma de fotografías fue de forma cronológica a lo largo de un periodo de crecimiento, luego de obtener las fotografías se implementó la segmentación semántica, en donde solo se seleccionó lo que era las hojas, el tallo de la planta y en algunos casos el bulbo que se encontraba visible, para finalmente entrenar el modelo de la red, en donde se obtuvieron 93.90% de precisión al momento de su entrenamiento, así como una predicción acertada de la planta de cebolla. Los resultados obtenidos muestran que la utilización de una red neuronal convolucional U-Net puede ser una herramienta eficaz para detectar las características de esta, y utilizar estos resultados para futuras investigaciones.

## **Abstract**

To carry out research on a crop, it is necessary to implement techniques or technologies that help identify information and characteristics that interfere with the physiological processes of plants. U-Net convolutional neural networks are the most widely used to detect specific features within an image, as they work with segmented images, which helps them to be easily interpreted. The present research proposes the use of a U-Net convolutional neural network within an onion crop. The neural network was trained with photographs that were obtained from various onion plants that were selected within the crop. The taking of photographs was chronologically throughout a period of growth, after obtaining the photographs, semantic segmentation was implemented, where only the leaves, the stem of the plant and in some cases the bulb that was visible were selected, to finally train the model of the network. where 93.90% accuracy was obtained at the time of training, as well as an accurate prediction of the onion plant. The results obtained show that the use of a convolutional neural network U-Net can be an effective tool to detect its characteristics and use these results for future research.

## Tabla de contenido

|  |       |
|--|-------|
| <b>I. DEFINICIÓN DEL PROBLEMA DE INVESTIGACIÓN</b> ..... | XIII  |
| <b>1.1 Introducción</b> .....                            | XIII  |
| <b>1.2 Definición del problema</b> .....                 | XIII  |
| <b>1.3 Hipótesis</b> .....                               | XIV   |
| <b>1.4 Objetivos</b> .....                               | XIV   |
| <b>1.4.1 Objetivo general</b> .....                      | XIV   |
| <b>1.4.2 Objetivos específicos</b> .....                 | XIV   |
| <b>1.5 Justificación</b> .....                           | XV    |
| <b>1.6 Limitaciones</b> .....                            | XV    |
| <b>1.7 Estado del arte</b> .....                         | XV    |
| <b>II. MARCO TEÓRICO</b> .....                           | XVII  |
| <b>2.1 Taxonomía</b> .....                               | XVII  |
| <b>2.2 Morfología de la cebolla</b> .....                | XVII  |
| <b>2.2.1 Hojas</b> .....                                 | XVII  |
| <b>2.2.2 Sistema radicular</b> .....                     | XVII  |
| <b>2.2.3 Tallo</b> .....                                 | XVII  |
| <b>2.2.4 Bulbo</b> .....                                 | XVIII |
| <b>2.2.5 Flores</b> .....                                | XVIII |
| <b>2.2.6 Fruto</b> .....                                 | XVIII |
| <b>2.2.7 Semilla</b> .....                               | XVIII |
| <b>2.3 Fenología de la cebolla</b> .....                 | XIX   |
| <b>2.4 Fotoperiodo y clima</b> .....                     | XIX   |
| <b>2.5 Procesamiento digital de imágenes</b> .....       | XX    |
| <b>2.5.1 Imagen digital</b> .....                        | XX    |
| <b>2.5.2 Píxel</b> .....                                 | XX    |
| <b>2.6 Visión por computadora</b> .....                  | XXI   |
| <b>2.7 Máquinas de aprendizaje</b> .....                 | XXI   |
| <b>2.7.1 Aprendizaje supervisado</b> .....               | XXII  |
| <b>2.7.2 Aprendizaje no supervisado</b> .....            | XXII  |
| <b>2.7.3 Aprendizaje semisupervisado</b> .....           | XXII  |



|  |              |
|--|--------------|
| 2.8 Redes neuronales .....                           | XXII         |
| 2.8.1 funciones de activación .....                  | XXIII        |
| <b>III. METODOLOGÍA.....</b>                         | <b>XXIX</b>  |
| 3.1 Área de estudio .....                            | XXIX         |
| 3.2 Diseño estadístico .....                         | XXX          |
| 3.3 Selección de la muestra .....                    | XXXI         |
| 3.4 Uso de referencia .....                          | XXXI         |
| 3.5 Captura de imágenes.....                         | XXXII        |
| 3.6 Medición del grosor de tallo .....               | XXXIV        |
| 3.7 Elaboración de máscaras de las imágenes.....     | XXXV         |
| 3.8 Selección de algoritmo de clasificación.....     | XXXVI        |
| 3.9 Entrenamiento de la red neuronal.....            | XXXVII       |
| 3.10 Validación del algoritmo de clasificación ..... | XXXVIII      |
| <b>VI. RESULTADOS .....</b>                          | <b>XXXIX</b> |
| 4.1 Relación de crecimiento.....                     | XXXIX        |
| 4.2 Relación entre bulbo y tallo.....                | XLIV         |
| 4.3 Segmentación de imágenes .....                   | XLV          |
| <b>V. CONCLUSIONES .....</b>                         | <b>XLIX</b>  |
| <b>VI. REFERENCIAS BIBLIOGRÁFICAS.....</b>           | <b>L</b>     |
| <b>Anexos .....</b>                                  | <b>LII</b>   |

## Índice de figuras

|   |         |
|---|---------|
| Figura 1 Partes externas de la planta de cebolla. ....  | XVIII   |
| Figura 2 Fenología de la cebolla.....   | XIX     |
| Figura 3 Representación de una matriz .....   | XX      |
| Figura 4 Representación de una imagen con píxeles.....  | XXI     |
| Figura 5 Representación gráfica de función lineal .....   | XXIII   |
| Figura 6 Representación gráfica de función Umbral.....  | XXIV    |
| Figura 7 Representación gráfica de función sigmoide .....   | XXV     |
| Figura 8 Representación gráfica de función tangente hiperbólica .....   | XXVI    |
| Figura 9 Representación gráfica de función ReLu.....  | XXVII   |
| Figura 10 Representación gráfica de función Softmax .....   | XXVIII  |
| Figura 11 plántulas de cebolla trasplantadas.....   | XXIX    |
| Figura 12 Representación de la eliminación de orillas.....  | XXX     |
| Figura 13 División del área de trabajo.....   | XXX     |
| Figura 14 Selección de muestra en cultivo.....  | XXXI    |
| Figura 15 Colocación de referencia.....   | XXXI    |
| Figura 16 referencia de donde se colocaba el vernier digital .....  | XXXIV   |
| Figura 17 Página Roboflow, ejemplo de segmentación de la imagen .....   | XXXV    |
| Figura 18 Arquitectura de U-Net parte A representa la sección del codificador y parte B representa la sección del decodificador. .... | XXXVII  |
| Figura 19 Resultado de validación del entrenamiento de la red neuronal.....   | XXXVIII |
| Figura 20 grafica de regresión lineal de medidas.....   | XXXIX   |
| Figura 21 grafica de regresión lineal de medidas.....   | XL      |
| Figura 22 grafica de regresión lineal de medidas.....   | XLI     |
| Figura 23 grafica de regresión lineal de medidas.....   | XLII    |
| Figura 24 grafica de regresión lineal de medidas.....   | XLIII   |
| Figura 25 medidas de tallo y bulbo .....  | XLIV    |
| Figura 26 grafica de regresión lineal medidas de tallo y bulbo.....   | XLIV    |
| Figura 27 Imagen original.....  | XLV     |
| Figura 28 imagen segmentada, con su división de cada elemento. ....   | XLV     |
| Figura 29 Imagen Original .....   | XLVI    |
| Figura 30 imagen segmentada, con su división de cada elemento. ....   | XLVI    |
| Figura 31 imagen Original .....   | XLVII   |
| Figura 32 imagen segmentada, con su división de cada elemento. ....   | XLVII   |
| Figura 33 Imagen Original .....   | XLVIII  |
| Figura 34 imagen segmentada, con su división de cada elemento. ....   | XLVIII  |

## Índice de tablas

|  |       |
|--|-------|
| Tabla 1 fechas de toma de fotografías .....                              | XXXII |
| Tabla 2 medidas obtenidas .....  | XXXIV |
| Tabla 3 días transcurridos y medidas de planta 1 línea 1 cuadro 1 .....  | XXXIX |
| Tabla 4 días transcurridos y medidas de planta 10 línea 2 cuadro 2 ..... | XL    |
| Tabla 5 días transcurridos y medidas de planta 1 línea 3 cuadro 3 .....  | XLI   |
| Tabla 6 días transcurridos y medidas de planta 10 línea 4 cuadro 4 ..... | XLII  |
| Tabla 7 días transcurridos y medidas planta 1 línea 3 cuadro 5 .....     | XLIII |

# I. DEFINICIÓN DEL PROBLEMA DE INVESTIGACIÓN

## 1.1 Introducción

La cebolla (*Allium cepa*) es una de las hortalizas más cultivadas y consumidas en el mundo, así como una gran importancia económica y nutricional. Para su desarrollo y rendimiento se necesita de diversos factores agronómicos, uno de los más importantes son las condiciones ambientales, las prácticas de manejo del cultivo y las características morfológicas de la planta. Unas de las características que pueden tener un impacto significativo en el rendimiento y la calidad de la cebolla son: el diámetro del bulbo de la cebolla y el grosor del tallo de la planta de la cebolla.

A lo largo del ciclo del cultivo, obtener una relación entre estas dos características podría proporcionar información importante sobre el crecimiento y el desarrollo de la planta. Se sabe que el grosor del tallo está relacionado con la capacidad de la planta para transportar nutrientes y agua desde las raíces hasta las hojas y el bulbo, mientras que el diámetro del bulbo nos indica el tamaño y la calidad del producto final. Sin embargo, hasta la fecha, no se ha establecido si existe una relación directa entre estas dos variables durante el período de crecimiento de la cebolla antes de la cosecha.

La presente investigación pretende analizar si existe una relación entre el diámetro del bulbo y el grosor del tallo de la planta de cebolla cuando aún se encuentra sembrada, durante su etapa de crecimiento vegetativo. Al poder determinar si existe una correlación significativa entre estas dos características se puede proporcionar una información muy importante para mejorar las prácticas del cultivo y para optimizar el rendimiento de la cebolla. El estudio de esta relación contribuirá en ayudar a los productores agrícolas a mejorar la calidad y el tamaño de la cosecha, ayudando así a una mayor eficiencia en la producción.

## 1.2 Definición del problema

Actualmente de acuerdo con los registros que se encuentran en SIAP (*Servicio de Información Agroalimentaria y Pesquera | Gobierno | Gob.Mx*, n.d.) en México en el mes de junio de año 2022 se obtuvo una producción total de 695,847.22 toneladas de cebolla. Del total, Durango participó con una producción de 11,793.80 toneladas. Actualmente la empresa ALDA JUCE SPR DE RL. Ubicada en Villa Unión, Poanas, Durango, presenta una problemática económicamente significativa ya que para poder exportar su producto a EE. UU. se requiere cumplir de ciertos requisitos en cuanto a la calidad, tamaño y madurez de acuerdo con los estándares de calidad establecidos por el departamento de Agricultura de los Estados Unidos (USDA)(*Marketing and Regulatory Programs Agricultural*

*Marketing Service Specialty Crops Program Specialty Crops Inspection Division United States Standards for Grades of Onion Sets, 2016*) y al no poder determinar con certeza el tamaño de la cebolla aún sembrada ocasiona que los gastos se eleven, ya que se sigue regando y fertilizando el cultivo hasta un periodo que el personal considere necesario causando una disminución de margen de ganancias. El costo de inversión por hectárea del cultivo es aproximadamente de \$62,000 estos costos son de la obtención de las plantas, su trasplante, el riego y el uso de fertilizantes a lo largo del ciclo fenológico de la cebolla. Estos costos de inversión son sin contar el costo de cosecha, ni el sistema de riego a utilizar. El ciclo fenológico tiene una duración de aproximadamente de seis meses, los cuales se cuentan a partir de su trasplante.

### **1.3 Hipótesis**

Bajo el supuesto que el tamaño de la cebolla está directamente relacionado con el diámetro del tallo, entonces es posible que, con la ayuda de la medición indirecta del grosor del tallo de la cebolla a través de imágenes fotográficas cronológicamente obtenidas durante su desarrollo, y aplicando métodos de visión artificial, es posible estimar el tamaño del bulbo de la cebolla cuando está se encuentra aún plantada, mediante un modelo relacional de estas variables.

### **1.4 Objetivos**

#### **1.4.1 Objetivo general**

Predecir el tamaño del bulbo de la cebolla durante su ciclo fenológico, mediante la medición del tallo, empleando métodos de visión por computadora para su comprobación.

#### **1.4.2 Objetivos específicos**

- Analizar la fenología de la planta de cebolla para encontrar si existe relación entre el bulbo de la cebolla y el diámetro de su tallo.
- Realizar un diseño de experimentos estadístico en el cultivo de cebolla.
- Obtener fotografías de manera cronológica del cultivo de cebolla durante su periodo de crecimiento.
- Obtener características fisiológicas del tallo de la planta por medio de las fotografías
- Análisis estadístico de la correlación existente en la planta de cebolla.
- Evaluar la duración del ciclo de crecimiento para disminuir inversión y aumentar producción

## **1.5 Justificación**

El presente trabajo se enfoca al estudio del desarrollo fisiológico por medio de imágenes, ya que no se cuenta con alguna técnica o tecnología para poder determinar el crecimiento con relación al diámetro ecuatorial que nos permita estimar el tamaño de la cebolla, lo cual permitirá conocer con anticipación el potencial mercado de la producción. Este trabajo permitirá mostrar si existe relación entre el grosor del tallo y el tamaño del bulbo que se encuentran completamente desarrolladas, con esta información se podrá concluir que el cultivo se encuentra en el tamaño requerido y así ahorrar en insumos utilizados a lo largo del periodo vegetativo del cultivo, y por consecuencia aumentar los rendimientos.

## **1.6 Limitaciones**

Al momento del desarrollo de esta investigación se presentaron diversas limitaciones con relación al cultivo de cebolla, el cultivo se encontraba al aire libre y por consecuencia existía diversos problemas como animales, cambios de clima y maquinaria agrícola lo que ocasionaba que algunas plantas no se desarrollaran de forma correcta. El trabajar en un área que se encuentra al aire libre es imposible controlar variables que son importantes para el desarrollo del cultivo, al igual que en el momento de tomar las fotografías no se podía tomar exactamente a la misma altura ni distancia, ya que el suelo cambiaba al momento de su riego. Al principio se marcaron las plantas con las que se iba a trabajar en la cintilla de riego que se encontraba enfrente de todas las plantas, pero esto no funciono ya que se movió y por consecuencia ya no se sabía con exactitud cuál era la planta con la que se estaba trabajando. También se tenía planeado medir el bulbo de cebolla al momento de su cosecha de forma física de todas las plantas con las que se trabajaron, pero se cosecho antes de la fecha planeada y por consecuencia las mediciones no se pudieron realizar.

## **1.7 Estado del arte**

La cebolla (*Allium cepa*) es un cultivo que se produce principalmente en Asia, África, Europa, América y Oceanía. Por las características con las que cuenta la cebolla con relación a su almacenamiento y su durabilidad de envío, estas son comercializadas con mayor facilidad a comparación de las demás hortalizas. (Suleria et al., 2014)

Según la información encontrada en (FAOSTAT, 2021) (Organización de las naciones Unidas para la Alimentación y la Agricultura) la producción mundial de la cebolla en el año 2021 fue de 4,562,530.61 toneladas, el principal país de producción fue China con una producción de 605,153,61 toneladas. México en el mismo año, obtuvo una producción de 97,360.16 toneladas. En la entidad de Durango, se consiguió una producción total de 14,140.35 toneladas donde el

municipio de Mapimí fue el principal productor con la cantidad de 9360 toneladas, en cambio el municipio de Durango, su producción fue de 107.80 toneladas.(Producción Agrícola | Servicio de Información Agroalimentaria y Pesquera | Gobierno | Gob.Mx, 2021).

Según (Saini & Saini, 2020) señala que el aumento del crecimiento de la población ha hecho que la agricultura se convierta en un sector muy importante de manera mundial, por ello la agricultura tiene como desafío mejorar la eficiencia y la calidad de sus productos finales sin un control físico constante para poder satisfacer de manera completa la demanda de alimentos. Para estos desafíos existen la agricultura de precisión la cual ayuda a optimizar el uso de los insumos agrícolas ya que utilizan la cantidad correcta de insumos, así como el momento adecuado y en el lugar exacto. La agricultura de precisión (AP) utilizan tecnologías para recabar información acerca de sus cultivos. Ya existe una evolución de la agricultura de precisión, esta se llama agricultura 4.0 o Agricultura inteligente la cual utiliza principalmente el internet de las cosas, Big Data, Inteligencia Artificial y la Robótica, estas herramientas ayudan a amplificar, agilizar y hacer más eficientes las actividades que se efectúan dentro de la agricultura.(da Silveira et al., 2021)

Para poder estudiar el crecimiento de un cultivo es necesario identificar los factores que influyen en su desarrollo. Para ello es necesario utilizar herramientas apropiadas, que existen de una combinación de la agricultura con las tecnologías, las cuales ayudan a la identificación de información y algunas características que interfieren en los procesos fisiológicos de las plantas.(Repositorio Institucional Caxcán: Identificación de Parámetros Comunes En Un Cultivo de Cebolla (*Allium Cepa*) Mediante PDI, 2021).

La utilización de la inteligencia artificial por medio de una red neuronal en la agricultura se ha aplicado en diversas situaciones como lo son el conteo de plantas dentro de un cultivo, identificación temprana de malezas, identificación de madurez del cultivo.

Según (Ullah et al., 2024) propone un método alternativo para automatizar la estimación del recuento de plantas y el espaciamiento de estas dentro del campo, utilizando dos tipos de redes neuronales, una de ellas es la red neuronal de tipo YOLOv5 la cual utiliza para el conteo de las plantas, y la red neuronal de tipo U-Net para segmentar las plantas y medir el espacio entre cada planta.

Para la detección temprana de plagas (Hadipour-Rokni et al., 2023) utiliza método modernos y no destructivos como son los sistemas de visión artificial y el aprendizaje profundo en un cultivo de cítricos. Utilizo imágenes de cítricos en 3 etapas, antes de la infestación, en el comienzo de la infestación de la fruta y ocho días después, con los resultados obtenidos se mostró que el método de red neuronal convolucional puede ser eficaz para controlar plagas en algún cultivo.

Se analizó seis modelos de redes neuronales artificiales para detectar el estado de madurez de arándanos silvestres, se clasificó de dos formas, bayas verdes, rojas y azules, y bayas inmaduras y bayas maduras. Los resultados obtenidos ayudarán a los productores a tomar decisiones y por consecuencia aumentar las ganancias al comprender mejor las características de la maduración.(Maceachern et al., 2023)

## **II. MARCO TEÓRICO**

### **2.1 Taxonomía**

Reino: Plantae

División: Magnoliophyta

Clase: Liliopsida (monocotiledóneas)

Orden: Asparagales

Familia: Alliaceae

Tribu: Alliae

Género: Allium

Especie: Allium cepa L.

### **2.2 Morfología de la cebolla**

La cebolla se describe como una planta herbácea, la parte comercial es el bulbo tunicado, que difieren en forma, color, tamaño y conservación después de la cosecha.(Aníbal et al., 2019.)

#### **2.2.1 Hojas**

Las hojas crecen opuestas una de otra y alternas, estas están cubiertas de una capa cerosa que protege de las enfermedades foliares. Una planta que crece en óptimas condiciones puede producir entre 13 a 18 hojas.

#### **2.2.2 Sistema radicular**

Esta es de tipo fasciculado, formado por raíces que se originan en el tallo cónico durante el desarrollo vegetativo. Cuando la planta se encuentra madura, las raíces se concentran a una profundidad de 25 cm y lateralmente a 15 cm.

#### **2.2.3 Tallo**

se encuentra en la base del bulbo, de este brotan las yemas, las hojas y las raíces.



### 2.2.4 Bulbo

Se puede tener diversas formas (cónica, globosa, chata, deprimida) y colores (blanco, amarillo, castaño, cobrizo, rojo, violáceo, púrpura) según sea la variedad. Este es el órgano en donde se acumulan las sustancias nutritivas de reserva. El bulbo se forma a partir del engrosamiento de las hojas basales (catáfilas).

### 2.2.5 Flores

Son de coloración blancas o lilas, la apertura floral es irregular y puede prolongarse por más de dos semanas.

### 2.2.6 Fruto

Es una capsula trilobular con una o dos semillas.

### 2.2.7 Semilla

La semilla es pequeña y de color negro, esta se encuentra lisa mientras crece y se hace rugosa al madurar, esto debido a la pérdida de agua.




Figura 1 Partes externas de la planta de cebolla. Fuente: obtenido de <https://es.slideshare.net/slideshow/gua-tecnica-del-cultivo-de-la-cebolla/236382660>

### 2.3 Fenología de la cebolla

La fenología de la cebolla se compone de dos fases, la fase vegetativa y la fase reproductiva.

En la fase vegetativa abarca 4 etapas, lo que es la etapa de almácigo, el trasplante, desarrollo y crecimiento de hojas y desarrollo y crecimiento del bulbo.

En la fase reproductiva, son dos etapas, la etapa de brotación del tallo de la floración y la etapa de plena floración.




Figura 2 Fenología de la cebolla

### 2.4 Fotoperiodo y clima

Según (Everardo Zamora, 2016) la cebolla necesita de temperatura fresca durante la etapa de plántula, y durante la formación del bulbo se requiere una temperatura moderadamente alta. Al inicio del ciclo de las plantas forman las hojas y raíces, y al final desarrollan los bulbos. Para formar y desarrollar el bulbo se requiere de una temperatura entre los 12 y 24 °C.

Se sabe que el crecimiento de los bulbos depende de la temperatura, ya que, si se tiene una temperatura alta, el crecimiento del bulbo será más rápido en relación con los que crecen con temperatura baja, pues la temperatura retarda el crecimiento.

## 2.5 Procesamiento digital de imágenes

El procesamiento digital de imágenes según (Szeliski, 2022a) es una disciplina que se centra en el análisis y el manejo de imágenes digitales utilizando técnicas matemáticas y algoritmos informáticos. Algunas de las operaciones comunes en el procesamiento de imágenes incluyen: 1. Mejora de la imagen, 2. Filtrado (eliminar el ruido o resaltar características específicas), 3. Segmentación (identificar objetos dentro de la imagen), 4. Reconocimiento de patrones (identificar características específicas dentro de una imagen).

### 2.5.1 Imagen digital

En los medios digitales, una imagen consta de una serie de píxeles. Estos píxeles están dispuestos en filas y columnas. Según (Gonzalez & Woods, 2018), una imagen digital se representa como una matriz bidimensional, donde cada elemento de la matriz corresponde a un píxel de la imagen. Esta matriz tiene dimensiones  $\mathbf{M} \times \mathbf{N}$ , donde  $\mathbf{M}$  es la altura de la imagen y  $\mathbf{N}$  es el ancho de la imagen. Cada valor en la matriz,  $f(x, y)$ , representa la intensidad de luz o color en el punto correspondiente de la imagen. Las coordenadas  $x$  y  $y$  indican la posición espacial del píxel en la imagen. (Figura 3)


$$f(x, y) = \begin{bmatrix} f(1, 1) & f(1, 2) & \dots & f(1, N) \\ f(2, 1) & f(2, 2) & \dots & f(2, N) \\ \vdots & \vdots & & \vdots \\ f(N, 1) & f(N, 2) & \dots & f(N, N) \end{bmatrix}$$

Figura 3 Representación de una matriz

### 2.5.2 Píxel

Un píxel es el elemento más diminuto dentro de una imagen digital, cada píxel posee un número que representa su color o su brillo. En una fotografía en escala de grises, este número representa la cantidad de luz emitida, mientras que, en una foto a color, cada píxel puede contener información en tres canales de color diferentes: rojo, verde y azul (RGB), los cuales se mezclan para crear el color definido. Según (Russ & Neal, 2018), la calidad y la resolución de la imagen son determinadas por el comportamiento de los píxeles. Un mayor

número de píxeles permite a un sistema de visión artificial captar más detalles, lo que aumenta la precisión en la detección y análisis de objetos y patrones.



*Figura 4 Representación de una imagen con píxeles*

## **2.6 Visión por computadora**

La visión por computadora es una rama de la inteligencia artificial, la cual busca que las máquinas interpreten el mundo visual, imitando las capacidades humanas. Utiliza técnicas de procesamiento digital de imágenes como la transformación de imágenes en donde se realiza una conversión a escala de grises, normalización para segmentar regiones de interés y aprendizaje automático para analizar, comprender e interpretar imágenes y videos.

Al inicio, la visión por computadora se enfocaba en problemas básicos, como la detección de bordes y la segmentación de imágenes. Pese a los avances en el aprendizaje profundo, especialmente con las redes neuronales convolucionales (CNN), ha permitido avances en áreas como el reconocimiento de imágenes, la detección de objetos y el análisis de complejas escenas.(Szeliski, 2022b)

## **2.7 Máquinas de aprendizaje**

Las máquinas de aprendizaje son modelos y algoritmos que se utilizan en el campo del aprendizaje automático (machine learning), la cual es una rama de la inteligencia artificial. Estos sistemas han sido creados con el propósito de adquirir conocimiento en lugar de seguir instrucciones

predeterminadas, estas construyen patrones o modelos a partir de datos, lo que les permite hacer predicciones o tomar decisiones.

Existen diferentes categorías de aprendizaje automático: 1. Aprendizaje supervisado, 2. Aprendizaje no supervisado. 3. Aprendizaje semisupervisado. (Xu & Saleh, 2021a)

### **2.7.1 Aprendizaje supervisado**

En el aprendizaje supervisado se entrena con un conjunto de datos etiquetados, donde cada entrada tiene una salida o etiqueta conocida. El objetivo es que aprenda a predecir estas salidas para nuevas entradas. Existen dos subcategorías principales, la regresión y la clasificación. La regresión implica la variable cuantitativa y la clasificación la variable cualitativa. (Xu & Saleh, 2021b)

### **2.7.2 Aprendizaje no supervisado**

El aprendizaje no supervisado consiste en examinar conjuntos de datos con solo variables de entrada y ninguna etiqueta o respuesta correspondiente. Su objetivo es explorar el espacio de características y encontrar patrones en el conjunto de datos. Existen dos subcategorías o tareas, agrupamiento y detección de anomalías. (Xu & Saleh, 2021b)

### **2.7.3 Aprendizaje semisupervisado**

El aprendizaje semisupervisado se utiliza datos con etiquetas, así como datos sin etiquetar, en donde se utiliza el conjunto de datos etiquetados para estimar y el conjunto de datos no etiquetados pueden ayudar a mejorar el rendimiento del modelo y proporcionar predicciones más precisas. (Xu & Saleh, 2021b)

## **2.8 Redes neuronales**

Las redes neuronales es un modelo computacional, el cual está inspirado en el funcionamiento del cerebro humano, diseñado para procesar información de manera similar a como lo hacen las neuronas en el cerebro. Estas redes neuronales son fundamentales para diversas aplicaciones de inteligencia artificial y el aprendizaje profundo. Los componentes clave de una red neuronal son las neuronas, pesos y la función de activación.

- Neuronas. – son elementos que reciben entradas y generan salidas después de aplicar una función de activación.
- Pesos. – establecen la importancia de las conexiones entre las neuronas y durante el proceso de aprendizaje se ajustan para minimizar el error en las predicciones.

- Función de activación. – permite que la red neuronal sea capaz de aprender patrones complejos y no lineales.

Una red neuronal está compuesta por tres tipos de capas: 1. Capa de entrada (recibe los datos iniciales), 2. Capas ocultas (realizan el procesamiento de datos utilizando un conjunto de pesos y funciones de activación), y 3. Capa de salida (se obtiene la predicción o la clasificación final).

### 2.8.1 funciones de activación

Para poder proseguir a otra neurona, en la salida debe de existir un filtro o una función limitadora la cual modifica el valor de la salida o asigna un límite. Esta función se le conoce como función de activación, esta transmite la información generada por la combinación de las entradas y los pesos. Existen diversos tipos de funciones de activación.

#### Función Lineal

También conocida como identidad, permite que la entrada sea igual a la salida, por lo que si se agrega a una red neuronal de varias capas se dice que es una regresión lineal, por lo que se va a generar un valor único. Una función lineal es adecuada en la capa de salida, cuando la salida sea un valor continuo.

$$y = mx + b$$




Figura 5 Representación gráfica de función lineal

## Función Umbral

Se le conoce también como escalón, esta función indica que, si la  $x$  es menor que 0 la salida va a ser 0, pero cuando es mayor igual a cero su salida será igual a 1. Esta función se utiliza cuando se quiere clasificar o se tiene salidas binarias.

$$f(x) = \begin{cases} 1, & \text{si } x \geq 0 \\ 0, & \text{si } x < 0 \end{cases}$$




Figura 6 Representación gráfica de función Umbral

## Función Sigmoide

Esta función también se le conoce como función logística, sus rangos de valores de salida esta entre 0 y 1, por lo que su salida se interpreta como una probabilidad. Si los valores de entrada son menores a 0, es decir  $x < 0$  la función será igual a 0, si se evalúa en 0 la función dará 0.5 y en valores mayores a 0 su valor es aproximadamente a 1.

La función sigmoide se utiliza principalmente cuando se necesita una clasificación binaria o cuando se involucra predicciones de probabilidades.

$$f(x) = \frac{1}{1 + e^{-x}}$$




Figura 7 Representación gráfica de función sigmoide




## **Función tangente hiperbólica**

Esta función trabaja con un rango de valores de salida entre -1 y 1. Lo cual significa que los valores negativos pueden ser activados de forma diferente a los positivos, esto ayuda a que el entrenamiento se facilite.

Es una opción común para las capas ocultas en las redes neuronales profundas ya que realiza la propagación hacia atrás (retropropagación)

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$



*Figura 8 Representación gráfica de función tangente hiperbólica*

## Función ReLu

La función ReLu (Rectified Linear Unit) que quiere decir unidad lineal rectificada, es una de las funciones más utilizadas en las redes neuronales profundas, debido a su simplicidad y eficacia, en esta función cuando la entrada es negativa, la salida será igual a 0, y cuando la entrada es positiva la salida queda igual.

ReLu es especialmente eficaz para las redes neuronales profundas o convolucionales, ya que ayuda a que no se sature de valores.

$$f(x) = \max(0, x)$$




Figura 9 Representación gráfica de función ReLu

## Función Softmax

La función Softmax se usa cuando se tiene modelos de clasificación, se agrega principalmente en la capa de salida de las redes neuronales, esto para problemas de clasificación multiclase. Esta función realiza una conversión de un vector de entrada en un vector de probabilidades, en donde la suma de todas las probabilidades es 1.

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}$$




Figura 10 Representación gráfica de función Softmax

### III. METODOLOGÍA

Para realizar la presente investigación se deberán realizar técnicas y actividades que ayuden a cumplir el objetivo, los cuales se describe a continuación:

#### 3.1 Área de estudio

Se utilizó como área de estudio un campo de cultivo, de forma cuadrada con dimensiones de 70 mts. x 70 mts. teniendo un área total de 4,900 mts., este campo se destinó para el sembrado de cebolla, en donde se contaba con 19 camas o surcos para trabajar, cada plántula fue plantada a una distancia de aproximadamente de 10 cm entre ellas, teniendo un aproximado total de 13,300 plantas. el campo de cultivo está localizado en el Instituto Tecnológico del Valle del Guadiana, Km. 22.5 carretera Durango-México, Villa Montemorelos, Dgo.

Para que una plántula se considere lista para su trasplante, esta debe de contar con un número de hojas no inferior a cuatro, una altura de aproximadamente 15 cm y un diámetro en la zona base del cuello de 0.8 cm aproximadamente. (Valle et al., 2010).



*Figura 11 plántulas de cebolla trasplantadas*

### 3.2 Diseño estadístico

Para trabajar con el cultivo primero se realizó la eliminación de las orillas para reducir el efecto orilla, este recorte consiste en descartar las primeras camas o surcos del cultivo ya que estas suelen estar propensas a daños externos, como el paso de maquinaria agrícola, así como el personal o animales que se encuentren por el cultivo. Se eliminó un total de 7 camas, 3 del lado izquierdo y 4 del lado derecho y de largo se quitaron un aproximado de 25m total, 12.5 metros de la parte superior y 12.5 metros de la parte inferior, esto para equilibrar el tamaño del área a trabajar. (figura 12)

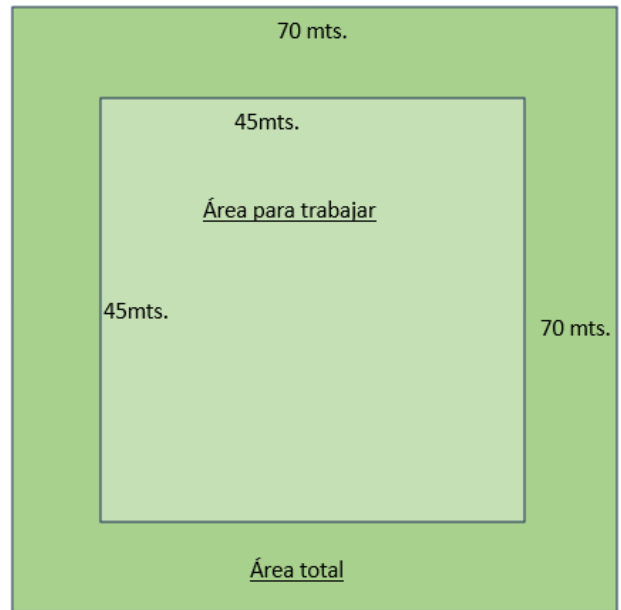


Figura 12 Representación de la eliminación de orillas.

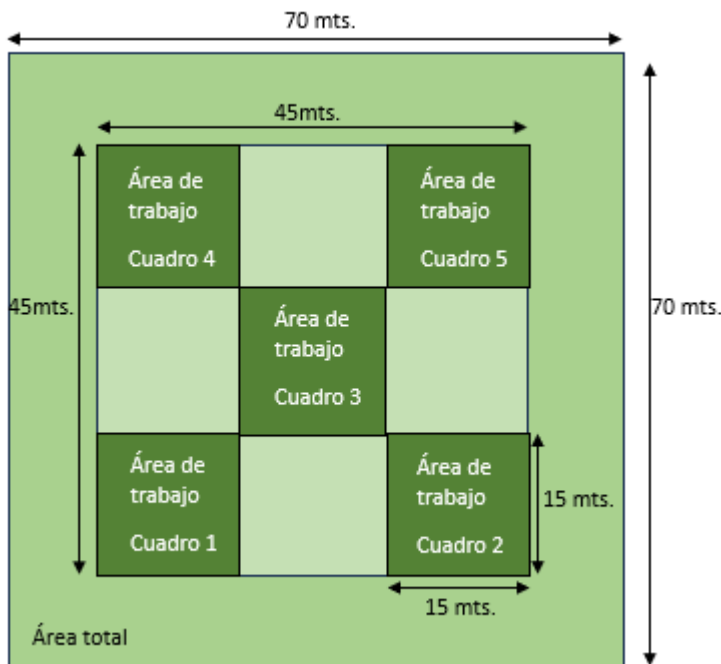


Figura 13 División del área de trabajo

Una vez eliminadas las orillas, el resto del campo del cultivo conforma el marco muestral, ya que de esta área se va a seleccionar la muestra de plantas de cebolla a las que se les va a dar seguimiento cronológico objetivos de este estudio. Para fines del diseño estadístico, el área de cultivo restante fue dividido en una cuadrícula de 3x3 obteniendo 9 cuadros en total, de los cuales fueron seleccionados los cuadros de las esquinas inferiores y superiores y el cuadro central, esto para tener muestras de diversos puntos del cultivo, ya que es diferente el crecimiento

en todo el cultivo. (figura 13)

### 3.3 Selección de la muestra

En cada cuadro de área de estudio hay 4 camas para trabajar, y de cada cama se seleccionaron 10 plantas que estuvieran colocadas de manera seguida para facilitar su localización e identificación, ya que estas mismas plantas van a ser el objeto de estudio durante todo el periodo del ciclo de crecimiento de la planta de cebolla (figura 14). La selección de las plantas se hizo de forma al azar, utilizando una pelota, la cual fue lanzada hacia cada cuadro seleccionado, y en la planta donde cayó la pelota fue seleccionada junto con las 10 plantas siguientes. En total se seleccionaron 200 plantas.




Figura 14 Selección de muestra en cultivo

### 3.4 Uso de referencia

Para ayudar a la medición de la imagen en lo digital se requirió poner una referencia a un costado de la planta a trabajar, ya que la referencia se sabía cuánto media de circunferencia y esto nos ayudaría a comparar las medidas en lo digital. (Figura 15)



Figura 15 Colocación de referencia

### 3.5 Captura de imágenes

Para la captura de imagen se utilizó una cámara fotográfica digital con una resolución de 18 mega píxeles. Además, con una lente EF-S 18-55 mm, y se colocó en la menor amplificación de la lente. La toma de fotografías se empezó a realizar cuando la plántula tenía 31 días de estar sembrada, se realizó durante los diez sábados consecutivos en el periodo de noviembre 2022 a enero 2023, obteniendo 200 imágenes por día, totalizando 2200 fotografías. (Tabla 1).

La fotografía se realizaba enfrente de la planta a trabajar. Para que la toma de fotografías fuera más exacta se realizó dos diseños, uno consiste en una base de madera con dos bastones en los costados esto con la finalidad de brindar un mejor soporte, y en la base se le colocó una regla de 30 cm, la cual asegura que sea tomada a la misma distancia (figura 16). El segundo diseño es un bastón que tiene en el extremo inferior colocado una regla de 30 cm y a 15 cm de altura se colocó un soporte para la cámara (figura 17). Se optó por utilizar el segundo diseño ya que era más exacto y fácil de maniobrar en el campo de trabajo.

| Fecha             | Cantidad de fotografías |
|-------------------|-------------------------|
| 12 noviembre 2022 | 200                     |
| 19 noviembre 2022 | 200                     |
| 26 noviembre 2022 | 200                     |
| 03 diciembre 2022 | 200                     |
| 10 diciembre 2022 | 200                     |
| 17 diciembre 2022 | 200                     |
| 24 diciembre 2022 | 200                     |
| 31 diciembre 2022 | 200                     |
| 07 enero 2023     | 200                     |
| 14 enero 2023     | 200                     |
| 21 enero 2023     | 200                     |
| Total             | 2200                    |

*Tabla 1 fechas de toma de fotografías*




Figura 16 primer diseño de soporte de cámara




Figura 17 segundo diseño de soporte de cámara



### 3.6 Medición del grosor de tallo

Durante el periodo de la toma de fotografías se realizó la medición del tallo de forma manual con ayuda de un vernier digital, este se colocaba en el tallo de la planta como se muestra en la **figura 18**, la medición nos permitirá tener información real sobre el crecimiento de la planta de cebolla, para posteriormente comparar los resultados digitales con los reales. La medición se realizó en el 20% de las plantas a trabajar, se escogieron la primera y la ultima de cada fila de plantas de cada cama, teniendo 40 medidas de plantas por cada día de toma de fotografías. (Tabla 2).



Figura 16 referencia de donde se colocaba el vernier digital

|          | 12-nov   |           | 19-nov   |           | 26-nov   |           | 03-dic   |           | 10-dic   |           | 17-dic   |           | 24-dic   |           | 31-dic   |           | 07-ene   |           | 14-ene   |           | 21-ene   |           |
|----------|----------|-----------|----------|-----------|----------|-----------|----------|-----------|----------|-----------|----------|-----------|----------|-----------|----------|-----------|----------|-----------|----------|-----------|----------|-----------|
| cuadro 1 | planta 1 | planta 10 | planta 1 | planta 10 | planta 1 | planta 10 | planta 1 | planta 10 | planta 1 | planta 10 | planta 1 | planta 10 | planta 1 | planta 10 | planta 1 | planta 10 | planta 1 | planta 10 | planta 1 | planta 10 | planta 1 | planta 10 |
| linea 1  | 5.8      | 5.3       | 6.2      | 6.5       | 7.6      | 7.3       | 8.6      | 7.5       | 9        | 8.2       | 10.1     | 9.5       | 12       | 10.6      | 12.5     | 11.6      | 13       | 12.1      | 13.5     | 13.2      | 14       | 13.6      |
| linea2   | 5.2      | 4.2       | 6.4      | 5.1       | 7.5      | 6.2       | 9.5      | 7.4       | 9.8      | 8.2       | 10.1     | 8.8       | 11.9     | 10.2      | 13.2     | 11.9      | 14       | 12.7      | 14.8     | 12.8      | 15.3     | 13.8      |
| linea3   | 4.7      | 4.2       | 4.8      | 5.5       | 4.9      | 6.4       | 6.1      | 7.1       | 6.9      | 7.4       | 7.9      | 8.5       | 8.7      | 8.6       | 8.8      | 9         | 9        | 10.2      | 9.8      | 11        | 10       | 12.2      |
| linea4   | 4.9      | 3.2       | 5.2      | 3.8       | 7.3      | 4.1       | 7.8      | 5.4       | 8.2      | 5.6       | 8.8      | 5.7       | 10.6     | 6.3       | 11       | 8.4       | 11.4     | 8.8       | 12.5     | 8.9       | 13.3     | 9.4       |
| cuadro 2 |          |           |          |           |          |           |          |           |          |           |          |           |          |           |          |           |          |           |          |           |          |           |
| linea 1  | 3.9      | 5.2       | 5        | 6.5       | 5.1      | 7.2       | 6.4      | 8         | 6.6      | 8.2       | 7.7      | 9.7       | 8.3      | 10.3      | 8.5      | 10.9      | 8.6      | 11.1      | 9.3      | 11.9      | 9.6      | 12.7      |
| linea2   | 6.4      | 4.3       | 6.8      | 4.7       | 7        | 6.2       | 7.1      | 6.7       | 7.4      | 6.8       | 7.6      | 7.7       | 7.9      | 7.7       | 7.9      | 8.6       | 9.2      | 8.9       | 9.2      | 9.2       | 9.5      | 9.7       |
| linea3   | 4.9      | 4.4       | 5.9      | 5.3       | 6.5      | 6.2       | 6.7      | 7.6       | 7.7      | 8.4       | 8        | 9.8       | 9.8      | 10.2      | 10.7     | 11.5      | 11.9     | 11.7      | 12.3     | 12.7      | 13.1     | 13.3      |
| linea4   | 3.7      | 2.3       | 3.9      | 4.6       | 4.6      | 5.4       | 4.9      | 6.2       | 5.4      | 6.3       | 6.4      | 7.1       | 7.1      | 7.4       | 7.6      | 8.7       | 8.9      | 9.4       | 9.3      | 9.9       | 9.6      | 10.2      |
| cuadro 3 |          |           |          |           |          |           |          |           |          |           |          |           |          |           |          |           |          |           |          |           |          |           |
| linea 1  | 4        | 4.9       | 5.2      | 5.1       | 5.6      | 6         | 6.7      | 6.3       | 7.4      | 6.6       | 7.7      | 7.3       | 8.6      | 8.8       | 9.5      | 9.7       | 10       | 10.4      | 11       | 11.7      | 11.8     | 12.5      |
| linea2   | 4.6      | 6.8       | 5.1      | 7.1       | 5.8      | 7.5       | 6.3      | 8.8       | 6.5      | 9.3       | 6.6      | 9.7       | 8.5      | 10.3      | 9.2      | 11.1      | 9.9      | 11.4      | 10.3     | 12.2      | 11.9     | 12.9      |
| linea3   | 4.8      | 3.4       | 5.2      | 4.4       | 5.3      | 5.2       | 6.1      | 6.4       | 7.6      | 6.4       | 8        | 7.4       | 8.7      | 7.6       | 9.6      | 7.7       | 10.3     | 8.3       | 11.4     | 9.7       | 11.7     | 10.4      |
| linea4   | 5.1      | 4.8       | 6        | 5.2       | 6.3      | 6.4       | 8        | 8.2       | 9.5      | 9.1       | 9.8      | 9.1       | 10.2     | 10.5      | 11       | 10.9      | 12       | 11.9      | 12.6     | 12.8      | 13       | 13.5      |
| cuadro 4 |          |           |          |           |          |           |          |           |          |           |          |           |          |           |          |           |          |           |          |           |          |           |
| linea 1  | 4.3      | 3.2       | 4.7      | 3.3       | 5.5      | 3.8       | 6.5      | 4.7       | 7.3      | 5.2       | 8.9      | 5.5       | 9.3      | 5.6       | 10.6     | 5.8       | 11.3     | 6.5       | 11.5     | 7.7       | 11.7     | 7.9       |
| linea2   | 3.4      | 3.8       | 3.5      | 4.3       | 4.1      | 4.6       | 4.7      | 4.8       | 5.3      | 5.1       | 7        | 7.2       | 8.5      | 8.1       | 9.2      | 9.3       | 10.3     | 10        | 11.3     | 10.7      | 12.8     | 11.9      |
| linea3   | 3.2      | 3.3       | 4        | 3.9       | 4.2      | 4.2       | 5.6      | 4.9       | 5.8      | 4.9       | 6.4      | 6.1       | 7.1      | 6.3       | 7.7      | 7         | 8        | 7.5       | 8.7      | 7.8       | 9.3      | 8.3       |
| linea4   | 6.3      | 4.8       | 6.5      | 5.3       | 6.8      | 6.3       | 7        | 7.7       | 7.9      | 8         | 8.3      | 9.9       | 8.7      | 10.1      | 9.6      | 11.3      | 10.8     | 11.8      | 11.1     | 12.2      | 11.6     | 12.5      |
| cuadro 5 |          |           |          |           |          |           |          |           |          |           |          |           |          |           |          |           |          |           |          |           |          |           |
| linea 1  | 3.3      | 3.3       | 3.7      | 4.1       | 3.8      | 4.4       | 4.2      | 5.1       | 4.2      | 5.8       | 5.1      | 6.1       | 5.6      | 6.9       | 6        | 7.2       | 6        | 7.7       | 6.9      | 8.4       | 7.1      | 9.2       |
| linea2   | 2.6      | 3         | 3        | 3.8       | 3.4      | 4.1       | 3.7      | 4.5       | 3.7      | 5.1       | 5.5      | 5.9       | 5.6      | 6.4       | 5.7      | 7.1       | 6.2      | 8.2       | 6.9      | 8.6       | 7.8      | 9         |
| linea3   | 3.1      | 3.2       | 3.5      | 3.2       | 3.5      | 3.4       | 4.6      | 5.4       | 5.3      | 5.8       | 6.1      | 6.3       | 6.3      | 6.8       | 6.6      | 7.1       | 6.9      | 7.8       | 7.5      | 8.7       | 8        | 9         |
| linea4   | 2.9      | 2.8       | 3.1      | 3         | 3.2      | 3.4       | 4.1      | 4.4       | 4.2      | 4.8       | 5.1      | 4.8       | 5.4      | 5.3       | 5.8      | 5.7       | 6.1      | 6         | 6.5      | 6.9       | 6.7      | 6.9       |

Tabla 2 medidas obtenidas

### 3.7 Elaboración de máscaras de las imágenes

Para el entrenamiento de la red neuronal se necesita generar el conjunto de máscaras para cada imagen, este proceso consiste en la binarización de las imágenes, separando el objeto de interés del resto de objetos (fondo de la imagen), esto conforman el conjunto de imágenes segmentadas que van a servir para el entrenamiento de la U-Net, por eso, estas máscaras resaltan los elementos de interés para facilitar su identificación.

Para la generación de las máscaras de las imágenes, se utilizó la herramienta de binarización de Robloflow en su modalidad de uso libre (Robloflow: Computer Vision Tools for Developer, 2019), **Figura 19**, cuyo principal objetivo es proporcionar herramientas para facilitar el proceso de la elaboración de etiquetas (imágenes) para el entrenamiento de modelos de redes neuronales tanto convolucionales como secuenciales. Para la segmentación de las imágenes, se definieron diferentes clases, en donde cada clase distingue un objeto de interés dentro de cada imagen, en esta investigación, se definieron las clases 1. “Tallo”, 2. “Hoja” y 3. “Referencia”, que nos va a auxiliar a la medición del tallo, y finalmente la clase 4. “Bulbo” que en algunas fotografías se podía observar. Todos estos objetos son los que necesitamos detectar en cada imagen. Para delimitar cada clase se utilizó la herramienta llamada “*polygon tool*”, esta nos ayudó a que fuera más exacta la selección de los objetos. Se trabajaron con todas las fotografías que anteriormente se habían obtenido.

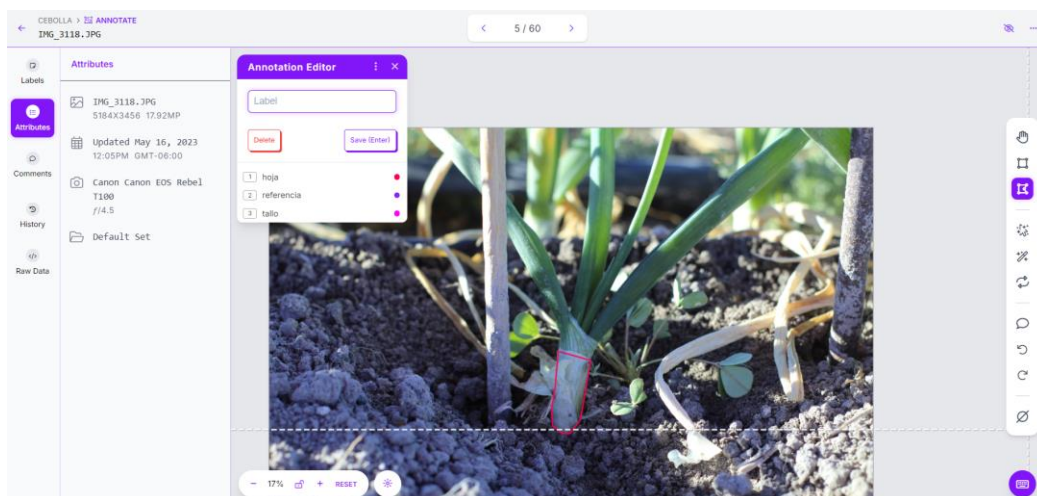


Figura 17 Página Roboflow, ejemplo de segmentación de la imagen

### 3.8 Selección de algoritmo de clasificación

Para segmentar las imágenes, se seleccionó una red neuronal convolucional en configuración U-Net (Ronneberger et al., 2015), ya que es una red neuronal que ofrece un buen nivel de desempeño en el segmentado de los diferentes elementos de interés dentro de cada imagen, proporcionando una mejor segmentación en comparación con los modelos convencionales.

De acuerdo con (Ghaznavi et al., 2024) la arquitectura de U-Net se construye y propone para la segmentación semántica basada en una arquitectura de red neuronal convolucional (CNN), que consta de una topología de red convolucional codificador-decodificador. En cada nivel, los codificadores y decodificadores entrelazados están conectados entre sí mediante puentes para combinar funciones derivadas de la parte decodificadora. La representación de características resultante de la parte del decodificador es útil para la localización, mientras que las características de la parte del codificador son efectivas para una segmentación precisa.

En la **Figura 20** se muestra la arquitectura sugerida para la implementación de la arquitectura U-Net para este estudio. Para la codificación de la red neuronal U-Net se comenzó con la entrada de la imagen la cual se trabajó a color con un tamaño de 640 pixeles por 640 px, y con 3 dimensiones (RGB), después se realiza la parte de extracción de características, teniendo cuatro etapas conformadas por dos convoluciones y un “*Max pooling*”, en cada etapa varía el número de filtros de convolución comenzando con 64, la segunda etapa con 128, la tercera con 256, la cuarta con 512, la configuración de cada capa es la misma, con un tamaño de kernel de 3x3, un padding que se mantenga igual y con el tipo de activación Relu. La configuración del “*Max pooling*” se conforma con el tamaño del filtro el cual es de 2x2 y con saltos de 2x2. En la etapa cinco el número de filtros de convolución es de 1024 con la misma configuración, en esta etapa solo se realiza dos convoluciones sin realizar el “*Max pooling*”.

Luego se realiza la parte de expansión, en las etapas 6 a la 9, se codifica la operación de convolución ascendente en donde el número de filtros se comienza con 512 en la etapa sexta, en la etapa séptima con 254, en la octava 128 y en la novena con 64, se concatena con la etapa paralela de las etapas 6 a la 9 y se realizan dos convoluciones con la misma configuración de tamaño del kernel, padding y el tipo de activación. Concluyendo con una salida en donde se hace una convolución, con un tamaño de filtro de 4, ya que se están trabajando con 4 clases de objetos a identificar, con el mismo tamaño de kernel y padding que se trabajó y el tipo de activación cambiaria por el softmax.




Figura 18 Arquitectura de U-Net parte A representa la sección del codificador y parte B representa la sección del decodificador.

Fuente: Obtenida de (Ghaznavi et al., 2024)

### 3.9 Entrenamiento de la red neuronal

A partir de la implementación de la red neuronal, se utilizan cada una de las imágenes con su respectiva máscara para el entrenamiento de la U-Net, para este paso se utilizaron 200 imágenes las cuales fueron alimentadas a la red de segmentación para su entrenamiento.

Se realizaron tres diferentes entrenamientos, uno de 10 épocas de entrenamiento, el segundo con 20 épocas y el tercero con 50 épocas. Para el entrenamiento de los pesos de la U-Net, se utilizó el algoritmo ADAM el cual es un algoritmo de optimización más utilizado en el entrenamiento de redes neuronales profundas debido a su capacidad para ajustarse y manejar datos con características variadas, lo que lo convierte en una excelente opción para una amplia gama de aplicaciones de redes

neuronales profundas como lo es el reconocimiento de imágenes. (Kingma & Ba, 2014) y se alimentaron las imágenes en lotes de 32 imágenes cada uno.

### 3.10 Validación del algoritmo de clasificación

Después del entrenamiento de la red neuronal se realizó la validación de los datos que se obtuvieron. El cual consistió en realizar un código para utilizar el modelo que anteriormente se adquirió con el entrenamiento de la red neuronal, también se utilizan nuevas imágenes para ver si realmente se entrenó la red neuronal y no se sobreentrenó. Se utiliza la función de TensorFlow “*model.predict ()*” para realizar predicciones sobre datos nuevos o no vistos, una vez que el modelo ha sido entrenado. Este método toma como entrada uno o varios ejemplos de datos y devuelve una predicción de salida basada en el modelo entrenado. Se utiliza para predecir la clase o el valor para nuevos datos.



Figura 19 Resultado de validación del entrenamiento de la red neuronal

## VI. RESULTADOS

### 4.1 Relación de crecimiento

Para obtener una relación de crecimiento se empleó la regresión lineal, en donde se registraron los días transcurridos, así como las medidas de la planta, obteniendo la siguiente tabla.

Se seleccionó una planta de cada cuadro que se tenía para trabajar para realizar las gráficas, las cuales son:

1.- Características: Planta: 1; Línea: 1; Cuadro: 1.

| Fechas | Días transcurridos | Medidas |
|--------|--------------------|---------|
| 12-nov | 31                 | 5.8 mm  |
| 19-nov | 38                 | 6.2 mm  |
| 26-nov | 45                 | 7.6 mm  |
| 03-dic | 52                 | 8.6 mm  |
| 10-dic | 59                 | 9 mm    |
| 17-dic | 66                 | 10.1 mm |
| 24-dic | 73                 | 12 mm   |
| 31-dic | 80                 | 12.5 mm |
| 07-ene | 87                 | 13 mm   |
| 14-ene | 94                 | 13.5 mm |
| 21-ene | 101                | 14 mm   |

Tabla 3 días transcurridos y medidas de planta 1 línea 1 cuadro 1




Figura 20 grafica de regresión lineal de medidas

2.- Características: Planta: 10; Línea: 2; Cuadro: 2.

| Fechas | Días transcurridos | Medidas |
|--------|--------------------|---------|
| 12-nov | 31                 | 4.3 mm  |
| 19-nov | 38                 | 4.7 mm  |
| 26-nov | 45                 | 6.2 mm  |
| 03-dic | 52                 | 6.7 mm  |
| 10-dic | 59                 | 6.8 mm  |
| 17-dic | 66                 | 7.7 mm  |
| 24-dic | 73                 | 7.7 mm  |
| 31-dic | 80                 | 8.6 mm  |
| 07-ene | 87                 | 8.9 mm  |
| 14-ene | 94                 | 9.2 mm  |
| 21-ene | 101                | 9.7 mm  |

Tabla 4 días transcurridos y medidas de planta 10 línea 2 cuadro 2

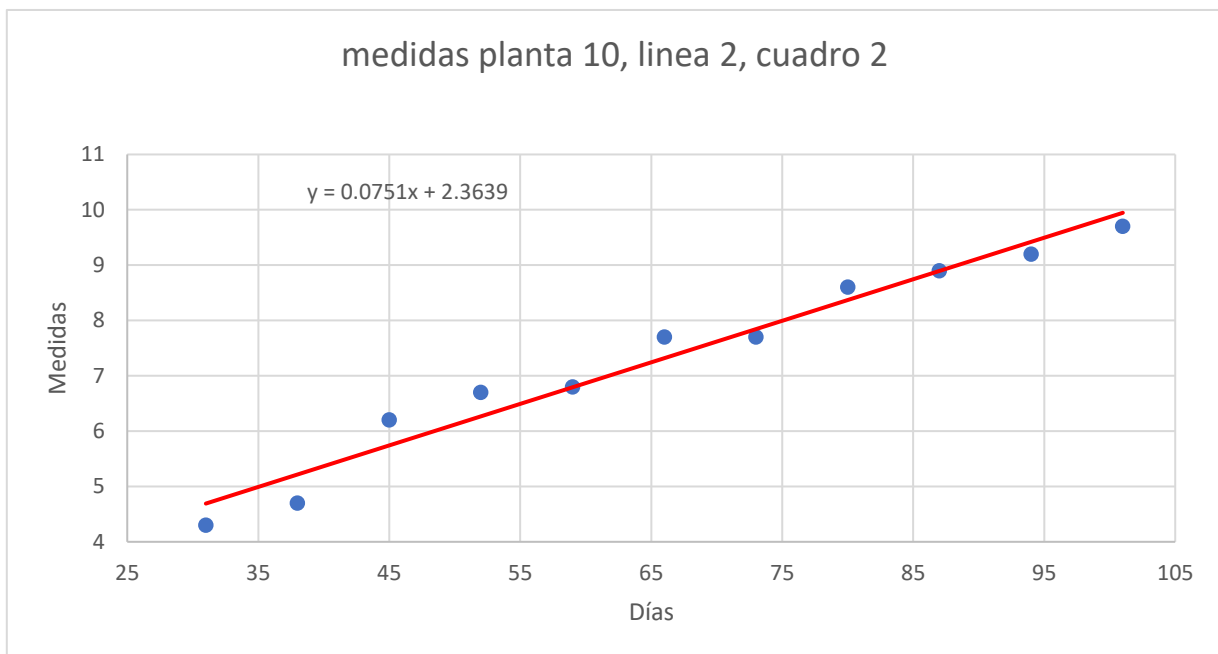


Figura 21 grafica de regresión lineal de medidas

3.- Características: Planta: 1; Línea: 3; Cuadro: 3.

| Fechas | Días transcurridos | Medidas |
|--------|--------------------|---------|
| 12-nov | 31                 | 4.8 mm  |
| 19-nov | 38                 | 5.2 mm  |
| 26-nov | 45                 | 5.3 mm  |
| 03-dic | 52                 | 6.1 mm  |
| 10-dic | 59                 | 7.6 mm  |
| 17-dic | 66                 | 8 mm    |
| 24-dic | 73                 | 8.7 mm  |
| 31-dic | 80                 | 9.6 mm  |
| 07-ene | 87                 | 10.3 mm |
| 14-ene | 94                 | 11.4 mm |
| 21-ene | 101                | 11.7 mm |

Tabla 5 días transcurridos y medidas de planta 1 línea 3 cuadro 3




Figura 22 grafica de regresión lineal de medidas



4.- Características: Planta: 10; Línea: 4; Cuadro: 4.

| Fechas | Días transcurridos | Medidas |
|--------|--------------------|---------|
| 12-nov | 31                 | 4.8 mm  |
| 19-nov | 38                 | 5.3 mm  |
| 26-nov | 45                 | 6.3 mm  |
| 03-dic | 52                 | 7.7 mm  |
| 10-dic | 59                 | 8 mm    |
| 17-dic | 66                 | 9.9 mm  |
| 24-dic | 73                 | 10.1 mm |
| 31-dic | 80                 | 11.3 mm |
| 07-ene | 87                 | 11.8 mm |
| 14-ene | 94                 | 12.2 mm |
| 21-ene | 101                | 12.5 mm |

Tabla 6 días transcurridos y medidas de planta 10 línea 4 cuadro 4




Figura 23 grafica de regresión lineal de medidas

5.- Características: Planta: 1; Línea: 3; Cuadro: 5.

| Fechas | Días transcurridos | Medida planta 1 línea 3 cuadro 5 |
|--------|--------------------|----------------------------------|
| 12-nov | 31                 | 3.1 mm                           |
| 19-nov | 38                 | 3.5 mm                           |
| 26-nov | 45                 | 3.5 mm                           |
| 03-dic | 52                 | 4.6 mm                           |
| 10-dic | 59                 | 5.3 mm                           |
| 17-dic | 66                 | 6.1 mm                           |
| 24-dic | 73                 | 6.3 mm                           |
| 31-dic | 80                 | 6.6 mm                           |
| 07-ene | 87                 | 6.9 mm                           |
| 14-ene | 94                 | 7.5 mm                           |
| 21-ene | 101                | 8 mm                             |

Tabla 7 días transcurridos y medidas planta 1 línea 3 cuadro 5




Figura 24 grafica de regresión lineal de medidas

#### 4.2 Relación entre bulbo y tallo

Se seleccionaron 60 plantas al azar, las cuales habían sido cosechadas dos días antes de escoger, luego de seleccionarlas se midieron el tallo y el bulbo de cada planta, obteniendo los siguientes datos. (figura 25).

Estos datos nos ayudarán para poner observar si existe relación entre el grosor del tallo con el tamaño del bulbo de la cebolla, para encontrar dicha relación se utilizó la regresión lineal.

| Tallo (mm) | Bulbo (mm) | Tallo (mm) | Bulbo (mm) | Tallo (mm) | Bulbo (mm) | Tallo (mm) | Bulbo (mm) | Tallo (mm) | Bulbo (mm) | Tallo (mm) | Bulbo (mm) |
|------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|
| 6.8        | 13.2       | 5.5        | 13.5       | 6.4        | 12.5       | 6          | 12.1       | 5.1        | 9.7        | 7          | 14.4       |
| 5.7        | 12.9       | 6.1        | 13.3       | 4          | 19         | 4.2        | 7          | 8          | 16.5       | 8.5        | 13.9       |
| 7          | 10.9       | 6.3        | 11.7       | 5.6        | 14.7       | 4.5        | 10.9       | 8.8        | 10.2       | 6          | 10         |
| 4.9        | 10.6       | 8.2        | 14.5       | 5.5        | 16.2       | 6.5        | 13.9       | 6.8        | 9.6        | 6.9        | 10.1       |
| 8          | 14.1       | 5          | 9          | 6.1        | 12.5       | 6.7        | 11.9       | 5.5        | 10.4       | 7.3        | 11.8       |
| 7.1        | 13.5       | 8.1        | 13.7       | 6.5        | 12.1       | 7.8        | 18         | 7          | 14         | 7.1        | 12.7       |
| 7          | 12.2       | 6.1        | 9.5        | 7          | 17.3       | 5.5        | 6.5        | 8.3        | 14         | 5          | 11.5       |
| 5.5        | 10.1       | 5.7        | 10         | 8          | 21         | 6.5        | 20.1       | 6          | 14.6       | 7          | 12         |
| 7          | 12         | 6.6        | 14.2       | 5.4        | 8.5        | 7.1        | 17.6       | 6.1        | 13.8       | 7          | 9          |
| 6.5        | 11.2       | 7          | 12.6       | 5.5        | 13         | 7.2        | 14.5       | 7.1        | 10.7       | 6.2        | 11.7       |

Figura 25 medidas de tallo y bulbo

Como se muestra en la gráfica de regresión lineal, se puede observar que hay una dispersión de datos, lo que nos indica que no existe mucha relación entre las variables ya que solo el 8.35% de la variabilidad en el tamaño del bulbo está siendo explicada por el grosor del tallo.

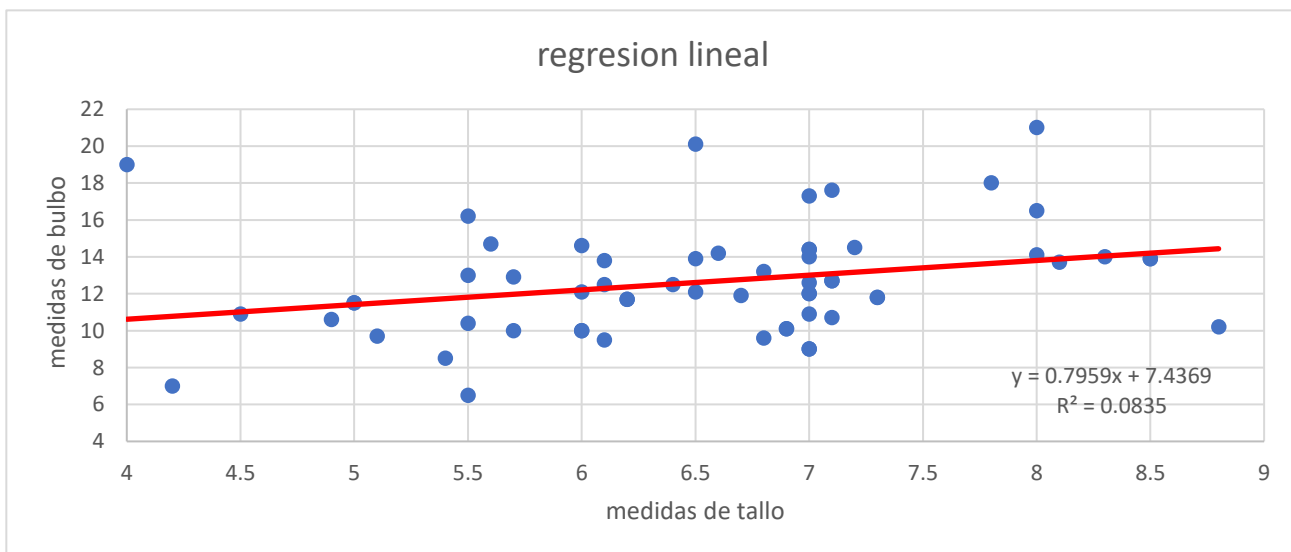


Figura 26 grafica de regresión lineal medidas de tallo y bulbo

### 4.3 Segmentación de imágenes

Luego del entrenamiento de la red neuronal, la validación y la comprobación de las imágenes segmentadas en cuatro categorías (“tallo”, “bulbo”, referencia”, “hojas”), se puede observar que el resultado es un objeto bien delimitado. Se muestran algunos ejemplos de las imágenes con las que se trabajaron con su respectiva máscara, así como la división de ella mostrando cada uno de los elementos con los que se trabajaron.



Figura 27 Imagen original




Figura 28 imagen segmentada, con su división de cada elemento.



Figura 29 Imagen Original




Figura 30 imagen segmentada, con su división de cada elemento.



Figura 31 imagen Original




Figura 32 imagen segmentada, con su división de cada elemento.



Figura 33 Imagen Original




Figura 34 imagen segmentada, con su división de cada elemento.

## V. CONCLUSIONES

Se puede concluir que el uso del procesamiento de imágenes para determinar el crecimiento de la planta de cebolla aún sembrada es posible, se deben considerar la cantidad de fotografías, así como la manera de tomarlas ya que esto es esencial para obtener las mediciones necesarias para poder obtener una relación, así como para detectar los objetos de interés.

Se considera que el uso de la arquitectura de la red neuronal de tipo U-Net produce resultados muy satisfactorios para la detección de la planta de cebolla, así como sus componentes, cabe resaltar que es muy importante la realización de las máscaras de etiquetado de una manera cuidadosa, para que la red neuronal pueda aprender de manera correcta los patrones con los que se identifica la planta. Una correcta etiquetación se puede obtener mejores resultados de predicción en la red neuronal entrenada.

El uso de la regresión lineal es de gran ayuda para obtener relación entre dos variables, como lo son el grosor del tallo y el tamaño del bulbo de la cebolla. No se obtuvo una buena relación entre estas dos variables porque no se contaba con un buen tamaño de muestra de datos para obtener una relación.

Puede que también se tuviera que considerar otros variables importantes como los nutrientes del suelo, el riego o las condiciones climáticas.

En otro caso se pudiera explorar otros modelos más complejos.



## VI. REFERENCIAS BIBLIOGRÁFICAS

- Aníbal, P., Ojeda, V., Rubén, A., Toledo, S., & Daniel González Villalba, J. (n.d.). *Cipriano Ramón Enciso Garay*.
- da Silveira, F., Lermen, F. H., & Amaral, F. G. (2021). An overview of agriculture 4.0 development: Systematic review of descriptions, technologies, barriers, advantages, and disadvantages. *Computers and Electronics in Agriculture*, 189, 106405. <https://doi.org/10.1016/J.COMPAG.2021.106405>
- Everardo Zamora, P. (n.d.). *EL CULTIVO DE LA CEBOLLA*.
- FAOSTAT. (n.d.). Retrieved April 23, 2023, from <https://www.fao.org/faostat/es/#data/QCL/visualize>
- Ghaznavi, A., Saberioon, M., Brom, J., & Itzerott, S. (2024). Comparative performance analysis of simple U-Net, residual attention U-Net, and VGG16-U-Net for inventory inland water bodies. *Applied Computing and Geosciences*, 21, 100150. <https://doi.org/10.1016/J.ACAGS.2023.100150>
- Gonzalez, R. C., & Woods, R. E. (2018). Digital Image Processing, Global Edition. *Person Education*, 19–44.
- Hadipour-Rokni, R., Askari Asli-Ardeh, E., Jahanbakhshi, A., Esmaili paeen-Afrakoti, I., & Sabzi, S. (2023). Intelligent detection of citrus fruit pests using machine vision system and convolutional neural network through transfer learning technique. *Computers in Biology and Medicine*, 155, 106611. <https://doi.org/10.1016/J.COMPBIOMED.2023.106611>
- Kingma, D. P., & Ba, J. L. (2014). Adam: A Method for Stochastic Optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*. <https://arxiv.org/abs/1412.6980v9>
- Maceachern, C. B., Esau, T. J., Schumann, A. W., Hennessy, P. J., & Zaman, Q. U. (2023). Detection of fruit maturity stage and yield estimation in wild blueberry using deep learning convolutional neural networks. *Smart Agricultural Technology*, 3, 100099. <https://doi.org/10.1016/j.atech.2022.100099>
- Marketing and Regulatory Programs Agricultural Marketing Service Specialty Crops Program Specialty Crops Inspection Division United States Standards for Grades of Onion Sets*. (2016). [https://www.ascr.usda.gov/complaint\\_filing\\_cust.html](https://www.ascr.usda.gov/complaint_filing_cust.html)
- Producción Agrícola | Servicio de Información Agroalimentaria y Pesquera | Gobierno | gob.mx*. (n.d.). Retrieved April 23, 2023, from <https://www.gob.mx/siap/acciones-y-programas/produccion-agricola-33119>

- Repositorio Institucional Caxcán: Identificación de parámetros comunes en un cultivo de cebolla (Allium cepa) mediante PDI.* (n.d.). Retrieved March 22, 2022, from <http://ricaxcan.uaz.edu.mx/jspui/handle/20.500.11845/1914>
- Roboflow: Computer vision tools for developers and enterprises.* (n.d.). Retrieved May 17, 2024, from <https://roboflow.com/>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9351, 234–241. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
- Russ, John., & Neal, F. . (2018). *The Image Processing Handbook, 7th Edition.* 1035.
- Saini, M. K., & Saini, R. K. (2020). Agriculture monitoring and prediction using Internet of Things (IoT). *PDGC 2020 - 2020 6th International Conference on Parallel, Distributed and Grid Computing*, 53–56. <https://doi.org/10.1109/PDGC50313.2020.9315836>
- Servicio de Información Agroalimentaria y Pesquera | Gobierno | gob.mx.* (n.d.). Retrieved August 9, 2022, from <https://www.gob.mx/siap/>
- Suleria, H. A. R., Butt, M. S., Anjum, F. M., Saeed, F., & Khalid, N. (2014). Onion: Nature Protection Against Physiological Threats. <https://doi.org/10.1080/10408398.2011.646364>, 55(1), 50–66. <https://doi.org/10.1080/10408398.2011.646364>
- Szeliski, R. (2022a). *Image Processing.* 85–151. [https://doi.org/10.1007/978-3-030-34372-9\\_3](https://doi.org/10.1007/978-3-030-34372-9_3)
- Szeliski, Richard. (2022b). *Computer vision : algorithms and applications.*
- Ullah, M., Islam, F., & Bais, A. (2024). *Quantifying consistency of crop establishment using a lightweight U-Net deep learning architecture and image processing techniques* ARTICLE IN F O. <https://doi.org/10.1016/j.compag.2024.108617>
- Valle, M. Q., Amilcar, G., Castillo, V., Arturo, J., & Director, M. (2010). *Guía para la implementación de Buenas Prácticas Agrícolas (BPA) para el cultivo de Cebolla.* [www.gob.pe/senasa](http://www.gob.pe/senasa)
- Xu, Z., & Saleh, J. H. (2021a). Machine learning for reliability engineering and safety applications: Review of current status and future opportunities. *Reliability Engineering & System Safety*, 211, 107530. <https://doi.org/10.1016/J.RESS.2021.107530>
- Xu, Z., & Saleh, J. H. (2021b). Machine learning for reliability engineering and safety applications: Review of current status and future opportunities. *Reliability Engineering & System Safety*, 211, 107530. <https://doi.org/10.1016/J.RESS.2021.107530>

## Anexos

Código de implementación de la red neuronal U-Net y entrenamiento

```
#importar librerias

import os
import cv2
import numpy as np
#from os import listdir
from cv2 import resize
import matplotlib.pyplot as plt

# importar imagenes a trabajar y mascaras
IMG_WIDTH = 512
IMG_HEIGHT = 512
IMG_CHANNELS = 3

SUBFOLDERS=['imagen','mascara']

imagenes = sorted(os.listdir(SUBFOLDERS[0]))
mascaras = sorted(os.listdir(SUBFOLDERS[1]))

img = np.zeros((len(imagenes),640,640,3))
msk = np.zeros((len(mascaras),640,640))

idx = 0
for imagen in imagenes:
    nombre_imagen = os.path.join(SUBFOLDERS[0],imagenes[idx])
    imagen_tmp = cv2.imread(nombre_imagen,cv2.IMREAD_COLOR)
    img[idx] = imagen_tmp
    idx = idx + 1

idx = 0
for mascara in mascaras:
    nombre_mascara = os.path.join(SUBFOLDERS[1],mascaras[idx])
    mask_tmp = cv2.imread(nombre_mascara,cv2.IMREAD_GRAYSCALE)
```

```

for mascara in mascaras:
    nombre_mascara = os.path.join(SUBFOLDERS[1],mascaras[idx])
    mask_tmp = cv2.imread(nombre_mascara,cv2.IMREAD_GRAYSCALE)
    msk[idx] = mask_tmp
    idx = idx + 1

aleatorio = 10

plt.imshow(np.uint8(msk[aleatorio]*80))

plt.imshow(np.uint8(img[10]))

np.save('x_train.npy',img.astype(np.uint8))
np.save('y_train.npy',msk.astype(np.uint8))

x_train = np.load('x_train.npy')
y_train = np.load('y_train.npy')

aleatorio = 10

plt.imshow(y_train[aleatorio]*80)

plt.imshow(x_train[aleatorio])

```

```

#Unet

import tensorflow as tf
import keras
from keras.layers import Conv2D, MaxPooling2D, Dense, Flatten, Dropout, Conv2DTranspose

#from keras.engine import input_layer

inp =tf.keras.layers.Input((640,640,3))

c1=tf.keras.layers.Conv2D(filters=64,kernel_size=(3,3),padding="same",activation="relu")(inp)
c1=tf.keras.layers.Conv2D(filters=64,kernel_size=(3,3),padding="same",activation="relu")(c1)
m1=tf.keras.layers.MaxPooling2D(pool_size=(2,2), strides=(2,2))(c1)

c2=tf.keras.layers.Conv2D(filters=128,kernel_size=(3,3),padding="same",activation="relu")(m1)
c2=tf.keras.layers.Conv2D(filters=128,kernel_size=(3,3),padding="same",activation="relu")(c2)
m2=tf.keras.layers.MaxPooling2D(pool_size=(2,2), strides=(2,2))(c2)

c3=tf.keras.layers.Conv2D(filters=256,kernel_size=(3,3),padding="same",activation="relu")(m2)
c3=tf.keras.layers.Conv2D(filters=256,kernel_size=(3,3),padding="same",activation="relu")(c3)
m3=tf.keras.layers.MaxPooling2D(pool_size=(2,2), strides=(2,2))(c3)

c4=tf.keras.layers.Conv2D(filters=512,kernel_size=(3,3),padding="same",activation="relu")(m3)
c4=tf.keras.layers.Conv2D(filters=512,kernel_size=(3,3),padding="same",activation="relu")(c4)
m4=tf.keras.layers.MaxPooling2D(pool_size=(2,2), strides=(2,2))(c4)

c5=tf.keras.layers.Conv2D(filters=1024,kernel_size=(3,3),padding="same",activation="relu")(m4)
c5=tf.keras.layers.Conv2D(filters=1024,kernel_size=(3,3),padding="same",activation="relu")(c5)

t6=tf.keras.layers.Conv2DTranspose(filters=512,kernel_size=(2,2),padding="valid", strides=(2,2))(c5)
cc6=tf.keras.layers.concatenate([t6,c4])
c6=tf.keras.layers.Conv2D(filters=512,kernel_size=(3,3),padding="same",activation="relu")(cc6)
c6=tf.keras.layers.Conv2D(filters=512,kernel_size=(3,3),padding="same",activation="relu")(c6)

```

```

t7=tf.keras.layers.Conv2DTranspose(filters=256,kernel_size=(2,2),padding="valid", strides=(2,2))(c6)
cc7=tf.keras.layers.concatenate([t7,c3])
c7=tf.keras.layers.Conv2D(filters=256,kernel_size=(3,3),padding="same",activation="relu")(cc7)
c7=tf.keras.layers.Conv2D(filters=256,kernel_size=(3,3),padding="same",activation="relu")(c7)

t8=tf.keras.layers.Conv2DTranspose(filters=128,kernel_size=(2,2),padding="valid", strides=(2,2))(c7)
cc8=tf.keras.layers.concatenate([t8,c2])
c8=tf.keras.layers.Conv2D(filters=128,kernel_size=(3,3),padding="same",activation="relu")(cc8)
c8=tf.keras.layers.Conv2D(filters=128,kernel_size=(3,3),padding="same",activation="relu")(c8)

t9=tf.keras.layers.Conv2DTranspose(filters=64,kernel_size=(2,2),padding="valid", strides=(2,2))(c8)
cc9=tf.keras.layers.concatenate([t9,c1])
c9=tf.keras.layers.Conv2D(filters=64,kernel_size=(3,3),padding="same",activation="relu")(cc9)
c9=tf.keras.layers.Conv2D(filters=64,kernel_size=(3,3),padding="same",activation="relu")(c9)

out=tf.keras.layers.Conv2D(filters=4,kernel_size=(3,3),padding="same",activation="softmax")(c9)

model=tf.keras.Model(inputs=[inp],outputs=[out])

model.compile(optimizer='adam',loss='sparse_categorical_crossentropy',metrics=('accuracy'))

# Commented out IPython magic to ensure Python compatibility.
from keras.callbacks import Callback
from tensorflow.keras.callbacks import TensorBoard
import datetime
# Cargamos la extensión, definimos la carpeta logs para guardar los datos de entrenamiento, y definimos el callback
# %load_ext tensorboard
logdir = os.path.join("logs", datetime.datetime.now().strftime("%Y%m%d-%H%M%S"))
tensorboard_callback = TensorBoard(logdir, histogram_freq=1)

model.fit(x_train,y_train,batch_size=25,epochs=20,validation_split=0.2, callbacks=[tensorboard_callback])

model.save('my_model15.h5')

```

## Código de validación del entrenamiento

```
import tensorflow as tf
import cv2
import os
import numpy as np

model = tf.keras.models.load_model('my_model.h5')

IMG_WIDTH = 128
IMG_HEIGHT = 128
IMG_CHANNELS = 3

newX= []

SUBFOLDERS=['imagen']

imagenes = sorted(os.listdir(SUBFOLDERS[0]))

print(imagenes)

print(len(imagenes))

img = np.zeros((len(imagenes),640,640,3))

idx = 0

for imagen in imagenes:
    nombre_imagen = os.path.join(SUBFOLDERS[0],imagenes[idx])
    imagen_tmp = cv2.imread(nombre_imagen,cv2.IMREAD_COLOR)
    imgResize = cv2.resize(imagen_tmp,(IMG_WIDTH,IMG_HEIGHT))
    newX.append(imagen_tmp)
    #img[idx] = imagen_tmp
    #idx = idx + 1
```

```

Xnew = np.array(newX)
print(len(Xnew))

import matplotlib.pyplot as plt

plt.imshow(np.uint8(Xnew[0]))

y_prediccion = model.predict(Xnew)
#print(y_prediccion)
print(y_prediccion.shape)

y_prediccion = np.round(y_prediccion)
print(y_prediccion.shape)

#y_prediccion[1] = 3
#print(y_prediccion.shape)

def display_mask(i):
    mask = np.argmax(y_prediccion[i], axis=-1)
    mask = np.expand_dims(mask, axis=-1)
    print(mask.shape)
    img = ImageOps.autocontrast(keras.preprocessing.image.array_to_img(mask))
    display(img)
    cv2.imwrite('mask.png',mask)

i = 0

# Display mask predicted by our model
display_mask(i) # Note that the model only sees inputs at 150x150.

```



Se anexa un enlace en donde se podrá encontrar todas las imágenes y las mascararas con las que se trabajaron a lo largo de la investigación

[https://drive.google.com/drive/folders/1eg0PPrWwpfTjDtgM\\_EiUGcdIWmgyMPSW?usp=drive\\_link](https://drive.google.com/drive/folders/1eg0PPrWwpfTjDtgM_EiUGcdIWmgyMPSW?usp=drive_link)