



**FACULTAD DE INGENIERIA, ARQUITECTURA Y
URBANISMO**

**ESCUELA PROFESIONAL DE INGENIERIA DE SISTEMAS
TESIS**

**DETECCIÓN AUTOMÁTICA DE LA ENFERMEDAD
LASIODIPLODIA THEOBROMAE DEL PALTO
UTILIZANDO IMÁGENES DIGITALES CON REDES
NEURONALES CONVOLUCIONALES.**

**PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO
DE SISTEMAS**

Autor:

Bach. Flores Tello Jaime Nicolas

ORCID: <https://orcid.org/0000-0003-1942-9651>

Asesor:

Mag. Mejia Cabrera Heber Ivan

ORCID: <https://orcid.org/0000-0002-0007-0928>

Línea de Investigación:

Infraestructura, Tecnología y Medio Ambiente

Pimentel – Perú 2022

APROBACION DEL JURADO

**DETECCIÓN AUTOMÁTICA DE LA ENFERMEDAD LASIODIPLDIA
THEOBROMAE DEL PALTO UTILIZANDO IMÁGENES DIGITALES CON
REDES NEURONALES CONVOLUCIONALES**

Bach. Flores Tello Jaime Nicolas

Autor

DR. Forero Vargas Manuel Guillermo

Presidente de Jurado

MG. Diaz Vidarte Miguel Orlando

Secretario de Jurado

MG. Mejia Cabrera Heber Ivan

Vocal de Jurado

DEDICATORIA

La presente investigación se la dedico a mis padres y mis hermanos y a toda mi familia quienes creyeron en mí y me apoyaron de manera incondicional a pesar de las diversas y difíciles situaciones que se me presentaron durante mi etapa de formación académica profesional.

A aquellas personas que me apoyaron de manera directa e indirectamente.

AGRADECIMIENTOS

Primeramente, a Dios por haberme permitido continuar y llegar hasta este momento de mi vida. A mi madre Luz Angelica Tello Guerrero y a mi padre Jaime Flores Trolla por ser los pilares en mi formación, a mis hermanos Dany quien amo, admiro y es mi ejemplo a seguir y mi hermana Yanira por el amor que me da y a toda mi familia por el apoyo incondicional y a aquellas personas que me apoyaron directa o indirectamente. A todos mis profesores por sus enseñanzas en cada clase y quienes hicieron posible el satisfactorio desarrollo de esta investigación.

RESUMEN

La Palta es una fruta muy importante debido a los nutrientes que posee y a los beneficios que trae a la salud, crece en zonas con climas tropicales y subtropicales, es atacado por plagas y enfermedades. Siendo *Lasiodiplodia Theobromae* la enfermedad más recurrente. Realizar la identificación usando la experticia humana genera complicaciones, la presente investigación propuso detectar la enfermedad de manera automática haciendo uso de las redes neuronales convolucionadas. La investigación tuvo 4 etapas. La primera etapa siguió un riguroso protocolo para realizar la toma de imágenes, en la segunda etapa se caracterizó la enfermedad visualmente. En la tercera etapa las imágenes se sometieron a un pre procesamiento. En la etapa quinta se realizó la clasificación automática de la enfermedad. Obteniendo como resultados un 98% de precisión, 96% de exactitud, 96% de sensibilidad y 98% de especificidad. Concluyéndose que las redes neuronales convolucionales fueron efectivas para la clasificación digital, sin embargo, para la obtención de mejores resultados es necesario que el repositorio de imágenes se más grande.

PALABRAS CLAVE

Detección automática, *Lasiodiplodia Theobromae*, Redes Neuronales, Binarización, RGB, HSV, LAB.

ABSTRAC

Avocado is a very important fruit because of the nutrients it has and the benefits it brings to health, it grows in areas with tropical and subtropical climates, is attacked by pests and diseases. Lasiodiplodia being Theobromae the most recurrent disease. Performing the identification using human expertise generates complications, the present investigation proposed to detect the disease automatically using convoluted neural networks. The investigation had 4 stages. The first stage followed a rigorous protocol to perform the imaging, in the second stage the disease was characterized visually. In the third stage the images underwent a preprocessing. In the fifth stage the automatic classification of the disease was performed. Obtaining 98% precision, 96% accuracy, 96% sensitivity and 98% specificity as results. Concluding that the convolutional neural networks were effective for digital classification, however, in order to obtain better results, it is necessary that the image repository be larger.

Keyword

Automatic detection, Theobromae Lasiodiplodia, Neural Networks, Binarization, RGB, HSV, LAB.

ÍNDICE

I. Introducción	11
1.1 Realidad Problemática	11
1.2 Antecedentes de Estudio	18
1.3 Teorías relacionadas al tema	24
1.4 Formulación del Problema	41
1.5 Justificación e importancia del estudio	41
1.6 Hipótesis	42
1.7 Objetivos	42
II. MATERIAL Y MÉTODO.....	43
2.1 Tipo y Diseño de Investigación	43
2.2 Población y muestra.....	43
2.3 Variables, Operacionalización	43
2.4 Técnicas e instrumentos de recolección de datos, validez y confiabilidad 46	
2.5 Procedimientos de análisis de datos.....	46
2.6 Criterios éticos	48
2.7 Criterios de Rigor científico.	48
III. RESULTADOS	49
3.1 Resultados en Tablas y Figuras	49
3.2 Discusión de resultados	54
3.3 Aporte práctico	56
IV. CONCLUSIONES Y RECOMENDACIONEs	73
4.1. Conclusiones.....	73
4.2 Recomendaciones.....	73
REFERENCIAS.....	75
ANEXOS	79

ÍNDICE DE FIGURAS

Figura 1. Área mundial con cultivo de palta (ha) des el año 2000 al año 2012.	13
Figura 2. Producción mundial de palta (toneladas). desde 2007 hasta 2017.	14
Figura 3. Crecimiento de producción de palta en Perú (toneladas). desde 2007 hasta 2017.....	15
Figura 4. Rendimiento de la producción mundial de palta (t/ha). entre el 2000 y el 2017	16
Figura 5. Topología de una neurona artificial.	30
Figura 6. Ilustración del concepto de la red neuronal de una capa	31
Figura 7. Ilustración del concepto de la red neuronal con capa oculta.	31
Figura 8. Representación gráfica de una convolución.....	32
Figura 9. Ejemplo de una convolución	33
Figura 10. Capas de convoluciones.	34
Figura 11. Ejemplificación de la función de ReLu. Donde se consideran a los valores de color blanco como positivos y a los valores de color negro como negativos.....	35
Figura 12. Imagen de 5x5 pixeles con valores 0 y 1. Donde se aplicará una convolución con figura siguiente	35
Figura 13. Campo receptivo que se convolucionará con la figura anterior.	35
Figura 14. Paso 01 de una convolución. Donde se observa la superposición de la imagen naranja sobre la verde siendo el resultado de convolución el valor 4 sugerido en la siguiente ecuación.	36
Figura 15. Paso 02 de una convolución. donde se observa el desplazamiento en 1 pixel de la imagen naranja sobre la imagen verde dando como valor de convolucion el valor 3 que arroja de la siguiente ecuacion.	36
Figura 16. Resultado de una convolución. Donde se aprecia, una imagen de 5x5 pixeles se trasformó en una de 3x3.....	37
Figura 17. Ejemplo de imagen a convolucionar con valores en escala de grises que van de 0 a 255.....	37
Figura 18. Matriz resultante de la convolución realizada en escala de grises.	38
Figura 19. Funcionamiento de la capa pooling.....	39

Figura 20. Ejemplificación del funcionamiento de la capa pooling en una fotografía. Se toma regiones de 2 x 2 píxeles y las reduce tomando el máximo valor de cada una.....	39
Figura 21. Representación gráfica del esquema de un cubo RGB a 24 bits.	40
Figura 22. comparación entre los resultados obtenidos en pruebas y validación..	54
Figura 23. Comparación de resultados obtenidos en la presente investigación y la investigación de (Flores et al., 2020).....	55
Figura 24. Método propuesto de la investigación.	56
Figura 25. Pasos del protocolo de adquisición de imágenes digitales.	57
Figura 26. Protocolo de Adquisición de imágenes digitales en campo del tallo del palto.	59
Figura 27. Imágenes redimensionadas con resolución 252 x 450.....	61
Figura 28. Segmentación del fondo de las imágenes digitales del tallo con el algoritmo de grabcut.....	62
Figura 29. Imágenes de los componentes de color del espacio RGB del tallo de aguacate en la Figura 28. a. Rojo. b. Verde. C. Azul	64
Figura 30. Imágenes de los componentes de color del espacio HSB del tallo de aguacate en la Figura 28. a. Componente H. Se ha aumentado el brillo para facilitar la visualización. b. Componente S. c. Componente V.....	66
Figura 31. Imagen segmentada utilizando el método de umbralización de máxima entropía, donde la región afectada por el hongo se separa del fondo.....	67
Figura 32. Resultado obtenido al superponer la imagen de la Figura 31, utilizada como máscara, sobre la original de la figura 28. Estas imágenes se utilizan como entradas clasificadoras para identificar si el área segmentada está infectada por lasiodiplodia.....	68
Figura 40. Dataset donde se encuentran almacenadas las imágenes a utilizar, separadas en 3 carpetas.	69
Figura 41. Subdivisión de carpetas donde se almacenan las imágenes de tallos enfermos y tallos sanos.....	69
Figura 42. Diseño general de la elaboración del dataset para el procesamiento y clasificación de imágenes.....	70
Figura 43. Arquitectura de la red neuronal convolucional.	72

ÍNDICE DE TABLAS

Tabla 1	45
Tabla 2	50
Tabla 3	52
Tabla 4	59

I. INTRODUCCIÓN

1.1 Realidad Problemática

La palta peruana o conocida también como aguacate, cuyo nombre científico es *Persea Americana Var Mill*, es oriundo de centro América. En el año 2018 se posicionó como el principal líder de agro exportación en el Perú, dejando atrás a otros productos ya conocidos como café, bananos, mandarina, espárragos, etc. Con una proyección muy ambiciosa de expansión que fomentará el crecimiento de la agricultura nacional y traer consigo grandes ingresos económicos al trabajador rural. (Ministerio Agricultura y Riego Peru, 2019).

Este fruto tiene como origen áreas con condiciones climáticas cálidas, como, por ejemplo: México, países de América central y las Antillas. Actualmente este fruto es producido en todas las áreas cálidas al rededor del planeta, en un área mayor a las 400000 hectáreas cultivadas, su producción anual supera los 3 millones de toneladas, según información estadística de la FAO (*Food and Agriculture Organization*). El que mayor produce y que mayor exporta del mundo es México. El Perú fue ubicado en el sétimo puesto en producción en el año 2007 y también tiene el mismo puesto en las exportaciones del 2005. (Dirección General De Información Agraria, 2008).

La palta, en cuanto a consumo respecta, desde hace varios años ha ido creciendo exponencialmente, sus propiedades ricas en nutrientes y su sabor han hecho de este alimento un fruto de moda en los países más desarrollados, los jóvenes de los países emergentes son los que hacen que este fruto tenga grandes demandas. No por algo es la fruta con mayor variedad y cantidad de proteínas, además gracias a la gran concentración que tiene en aceites vegetales tiene un rico contenido graso y calórico y propiedades antioxidantes muy beneficiosas, gracias a todo lo mencionado anteriormente se tiene la creencia que ayuda a mitigar los riesgos de desarrollar enfermedades cardiacas y cáncer, en otras palabras, no sólo es una fruta fresca, sino una fruta funcional. La palta tiene muchas variedades en el mundo siendo 2 las más grandes: La palta fuerte y Hass. La variedad más consumida en Latinoamérica es la palta fuerte, pero a pesar de ello la Hass representa el 80% del mercado mundial. Como consecuencia de la producción errática de los árboles de la variedad fuerte, así como su piel que es extremadamente delicada que fuerza a

que los frutos sean manipulados más cuidadosamente, mientras que la variedad Hass tiene la cascara más dura, lo que permite ser manipulada más fácilmente y que sea transportado a largas distancias. El fruto del palto es considerado climatérico lo que significa que su maduración termina de desarrollar cuando el fruto es cosechado, en otras palabras, cuando es cortado de la planta. En ese aspecto, es necesario que sean tratado posterior a la cosecha, con finalidad de extender su vida útil. Permitiendo de este modo que cuando sean exportados, lleguen al consumidor final en excelente estado y se pueda disfrutar sus beneficios (Ministerio Agricultura y Riego Peru, 2019)

Según las nuevas estadísticas reveladas por la FAO, las zonas cultivadas de aguacate en el planeta han venido aumentando de forma progresiva en la última década. Para el 2000 las hectáreas cosechadas llegaban a 340 mil, para el 2006 se amplió a 348,000 hectáreas, hasta el 2012 se calculaba 486,000 hectáreas dando un 43% de aumento en comparación al 2000. Siendo el país con más zona de sus tierras que está dedicada netamente a la siembra de palta, México tiene un 27% de todo el mundo. En el Perú, las áreas dedicadas al cultivo de palta han venido creciendo sostenidamente, En la actualidad se ubica en el sexto puesto del top de los países del mundo con áreas cosechadas dejando un registro de 20 mil hectáreas hasta el año 2012. (Ministerio Agricultura y Riego Peru, 2015).




Figura 1. Área mundial con cultivo de palta (ha) des el año 2000 al año 2012.

Copyright 2015 por Ministerio de agricultura y riego Perú

De acuerdo con las cifras dadas por FAOSTAT (Food and Agriculture Organization of the United Nations) y cuyos resultados datan hasta el 2017, la producción a nivel del mundo de esta fruta ha ido reflejando una creciente predisposición durante el período 2000-2017, reflejando un 5.1% de crecimiento, con excepción del año 2008 debido a que el consumo mundial se expandió. la cifra de producción más elevada alcanzó en el año 2017, con 6 048 000 toneladas. Destacando notablemente México como el líder exportador, consumidor y productor en el mundo. En el 2018 representó el 34% de toda la producción del mundo. Tendiendo en promedio un incremento anual de 5.09%. (Ministerio Agricultura y Riego Peru, 2019)




Figura 2. Producción mundial de palta (toneladas). desde 2007 hasta 2017.

Copyright 2019 por Ministerio de agricultura y riego Perú

El segundo país es República dominicana, teniendo el 11% a nivel del mundo y un incremento anual de 13.3%. En lo que al Perú respecta, es el tercer país productor de palta en el mundo, con un 8%, el Perú es el país con más elevada tasa de desarrollo de producción promediando el 14.4% por año, habiendo logrado superar en el año 2007 a Estados Unidos, en el 2008 a Chile, Indonesia en el 2014 y en el 2015 a Colombia. Con ese comportamiento de crecimiento es posible que unos años se logre igualar en producción a República Dominicana. (Ministerio Agricultura y Riego Peru, 2019)




Figura 3. Crecimiento de producción de palta en Perú (toneladas). desde 2007 hasta 2017.

Copyright 2019 por Ministerio de agricultura y riego Perú

Según (Ministerio Agricultura y Riego Peru, 2015) la rentabilidad por países de la producción, sobresalen algunos que no se muestran. Esto se debe a que no representan cifras importantes de rendimiento, aunque demuestran una producción muy alta, entre los cuales tenemos: Seychelles, Bahamas, Timor, Polinesia Francesa, Palestina, y Samoa.

¿Pero, todo lo que se produce se exporta? (Ministerio Agricultura y Riego Peru, 2019) Nos dice que, en cuanto a rendimiento mundial el promedio del incremento apenas ha sido un 0.2%, en otras palabras, ha estado estancado en estos últimos años; sin embargo hay que resaltar el incremento elevado del rendimiento de aguacate de lado de República Dominicana, que ha aumentado notablemente desde hace algunos años, siendo en 2007, de 26 toneladas a 43 toneladas en 2017, mientras que Brasil, El Salvador y Kenia reflejan un rendimiento de 16.5 toneladas, 17.1 toneladas y 16.7 toneladas respectivamente.

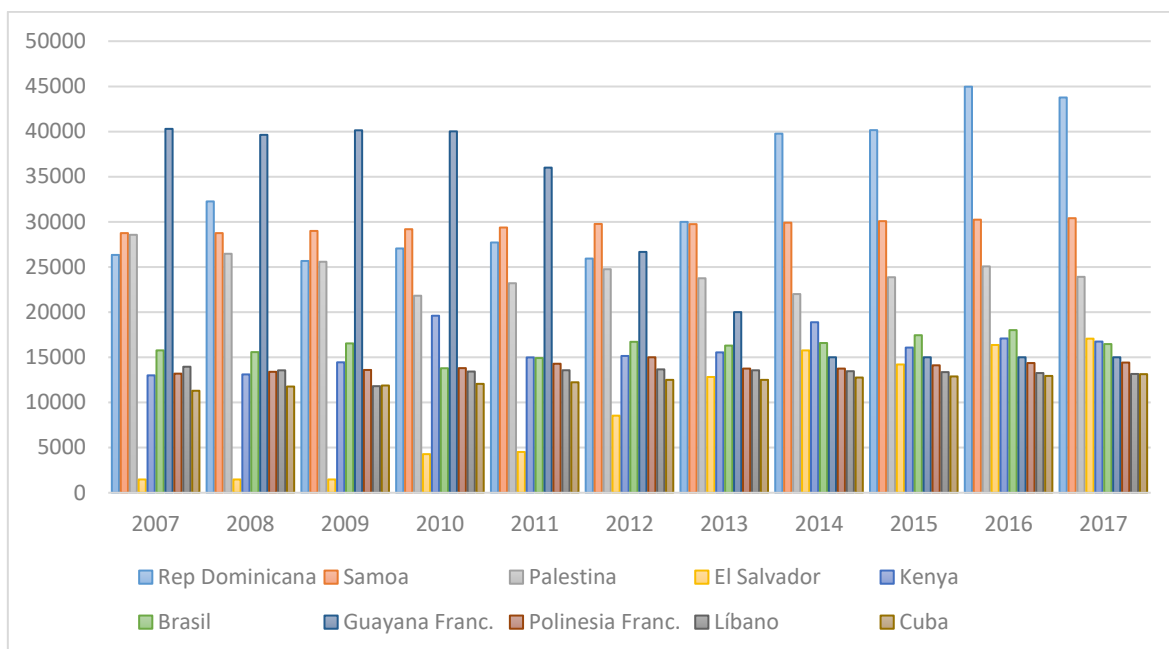


Figura 4. Rendimiento de la producción mundial de palta (t/ha). entre el 2000 y el 2017

Copyright 2015 por Ministerio de agricultura y riego Perú

Debido a los cambios en el ambiente, como la lluvia, la temperatura, la fertilidad del suelo, los cultivos pueden infectarse con hongos, bacterias y virus. Utilizan herbicidas y pesticidas herbicidas adecuados para las plantas para la prevención de enfermedades y aumentar la productividad y calidad del producto. Los patrones de observación visual de las plantas se utilizan para identificar y estudiar las enfermedades de las plantas. La detección de enfermedades de las plantas en la etapa inicial será beneficiosa ya que la enfermedad se puede controlar (Meyyappan, 2018).

Una de las técnicas principales para la propagación del aguacate es el injerto, esta a su vez, empleando una planta patrón producida vía semilla, esparcen una variedad de enfermedades severas de origen fúngico y en el peor de los casos provocan la muerte del árbol, por lo general, son las originarias de que se pueda llegar a alcanzar el 14% de la disminución de la producción y en un 10% la reducción de calidad, económicamente las de más importancia son las siguientes enfermedades: Lasiodiplodia, Dothiorella, Colletotrichum, Alternaria, Verticillium, Fusarium, etc. (Leal-Nares, 2004).

En recientes años, mediante el factor de elongación 1 alfa ($EF-1\alpha$) y el análisis de ADN en fragmentos espaciadores intergénicos (ITS), se ha sentado una conexión filogenética con diferentes especies. En comparación con otras similares especies o relacionadas cercanamente, esto ha logrado que se obtengan resultados más visibles de su ubicación (Abdollahzadeh et al., 2010).

Otro tipo de método para identificar las afecciones de las plantas, es la supervisión, pero este tipo de métodos tiene una principal desventaja la cual es, que muchas veces está sujeta a que un supervisor experto en el tema haga este tipo de supervisión o selección. (Trueba, 2017) Nos dice que la principal desventaja de este caso es que al final la estimación visual esta siempre sujeta a un individuo experimentado. Este tipo de métodos obviamente requieren mucho tiempo y también requieren de personal expedito en el tema. Como consecuencia la ingeniería ha tenido la necesidad de descubrir nuevas formas de detección y métodos que sean automáticos que cumplan con los requerimientos como la fiabilidad, sensibilidad y especificidad para mejorar así la detección de enfermedades o plagas en plantas.

Realmente, en estados de producción, el encargado cada periodo de tiempo examina la vegetación para encontrar enfermedades. Esto nos podría alarmar e indicar las areas donde la enfermedad ataca, pero estas observaciones son específicas y su exactitud está dependiente de la capacidad de resolución del ojo del hombre, inclusive se puede utilizar instrumento de amplificación (Boissard et al., 2007).

Una de las ventajas para utilizar la tecnología para detectar por imágenes, pueden llegar a ser muy precisas, con consistentes resultados y nada destructivas (Chen et al., 2002).

(Yan et al., 2009; Noda et al., 2006; y Husin et al, 2012.) dicen que el procesamiento de imágenes digitales es una técnica empleada muy ampliamente para automatizar de los procesos industriales, esto se debe por su alta confiabilidad, eficacia y sobre todo la rapidez al momento de procesar. Las industrias agrícolas han empezado a hacer uso de esta tecnología para la monitorización de rasgos de mayor importancia en los cultivos.

Según (Quintero et al., 2018) nos dice que las uno de las deficiencias de las redes neuronales convolucionales es el sobreajuste del modelo y esto se debe a la poca muestra que muchas veces se tiene.

1.2 Antecedentes de Estudio

(Meyyappan, 2018) “Detección de infecciones en plantas mediante procesamiento de imágenes” en la revista internacional de investigación en ingeniería moderna se enfrentó al problema que a mayor área de cultivo de plantas es mayo la pérdida de producción debido a los cambios climáticos como la lluvia, la temperatura, la fertilidad del suelo, los cultivos pueden infectarse con hongos, bacterias y virus, por lo que dicha investigación propuso detectar de manera automática de infecciones, basándose en la visión de detección de enfermedades de las plantas, utilizando la técnica de procesamiento de imágenes. Para dicho trabajo se empleó el algoritmo de k-means para la segmentación de color y el GLCM (conocida también como matriz de dependencia espacial de nivel de gris) se usó para la clasificación de la enfermedad. Según el análisis de texturas en las imágenes segmentadas que fueron usadas para la clasificación de infecciones como antracnosis, mancha foliar en las hojas arrojó como resultado que fue capaz de detectar la infección y clasificarla en un 98.27% de precisión. Tuvo como conclusión que las técnicas K-means y GLCM se utilizan para detección de enfermedades en hojas y reduce el costo y el tiempo de detección de lo que lo haría la experticia humana.

(Devaraj et al., 2019) en “Identificación de Enfermedades de Plantas usando Técnica de procesamiento de imágenes” en la Conferencia internacional sobre comunicación y procesamiento de señales, se enfrentaron al problema que debido a que el 70% de la población de un la India depende de la agricultura, lo más necesario es considerar es menos cultivo de calidad debido a las enfermedades que atacan a los cultivos. La solución que plantearon es desarrollar un sistema de software que encuentre y clasifique automáticamente las enfermedades en hojas. Se usó k-means para la segmentación y obtención de características y la técnica de Random forest Classifier para el entrenamiento y clasificación. Se obtuvieron como resultados para el hongo Antracnosa identificándola con un 99% de precisión. En conclusión, el desarrollo de un sistema de detección automática que utiliza

tecnología avanzada, como el procesamiento de imágenes, facilita el apoyo a los agricultores en la identificación de enfermedades en una etapa temprana o inicial y proporciona datos útiles para su gestión.

(Balcázar Guerrero, 2006) “Desarrollo de un módulo SIG para el manejo de imágenes multiespectrales orientado a la agricultura de precisión” en la Pontificia Universidad Católica del Perú. El problema que enfrentó es que en el Perú no se está desarrollando la agricultura de precisión, por lo que dicha investigación está realizada para que se desarrolle un sistema que haga uso de esta tecnología, para que siendo aplicada pueda sentar una base para la agricultura de precisión en el Perú. Se empleó el NDVI (Índice de Vegetación diferencial normalizado). Posteriormente se hizo el procesamiento de imágenes en MATLAB, se analizan las imágenes en GRASS. Los resultados obtenidos son los diferentes valores de NDVI en diferentes coordenadas de la imagen capturada. Los cuales fueron: (0.1784783), (0.108808), (0.150442), (-0.089947) de esto se concluye que el NDVI nos ha permitido diferenciar la vegetación enferma de la sana de otros elementos presentes en la imagen capturada. El software SIG GRASS nos hace posible el procesamiento de las fotos tomadas del censado como remoto, así como las imágenes capturadas desde un satélite. Lo cual hace que sea un software eficaz para poder llevar a cabo los objetivos.

(Pérez, 2014) “Identificación de Vegetación en Imágenes Satélites” en el Instituto Politécnico Nacional de México. El problema al que se enfrentó es como solucionar los problemas de software comercial de procesamiento de datos, el cual, brinda herramientas para manipular, analizar, clasificar y crear imágenes, por lo general tienen grandes costos, haciendo que su adquisición sea un poco inaccesible. Por lo que se propone desarrollar un algoritmo con la capacidad de distinguir áreas cubiertas de vegetación en fotos satelitales Landsat 5. Esto se logró haciendo que el algoritmo inicialmente pueda leer las siete bandas landsat 5. Como un modelo del progreso de algoritmo, se usó la imagen Landsat 29/46 que abarca el lago de Chapala y la ciudad de Guadalajara, para poder ver la imagen se usa las bandas 4, 3 y 2, para RGB donde se le otorga un color un falso a la colaboración de la imagen. Las bandas son pasadas individualmente por un filtro que usa los coeficientes de la transformada Wavelet Dautbechies de orden 4, como resultado

final se logra tener un contraste mejorado y homogeniza el nivel digital de la imagen. Para que se pueda observar mejor el producto final del procesamiento e identificación, se elige la zona de interés de aproximadamente (300 x 300 píxeles) mediante un puntero interactivo que estará en el software y se recorta. La imagen reducida ingresa a procesamiento y se clasifica usando ciertos criterios lógicos. Las clases generan individualmente una matriz binaria, la cual se puede exhibir de independientemente en cada una de las superficies indicadas. Como resultados después de realizar un filtro se observa un mejoramiento en el brillo de la imagen, el contorno de los objetos se suaviza, lo cual hace que los valores sean homogéneos. Luego de hacer la clasificación esta separa la vegetación de asfalto, agua, arena o suelos, alguna sombra asignándole unos diferentes colores para cada y no existen píxeles sin clasificar. Por lo que se concluye que el algoritmo desarrollado está apto para poder identificar en imágenes satelitales Landsat 5, las densidades de cobertura vegetal.

(Trueba, 2017) “Análisis de imágenes multiespectrales aéreas de vegetación” en la Universidad de Cantabria. El problema que se enfrentó fue la detección de plagas y enfermedades en la vegetación. Se propuso como solución utilizar imágenes multiespectrales tomadas desde drones aéreos. Se empleó el NDVI (Índice de Vegetación diferencial normalizado). Se procesaron las imágenes obtenidas mediante Pix4D, luego con este mismo software se calculó el NDVI, una vez calculado El Índice de Vegetación diferencial normalizada se procedió a procesar las imágenes en Matlab. Los resultados Obtenidos en las imágenes realizadas sobre el pinar fueron: El área del pinar cuenta con un índice de vegetación que varía entre 0,04 y 0,1, y las áreas de terrenos que corresponde a vegetación tienen un índice de 0,35 a 0,6. De esto se obtiene que los índices de vegetación elevados reconocen píxeles cubierto por tamaños sustanciales saludables, y en zonas donde no hay presencia de áreas verdes se obtiene índices de vegetación muy pobres. En el caso de los maizales se realizaron 3 vuelos en el primer vuelo arrojó que el índice varía entre os 0,6 y 0,87. En tanto, áreas de cultivo inferiores los valores de índice varían alrededor de los 0,80 y los 0,93. En el vuelo número 2 aparecen disimilitud en comparación con el vuelo número 1, la zona de baja arrojó 0,70 y 0,86, en tanto los valores del área alta varían entre 0,87 y 0,94, distribuyéndose las cifras más altas por el área baja de esa región. En el tercer vuelo el NDVI presenta

variaciones de 0,18 y 0,28 que son cifras muy bajas en comparación con los vuelos hechos con anterioridad. Lo que indica una falta muy alta de densidad foliar. Por lo que los resultados que se realizaron en el tercer vuelo quedan descartados. En conclusión, se diferencia las áreas verdes y menos sanas que otras, en consecuencia, se puede distinguir las enfermedades en cultivos y bosques. De igual forma que se han apreciado disimilitudes entre áreas dañadas y verdes, las texturas también pueden ayudar a la identificación de anomalías y enfermedades en la vegetación.

(Beltrán-Peña et al., 2014) “Detección Satelital y Molecular del viroide de la mancha de sol del aguacate”. El problema que abordó fue de resolver si los satélites QuickBird podrían detectar síntomas de ASBVd en arboles haciendo uso de la reflectancia espectral de dichos satélites y determinar si los árboles estaban sanos o afectados. Lo que se hizo fue que se determinaran diferentes clases espectrales de árboles sanos y enfermos. Luego se hizo el procesamiento digital con base de algoritmos de clasificación. Y fue realizado de la siguiente manera: se hizo un análisis molecular de hojas. También se realizó el procesamiento de imágenes de satélite QuickBird utilizando el algoritmo de máxima probabilidad para compararlo con la RT-PCR. Los resultados obtenidos de este estudio son: de 112 especímenes analizados con la técnica RT-PCR y las que fueron clasificadas digitalmente de la imagen de satélite, 76 coinciden con las 2 técnicas en un 67,8% De los 21 ejemplares sintomáticos, la RT-PCR decidió a 21 arboles como enfermos realmente mientras que las que fueron clasificadas digitalmente detecto 14 coincidiendo en un 66,7%, de los 34 especímenes que no presentaban síntomas 25 coincidieron con las dos técnicas en un 73,5%. de los 57 árboles sanos 37 coincidencia con la clasificación. De lo cual se puede concluir que la técnica que hace uso de la detección por satélite identificó con un 47% árboles afectados con ASBVd. La técnica de RT-PCR tenía una precisión de 49% en la eficiencia de detección.

(Moghadam et al., 2017) “Plant Disease Detection Using Hyperspectral Imaging”. El principal problema desarrollado en este tema es mejorar el uso de la agricultura de precisión a través de la detección de enfermedades de plantas y plagas, a través del método de la robótica para la localización espacial. Mediante el uso de imágenes hiperespectrales (VNIR y SWIR), se puede realizar la detección precoz

de enfermedades de las plantas, y así los agricultores puedan responder de una manera oportuna para facilitar y limitar daños a sus cultivos. Se utilizaron técnicas de imagen y de aprendizaje automático hiperespectrales aplicadas para identificar las afecciones de las plantas existentes. Una de estas técnicas es SVM (Máquina de Vector de Soportes), esta técnica se basa en el empleo de algoritmos de aprendizaje automático para la detección precoz de enfermedades de las plantas, la precisión de esta técnica es mucho mayor a la técnica de K-means. Otra de las técnicas utilizada es la tecnología VNIR, la cual se basa en una cámara que generan espectros hoja media de un retorno de la inversión en lugar de todos los píxeles de la hoja. Estas técnicas fueron realizadas en diferentes pasos: HYPERCUBO (Pre-procesamiento), en el cual se realiza la segmentación de la hoja y la eliminación de la rejilla. Técnicas de extracción de características en base a índices espectrales de la hoja, la totalidad del espectro y el tema de modelos probabilísticos de VNIR y sistemas de imagen SWIR. Obteniendo como resultados a partir de las pruebas hechas a través de imágenes hiperespectrales fueron muy favorables ya que arrojaron un 90% de precisión en la detección automática de enfermedades de la planta.

(H. Li et al., 2013) "Spectral mixture analysis based citrus greening disease detection using satellite image of Florida" El problema que enfrenta esta investigación es detectar la enfermedad de los cítricos, llamada el enverdecimiento de los cítricos, de manera oportuna y la ubicación específica de esta. Para ello se utilizó el índice de vegetación normalizada, para diferenciar diferentes tipos de elementos en la superficie, luego se separó las diferentes plantas de cítricos de otras plantas y poder detectar el enverdecimiento de las plantas. Esto se logró utilizando NVDI (Índice de vegetación normalizada), máquina de vectores de soporte, VCA (Vértice de análisis de componentes), ICE (iterado consteñido detección endmember). De esto se obtuvo los siguientes resultados: de un tamaño determinado 30 píxeles fueron de árboles sanos, el 30 de infectados, 25 píxeles eran de suelo y 40 píxeles de hierba. De la presente investigación se concluyó que basado en el análisis de mezcla espectral, se desarrolló un método para detección del enverdecimiento de cítricos, se demostró que existe un gran potencial para la detección de la enfermedad mediante una imagen de satélite.

(Roa & Menses, 2014) "Automated System for Classifying Hass Avocados Based on Image Processing Techniques". Se enfrenta a un problema que es muy común, el tiempo que invertían los agricultores en la selección de paltas era demasiado, pudiendo aprovechar este tiempo en otras actividades de agricultura. Lo que se planteó hacer como solución es que se hizo un sistema automatizado para la clasificación de los aguacates, siendo el primer paso la evaluación de la madurez del aguacate, luego se hizo el filtrado. Esto fue logrado utilizando la técnica de índice de RGB (rojo, verde y azul) y la técnica de aprendizaje supervisado K-means. Los resultados que se obtuvieron fueron: mediante k-means la precisión obtenida en los resultados es de 87,85%. Confusión matriz de resultados mostraron 82,22% de precisión al determinar la madurez de los aguacates de imágenes RGB. Finalmente, como conclusión ha quedado demostrado el diseño e implementación de una herramienta computacional basado en técnicas de procesamiento digital de imágenes dirigidas para determinar la madurez de los aguacates Hass. Este tipo de herramienta podría ser utilizado para la clasificación de otros tipos de frutas como los plátanos y las semillas como los granos de café.

(H. N. Li et al., 2011) "Spectrum-based method for quantitatively detecting diseases on cucumber leaf". El problema que enfrentó esta investigación fue que se necesitan algoritmos para cada tipo de instrumento de formación de imágenes multiespectrales. En cuanto a las hojas de las plantas, que varían con el tiempo y el espacio, por lo que es difícil conseguir la reflectancia constante de la hoja y la enfermedad área. Lo que se hizo para resolver este problema es la propuesta de desarrollar un nuevo método para localizar automáticamente el área de enfermedad en hojas de pepino a través de la tecnología de imágenes multiespectrales. Esto se llevó a cabo con la clasificación de los píxeles de imagen basado en espectro pixel y cuantificación de marca de áreas de lesión. Obteniéndose, así como resultado en ambas enfermedades analizadas se obtuvieron resultados favorables siendo 80% de precisión. Concluyéndose que, con el fin de detectar cuantitativamente la distribución y el nivel de enfermedad en las hojas de pepino, un algoritmo basado en el espectro para el diagnóstico de enfermedades de la hoja fue presentado y discutido. La enfermedad de speckle y miuldu en hojas de pepino se detectan usando el método. esto demuestra que la distribución de la enfermedad y la

gravedad en la hoja pueden designarse como imágenes en gris, que coinciden con el área de la enfermedad del cubo de datos multiespectrales muy bien.

1.3 Teorías relacionadas al tema

Hass

De origen californiano. Su fruto es de forma ovalada, de mediano tamaño, pueden llegar a pesar entre 200 a 300 gr. Es de una calidad excelente, tiene piel gruesa y además es muy fácil pelarla, presenta un color que varía de verde oscuro a violeta cuando el fruto madura. Con una semilla de pequeño tamaño, de esférica forma y adherida a su pulpa, puede estar en el árbol cierto tiempo aún luego de haber alcanzado su forma madura y sin perder calidad. Esta planta no es tan resistente al frío, pero tiene una productividad alta.

Fuerte

Este tipo de aguacate tiene una coloración verde, su proveniencia tiene raíces de un árbol mexicano nativo, presenta rasgos intermedios entre la raza guatemalteca y mexicana, por ello es considerado un natural híbrido de estas 2 especies. El fruto presenta una apariencia piriforme, de mediano tamaño, tiene un peso que varía de 180 a 400 gr. La longitud se aproxima a 10 a 12 cm, en cuanto a la anchura se aproxima de 6 a 7 cm, es áspera ligeramente, es fácil que se separe de la pulpa.

Edranol

Esta planta tiene un desarrollo medio. El fruto tiene forma piriforme, de cascara rugosa, de color verde y tamaño medio, este tipo de fruta llega a pesar entre 260 a 300 gr. La pulpa tiene un muy rico y agradable sabor.

Ettinger

Este tipo de palta tiene alargada forma ovalada, de mediano tamaño, cascara de coloración verde brillante lisa y fina. Su fruto es de muy buena calidad debido a que no tiene fibra. Forma parte de las más importantes variedades de Israel, donde la superficie plantada con este tipo de palta está entre el 25% y el 30%.

Bacon

Este tipo de palta es híbrida que resulta del cruce de razas de Guatemala y México, Originaría en California, por James Bacon, este fruto puede llegar a pesar entre 138 a 340 g. su piel es delgada de color verdusco y de un sabor bueno, su fruto tiene un pálido color amarillo-verde. Esta variedad tiene un patrón a crecer fuertemente, el lugar donde sale mayor fruto es en la copa del árbol. Aunque, es muy adecuado para aquellos lugares con peligro de las heladas ya que es muy resistente a las temperaturas, incluso -4.4° , es de gran importancia resaltar su anticipada maduración en relación de otros cultivos.

Gwen

Esta ejemplar es nueva, mostrado en California, proveniente de la variedad "Hass". La productividad de este fruto parece ser mayor que la del "Hass", se considera que puede llegar a doblar y la es más rápida la fructificación en los árboles jóvenes. Puede llegar a pesar entre 40 a 60 g. más que el "Hass". Ligeramente más ovalada.

Nabal

Variedad proveniente de Guatemala, este fruto se encuentra en un proceso de sustitución por su excesivo tamaño puede llegar a pesar entre 300 a 600 g. de lisa piel y un poco gruesa, posee una coloración verde oscuro. De semilla pequeña y de forma redondeada. Su carne es amarilla, tiene un sabor agradable y casi sin fibras. Es una variedad cuya cosecha es de manera alternada, cuando tiene buenos años puede lograrse obtener cosechas excepcionales. Pero, al próximo año es muy posible que no haya ningún fruto en su planta. Es un árbol muy sensible al frío.

Plagas del palto.

La palta o aguacate es una planta que es muy poco atacada por insectos o ácaros. En el campo apenas se sabe de plagas de esta especie y sólo en cóccido *Propulvinaria piridormis* Cockerell, que normalmente se sitúa en la parte de atrás de la hoja. En California, se han detectado algunos ataques esporádicos de ácaros, como lo es el *Oligonychus punicae* Hirst (ácaro del aguacate) y el *Eotetranychus sexmaculatus* Riley, que afecta directamente a las hojas (haz y envés) que son

propensas a caer, y el trips *Heliethrips haemorrhoidalis* Bouché, que ataca a hojas y frutos, produciendo manchas coriáceas de color marrón oscuro.

Enfermedades del palto

Entre las enfermedades fúngicas más importantes que atacan al cultivo de palta son ocasionadas por *Phytophthora cinnamoni*, *Verticillium albo-atrum* y *Rosellinia necatrix*. Este hongo ataca las Raíces hasta pudrir las y el caso del *V. albo-atrum*, además, se impide que el agua pueda pasar con facilidad por el Xilema. Los síntomas que presentan en las raíces son característicos de este tipo de infecciones, y también originan marchitamiento en las hojas y dejan débil al árbol en general.

De entre los virus, la más importante en el **Sun blotch**, y que no debe ser confundidos con manchas que son producidas por los rayos del sol, está enfermedad es esta producida por un viroide que es transmitido por la semilla, por injertos o incluso a través del polen. Produce estrías longitudinales amarillas sobre brotes y hojas; en sus ramas y tronco da lugar a estrías que contrastan con la corteza lisa de los árboles sanos, el este fruto origina depresiones, estrechas y alargadas, de color amarillento, salvo en el tipo de fruto, cuya piel es de color oscura. Otras enfermedades de tipo viral, como *stem-pitting*, que ataca al tronco de la planta, *black-streak*, que produce exudaciones gomosas en las zonas de inserción de la rama, *corking*, que produce el acorchado en altas o de la corteza del fruto, *end spotting*, o manchado de la zona estilar de fruto que han sido halladas en el fruto de palta, pero con mínima importancia.


Procesamiento digital.

Inicialmente las pruebas por manipular y almacenar imágenes se dieron en 1920, justamente se desarrollaba un sistema que transmitía fotografías a con un cable transatlántico empleando códigos telegráficos. Esto no hacía cifrar una imagen en 5 niveles de gris, con el tiempo fue mejorado a 15 niveles de gris por el año 1929. Dicho sistema nos permitió reducir la transmisión de imágenes de alta índole. (Gonzales, 1987)

En ciertos casos, el procesar imágenes se realiza mejor a través de transformar las imágenes que ingresan, transportando una tarea determinada a un área de la transformada, y la colocación inversa de la transformada para regresar al área espacial. La clase peculiarmente importante de transformación lineal 2-d, T expresado (u, v) , se puede denotar con la forma general

$$T(u, v) = \sum_{X=0}^{M-1} \sum_{Y=0}^{N-1} f(x, y)r(x, y, u, v)$$

(Leemans, Magein, & Destain, 1998) nos dice que para $f(x, y)$ es la figura de entrada, llamada “*el núcleo de transformación hacia adelante*”. Valorada a $u = 0, 1, 2, \dots, M - 1$ y $v = 0, 1, 2, \dots, N - 1$. Igual que anteriormente, X e Y son “*valores espaciales*”, durante que M y N son las medidas de columnas y filas de la variable f . los valores u y v se le dice “*transformadas variables*”. $T(u, v)$ se hace “*llamar transformada directa*” de $f(x, y)$. dado $T(u, v)$, se puede rescatar $f(x, y)$ utilizando la inversa transformada de $T(u, v)$,



donde $x=0, 1, 2, \dots, M-1$ y $Y=0, 1, 2, \dots, N-1$, para $s(x, y, u, v)$ es llamado “*El núcleo de transformación inversa*”.

La vista es tal vez el sentido más avanzado que poseemos, así que no es de sorpresa que las imágenes tengan un rol muy importante en la captación del ser humano.

Aun nosotros sólo podemos ver el espectro visible de la banda electromagnética, las maquinas creadas por el hombre pueden percibir el resto de bandas o mejor dicho pueden percibir el espectro completo. Las maquinas también pueden procesar imágenes.

Los autores no han llegado a un consenso para decidir el alcance del procesar imágenes digitalmente y donde es que inician otros terrenos. En esta presente definición consideremos 3 tipos de proceso:

Proceso de bajo nivel:

En este proceso se utilizan algoritmos como el procesamiento de imágenes para reducir el ruido, mejorar el contraste y filtros.

Se caracterizan porque sus entradas y salidas son Imágenes.

Proceso de nivel medio:

Se utilizan algoritmos para segmentar y clasificar objetos individualmente.

Es caracterizado porque las imágenes son sus entradas, mas sus salidas son variables extraídas de esas figuras

Proceso nivel alto:

Implicada a tener algún significado de un objeto distinguido, analizar imágenes y, por último, hacer las funciones intelectuales relacionadas con el aspecto.

Machine learning

También Llamado inteligencia artificial, es definida como la ciencia que busca que los computadores tomen decisiones sin la necesidad de ser programadas para realizar un acto explicito (Andrew, 2018), en otras palabras Machine Learning es aprender de los datos almacenados mediante la programación de computadoras (Russell, 2018)

Machine learning y sus tipos de aprendizaje

Supervisados

Este aprendizaje se lleva a cabo con la información que están incluidas en las soluciones. Se sub dividen en 2 tareas, la tarea de clasificación y regresión. La primera hace que el algoritmo de aprendizaje pueda separar los datos ingresados en categorías, por otro lado, la segunda hace que la red pueda establecer un dato numérico. Por ejemplo, se toma la foto de un gato y se ingresa al clasificador y se le ordena que la respuesta que tome sea “gato” en tanto la regresión como ejemplo, sería llenar datos de partes de un carro para que el precio del carro sea predicho. (Géron, 2017).

(Géron, 2017) nos afirma que “uno de los algoritmos más utilizados de este tipo es el de redes neuronales”.

No supervisados

Lo que hace la diferencia con los sistemas supervisados, es que a este no se les introduce respuestas anticipadas. Lo que se busca hacer es que entre los mismo se encuentren relaciones, identificando variables independientes (Géron, 2017).

Un ejemplo claro de este tipo de algoritmos es el *K-means* y PCA (*Principal Components Analysis*)(Géron, 2017).

Redes Neuronales

Las redes Neuronales artificial trata de emular el funcionamiento de las redes neuronales fisiológicas a través de interconexiones de neuronas hechas por computadoras. En una red neuronal, una sola neurona hecha por computadora es la mínima cantidad de procesamiento. La activación o cambios de una neurona depende de las entradas que recibe. Estas activaciones o cambios se dan mediante señales, las cuales pueden ser recibidas desde las mismas neuronas que están conectadas a la red o desde el exterior, para realizar el cálculo de los cambios o niveles de activación, se calcula primero las entradas totales que recibe la neurona y este valor es calculado haciendo una sumatoria total de las entradas ponderadas. (Isasi Viñuela & Galván León, 2004). Si esta suma supera el umbral determinado, se aplica al producto obtenido de dicha suma la función de activación, para así sólo tener una salida única.(Géron, 2017).

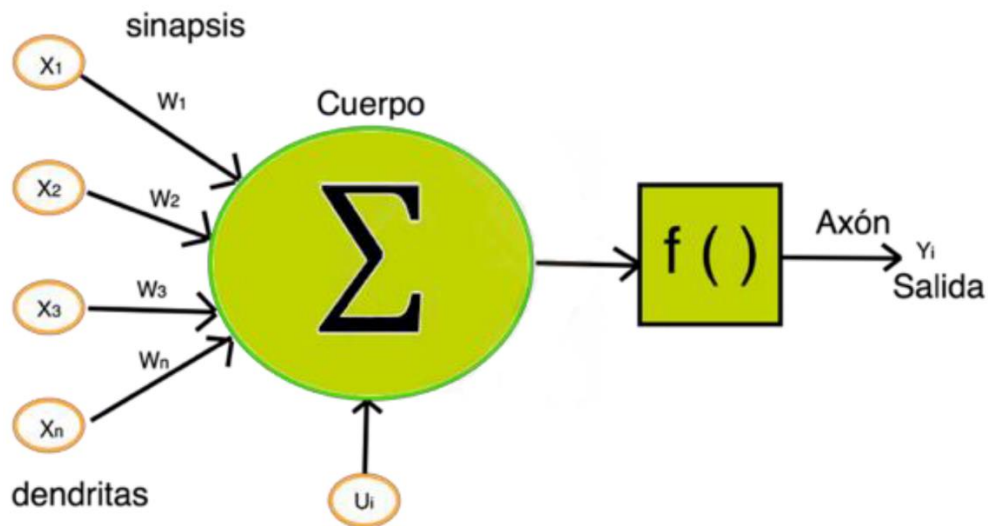


Figura 5. Topología de una neurona artificial.

Copyright 2018 por Utilización de redes neuronales convolucionales para la detección de tipos de imágenes

Las redes neuronales pueden tener sólo una capa o ser multicapa, las de una capa tienen una sola neurona, que es la encargada de procesar N entradas. Por otro lado las multicapa tienen muchas neuronas las cuales reciben N entradas, el resultado de esto, es pasado a otro grupo de neuronas que tiene nivel superior para que sean procesadas. Es posible que existan varios grupos de neuronas que dependan de resultados de anteriores niveles para que los datos recolectados fluyan por cada uno de estas para así tener en la red un producto final. En cualquier de las casuísticas cada una de las neuronas resuelve su propia función de activación que pueden llegar a ser diferentes al resto. Para la casuística en que las redes neuronales sean supervisadas y no cumplan con el umbral establecido, el resultado será considerado como correcto y de no ser así, se vuelven a calcular los pesos de los nodos back-propagation. (Hatle, Robert, & Jerome, 2008)




Figura 6. Ilustración del concepto de la red neuronal de una capa




Figura 7. Ilustración del concepto de la red neuronal con capa oculta.

Copyright 2018 por Utilización de redes neuronales convolucionales para la detección de tipos de imágenes

Redes Neuronales Convolucionales

Este tipo de redes se originó de un estudio realizado por David. H. Hubel y Torsten Wiesel, sobre la corteza visual en gatos. Ellos lograron demostrar que en la corteza visual hay conjuntos de neuronas poseedoras de un campo receptivo local. Los campos receptivos están definidos como área limitada en el espacio. Todos los conjuntos de neuronas de la corteza visual tienen como punto de enfoque un área

diferente del campo. Lo que conlleva a que existan varios campos receptivos que tiene la capacidad de sobreponerse y dar forma de un mosaico al campo visual completo. Estos campos receptivos determinarán las cualidades para la búsqueda de un objeto para que así se pueda definir en que consiste. Se identificó también que algunos conjuntos de neuronas tienen campos receptivos más amplios y responden a modelos más complejos, los cuales son el producto de mezclar modelos de niveles inferiores. Este estudio conllevó que se tenga la idea de que los conjuntos de neuronas de niveles bajos, tienen como base a los resultados que se obtuvieron previamente de los conjuntos de neuronas de niveles (Géron, 2017).

Lo más importante para el reconocimiento de imágenes es construir la capa convolucional que es la encargada de cotejar modelos de imágenes con la finalidad de ver su similitud.

Convolución

Es un proceso matemático que desplaza a una función por sobre otra y va midiendo en intervalo por intervalo que contenida se encuentra una función en la otra (Christian, Vincent, Ioffe, Jonathon, & Zbigniew, 2015).

$$y(t) = \int_{-\infty}^{+\infty} f(n) \cdot g(t-n) \cdot d_n$$




Figura 8. Representación gráfica de una convolución.

Copyright 2018 por Utilización de redes neuronales convolucionales para la detección de tipos de imágenes

La función f que está de color rojo y la función g está de color azul. El área verde que está de color verde muestra la superposición de ambas funciones, mientras que las líneas azules representan el tiempo t .




Figura 9. Ejemplo de una convolución

Copyright 2018 por Utilización de redes neuronales convolucionales para la detección de tipos de imágenes

se tienen las funciones f de color azul y la función g de color rojo, g se desplaza en el tiempo y se superpone con f . En el primer paso la función g comienza a tocar a la función f . en el siguiente paso la función g se sigue superponiendo con f por la izquierda lo que genera el área de color marrón. En el paso 3 la función g es la que se superpone con la función f que genera la misma superposición, siendo resultado espacio de color azul. Como último paso, donde la función g deja de superponerse con la función f .

Capas de una red neuronal convolucional

Capa convolucional

Es en esta capa donde se aplican filtros para la convolución de la imagen con el fin de lograr hallar la característica del modelo que aplica con más fuerza.

En la primera capa convolucional las neuronas no están conectadas a cada pixel de la imagen de entrada, sino que están conectadas a cada pixel de su campo receptivo. A si mismo en la segunda capa convolucional cada neurona se encuentra conectada con un rectángulo de la capa superior. Permitiendo a la red concentrarse en conceptos más pequeños para luego ser ensamblados en conceptos aún más

grandes para la capa convolucional siguiente y así hasta la última capa convolucional (Géron, 2017).




Figura 10. Capas de convoluciones.

Copyright 2018 por Utilización de redes neuronales convolucionales para la detección de tipos de imágenes

La capa Convolutiva funciona estableciendo un área de análisis que se mueve de lugar a otro hasta haber recorrido toda la imagen. Se realiza un conjunto de operaciones matemáticas por cada movimiento, para producir un valor único y se aplica la función de activación ReLu para así introducir valores no lineales dentro del modelo (Géron, 2017).

La función de activación de ReLu (Rectifier Linear Unit), consiste básicamente en quedarse con los valores positivos de la entrada. Lo que significa que, dado el número de X , la función devuelve el máximo de x y 0 . Cuanto más grandes sean los valores que se obtienen la característica buscada será más parecida.

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




Figura 11. Ejemplificación de la función de ReLU. Donde se consideran a los valores de color blanco como positivos y a los valores de color negro como negativos

Copyright 2018 por Utilización de redes neuronales convolucionales para la detección de tipos de imágenes

Una imagen está conformada por una matriz de píxeles que puede llegar a tener 16777215 colores. Una convolución se encarga de comparar la imagen original con la imagen de una característica. Para esto, se toma un campo receptivo - generalmente de 7x7 o 5x5 píxeles.

1	1	1	0	0
0	1	1	1	0
0	0	1	1	1
0	0	1	1	0
0	1	1	0	0

Figura 12. Imagen de 5x5 píxeles con valores 0 y 1. Donde se aplicará una convolución con figura siguiente

1	0	1
0	1	0
1	0	1

Figura 13. Campo receptivo que se convolucionará con la figura anterior.

Va moviéndose de la esquina superior izquierda hasta la esquina inferior derecha de las 2 imágenes y va calculando la similitud de ambas a cada paso. Es muy

importante realzar que el recorrido de dicha sección se realiza superponiendo la mitad de la ubicación nueva con la mitad de la anterior ubicación con el propósito de reducir la pérdida de datos que pueda ocurrir en la transición entre ambas.




Figura 14. Paso 01 de una convolución. Donde se observa la superposición de la imagen naranja sobre la verde siendo el resultado de convolución el valor 4 sugerido en la siguiente ecuación.

$$conv = 1 \times 1 + 1 \times 0 + 1 \times 0 + 0 \times 0 + 1 \times 1 + 1 \times 0 + 0 \times 1 + 0 \times 0 + 1 \times 1 = 4$$

Continuando con la superposición ahora esta se realiza en la parte media de la imagen de 5 x 5 pixeles y continua en su búsqueda de encontrar similitudes entre ambas.

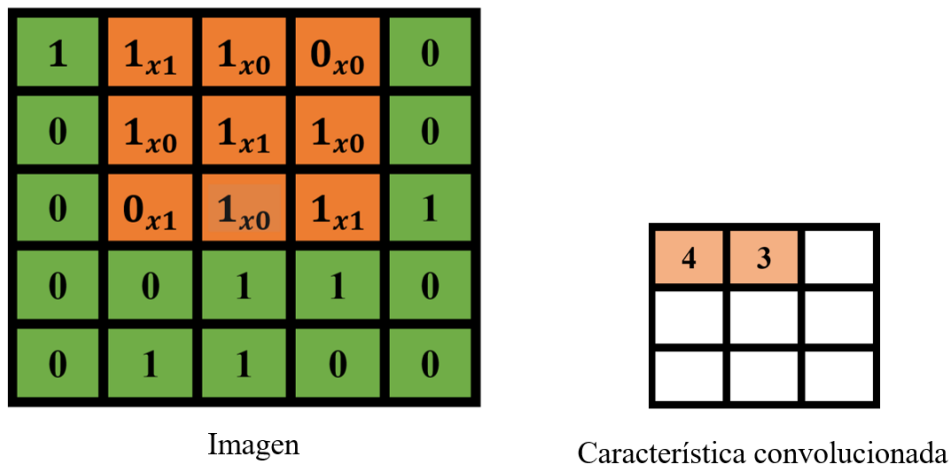


Figura 15. Paso 02 de una convolución. donde se observa el desplazamiento en 1 pixel de la imagen naranja sobre la imagen verde dando como valor de convolucion el valor 3 que arroja de la siguiente ecuacion.

$$conv = 1 \times 1 + 1 \times 0 + 0 \times 1 + 1 \times 0 + 1 \times 1 + 1 \times 0 + 0 \times 1 + 1 \times 0 + 1 \times 1 = 3$$

La convolución continua hasta obtener el siguiente valor

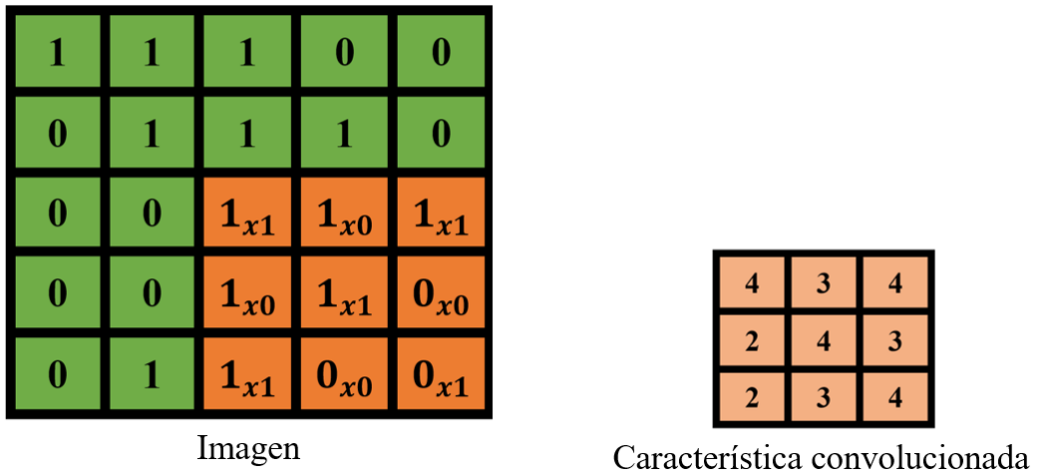


Figura 16. Resultado de una convolución. Donde se aprecia, una imagen de 5x5 pixeles se trasformó en una de 3x3.

Dicho ejemplo de convoluciones arroja como resultado:




Figura 17. Ejemplo de imagen a convolucionar con valores en escala de grises que van de 0 a 255

Copyright 2018 por Utilización de redes neuronales convolucionales para la detección de tipos de imágenes

Luego de aplicada la convolución se obtiene la matriz de valores siguiente.

0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	1	12	0	11	39	137	37	0	152	147	84	0	0
0	0	1	0	0	0	41	160	250	255	235	162	255	238	206	11	13
0	0	0	16	9	9	150	251	45	21	184	159	154	255	233	40	0
10	0	0	0	0	0	145	146	3	10	0	11	124	253	255	107	0
0	0	3	0	4	15	236	216	0	0	38	109	247	240	169	0	11
1	0	2	0	0	0	253	253	23	62	224	241	255	164	0	5	0
6	0	0	4	0	3	252	250	228	255	255	234	112	28	0	2	17
0	2	1	4	0	21	255	253	251	255	172	31	8	0	1	0	0
0	0	4	0	163	225	251	255	229	120	0	0	0	0	0	11	0
0	0	21	162	255	255	254	255	126	6	0	10	14	6	0	0	9
3	79	242	255	141	66	255	245	189	7	8	0	0	5	0	0	0
26	221	237	98	0	67	251	255	144	0	8	0	0	7	0	0	11
125	255	141	0	87	244	255	208	3	0	0	13	0	1	0	1	0
145	248	228	116	235	255	141	34	0	11	0	1	0	0	0	1	3
85	237	253	246	255	210	21	1	0	1	0	0	6	2	4	0	0
6	23	112	157	114	32	0	0	0	0	2	0	8	0	7	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Figura 18. Matriz resultante de la convolución realizada en escala de grises.

Copyright 2018 por Utilización de redes neuronales convolucionales para la detección de tipos de imágenes

Capa pooling o sampling

Esta capa es la encargada de hacer que las dimensiones del resultado que se obtuvieron de la capa convolucional se reduzcan y también reducir el tiempo de procesamiento. Al igual que anteriormente las neuronas en esta capa se conectan con un limitado número de neuronas de la capa anterior a esta que a su vez tienen reducido un campo reducido. El algoritmo que más se utiliza es **max-pooling** (Géron, 2017).




Figura 19. Funcionamiento de la capa pooling.




Figura 20. Ejemplificación del funcionamiento de la capa pooling en una fotografía. Se toma regiones de 2 x 2 píxeles y las reduce tomando el máximo valor de cada una.

Copyright 2018 por Utilización de redes neuronales convolucionales para la detección de tipos de imágenes

Capa Densa o fully connected

Se le denomina densa porque todos los nodos están conectados entre sí y su finalidad es realizar la clasificación de la imagen basándose en los resultados de las anteriores capas.

El modelo RGB.

En RGB, todos los colores aparecen en los elementos básicos el espectro azul, rojo y verde. Dicho ejemplo está basado en un procedimiento de ejes cartesianas que forman un cubo cuya estimación de RGB se encuentran en las partes límites. Amarillo, cian y magenta son los valores que se encuentran en esas 3 esquinas ya mencionadas con anterioridad, el negro que es el que está en el origen y el blanco que está en las esquinas más alejadas.




Figura 21. Representación gráfica del esquema de un cubo RGB a 24 bits.

Copyright 2005 de Procesamiento Digital de Imágenes (Vilet, 2005)

La cantidad utilizada de bits para cada pixel sea representada en el modelo RGB tiene como nombre “*profundidad de pixel*”.

Considere que una figura en la que cada una de las figuras verde, azul y roja es una figura que tiene 8 bits. De esto se considera a cada uno de pixeles de color RGB tiene 24 bits de profundidad. Una figura de 24 bits con RGB tiene un total de colores de $(2^8)^3 = 16,777,216$.

1.4 Formulación del Problema

¿En qué medida la técnica de redes neuronales convolucionadas permitirá detectar la presencia de la enfermedad *lasiodiplodia theobromae* en el palto?

1.5 Justificación e importancia del estudio

Justificación Tecnológica

La presente tesis está justificada por el avance tecnológico, para hacer uso del procesamiento de imágenes multispectrales para detectar enfermedades en árboles. Debido a que los métodos empleados para detectar la enfermedad de la Muerte regresiva, tienen como resultados bajos porcentajes en la detección del *lasiodiplodia theobromae*.

1.1.1. Justificación Económica

La elaboración de esta tesis está justificada económicamente debido a la necesidad de hacer la detección de esta enfermedad en grandes terrenos de cultivo, utilizando procesos químicos o de biología molecular, debido a que estos tipos de procesos son costosos y sólo se pueden utilizar en pequeños volúmenes de muestra. Es por lo que la detección de estas enfermedades utilizando las imágenes multispectrales abarcará grandes masas y utilizando costos mucho más reducidos.

Justificación Ambiental

La realización de esta tesis no tiene ninguna colisión con el medio ambiente.

Importancia

Uno de los motivos por los que la presente tesis es importante es para que sirva como antecedente para futuras investigaciones. Es importante también debido a que hoy en día existe una gran necesidad de implementación de técnicas precisas y eficientes en el terreno de la agricultura, que permitirá reducir gastos y pudiendo facilitar la existencia o no existencia de enfermedades en el palto, incrementando de esta manera la producción.

1.6 Hipótesis

La técnica de redes neuronales convolucionales detecta la presencia de la enfermedad *lasiodiplodia theobromae* de palto con un alto grado de precisión.

1.7 Objetivos

1.7.1 Objetivos General

Identificar la enfermedad de *lasiodiplodia theobromae* en Paltos utilizando imágenes digitales con redes neuronales convolucionales.

1.7.2 Objetivos Específicos

- Adquirir imágenes digitales en campo del tallo del palto.
- Caracterizar visualmente la enfermedad *lasiodiplodia Theobromae* en las imágenes digitales.
- Pre-procesar imágenes digitales de los tallos del palto.
- Elaborar el dataset para entrenamiento y procesamiento de las imágenes digitales de los tallos del palto.
- Implementar la técnica de procesamiento de imágenes para detectar la presencia de la enfermedad.

II. MATERIAL Y MÉTODO

2.1 Tipo y Diseño de Investigación

Tipo de Investigación

Esta investigación está basada en la metodología cuantitativa; se eligió esta metodología debido a que los indicadores están representados en cantidades numéricas. (Hernández, Fernández y Baptista, 2010) comentan la metodología cuantitativa, para poder demostrar su hipótesis utilizan la recolección de datos, basados en medir numéricamente y analizar estadísticamente, para así poder establecer diferentes patrones de comportamiento y también así poder demostrar teorías, también indican que dicho enfoque es de tipo probatorio y secuencial, cada una de las etapas proviene de una anterior y no podemos saltarnos pasos, el orden en el que se desarrolla debe ser riguroso.

Diseño de la investigación

Para esta investigación el abordaje metodológico que se eligió fue del subtipo cuasi – experimental. Tal como lo indica Campbell (1986) donde nos comenta que se puede diferenciar los experimentos verdaderos de los cuasiexperimentos, debido a la falta de asignación casual de los valores unitarios a los métodos

2.2 Población y muestra.

Población

Determinada por todos los algoritmos de aprendizaje automático utilizados en trabajos previos y similares para la clasificación de la enfermedad de manera correcta.

Muestra

La muestra de la investigación es no estadística por conveniencia, donde se toma en cuenta el algoritmo de redes neuronales convolucionadas para el reconocimiento de la enfermedad

2.3 Variables, Operacionalización

Variable independiente

Redes neuronales convolucionales

Variable dependiente

Detección automática de la enfermedad lasiodiplodia theobromae del palto.

Operacionalización

Tabla 1

Operacionalización de las variables de investigación

Variable Independiente	Dimensiones	Indicadores	Unidad de medida	Formula	Descripción	Técnica e instrumento de recolección de datos
Redes Neuronales Convolucionales	Tiempo	Tiempo de Procesamiento	Seg.	$T = T_i - T_f$	T = Tiempo total Ti = Tiempo inicial Tf = Tiempo final	Observación, ficha Técnica
Variable Independiente	Dimensiones	Indicadores	Unidad de medida	Formula	Descripción	Técnica e instrumento de recolección de datos
Detección de la enfermedad Lasiodiplodia Theobromae.	Eficiencia	Precisión	%	$P = \frac{(VP + VN)}{Total\ Imágenes}$	P = Precisión VP = Verdadero positivo VN = Verdadero negativo	Observación, ficha Técnica
		Exactitud		$E = \frac{VP}{VP+FN}$	E = Exactitud VP = Verdadero positivo FN = Falso Negativo	
		Sensibilidad		$S = \frac{VP}{VP+FN}$	S = Sensibilidad VP = Verdadero positivo FN = Falso Negativo	
		Especificidad		$Es = \frac{VN}{VN+FP}$	Es = Especificad VN= Verdadero negativo FP = Falso Positivo	

2.4 Técnicas e instrumentos de recolección de datos, validez y confiabilidad

Para la recolección de datos se usará la siguiente técnica:

Observación

Es la anotación óptica de lo que está ocurriendo en una real situación, consignando y clasificando los hechos prudentes siguiendo alguna maqueta prevista y según estudio del problema.

El instrumento para que los datos sean recolectados se utilizó con la siguiente técnica:

Ficha de observación

Es tomada como un proceso para la investigación, básicamente consiste en la utilización de los elementos adecuados para así realizar un lazo entre los hechos reales y la hipótesis, mediante la investigación ordenada y sistematizada y la observación científica.

Las herramientas que emplea este procedimiento para poder describir detalladamente los elemento observados e investigados, también se dice que este instrumento nos posibilita la recolección de datos, centrándose en un objetivo particular, para que así se determinen valores específicos.

2.5 Procedimientos de análisis de datos

Basándonos en la recolección de datos, con esta técnica se detallará las siguientes consideraciones:

En la primera fase se adquirieron las imágenes que fueron tomadas con la cámara canon. Para fase dos se realizó la caracterización visual de la enfermedad lasiodiplodia *Theobromae* en las imágenes digitales. En la tercera fase se realizó el pre-procesamiento de las imágenes digitales de los tallos del palto. Para la cuarta se realizó la elaboración del dataset para entrenamiento y procesamiento de las imágenes

digitales de los tallos del palto. En la fase quinta se implementará la técnica de procesamiento de imágenes para detectar la presencia de la enfermedad. Como última fase y no menos importante se evaluaron resultados.

Plan de análisis estadísticos de datos

La estimación de las técnicas utilizadas en cada prueba, se calcularon con las fórmulas matemáticas siguientes:

a) Precisión

Es el diagnóstico correcto del total de las muestras proporcionadas.

$$\frac{\left(\sum_{i=1}^M \frac{TP_i}{TP_i + FP_i}\right)}{M}$$

b) Sensibilidad

Marca la cantidad de luz que se necesita para hacer una fotografía se traducirá en un aumento de pixeles distribuidos al azar

$$\frac{\left(\sum_{i=1}^M \frac{Tp_i}{TP_i + FN_i}\right)}{M}$$

c) Severidad

Porcentaje de área de tejidos cubiertas con síntomas.

$$\frac{\sum_{i,j} p(i,j)}{T(i,j)} \times 100$$

2.6 Criterios éticos

Derechos de autor: El instrumental utilizado en el desarrollo de esta investigación estuvo correctamente citado y referenciado con sus correspondientes propietarios como integrante de la investigación.

Confidencialidad: Protege y asegura la autenticidad de sus fuentes, de la misma forma a los involucrados que participaron como informadores en la investigación.

2.7 Criterios de Rigor científico.

Fiabilidad

Esta investigación cumplió con las perspectivas que fueron explicadas en el argumento y la realización con las políticas y estándares para su ejecución.

Validez

La información recopilada en esta investigación fue analizada y evaluada minuciosamente por los especialistas en el asunto con la finalidad de confirmar la verdad de los resultados.

Consistencia

La investigación presentó elementos coherentes y fueron certificados por la sociedad de científicos.

III. RESULTADOS

3.1 Resultados en Tablas y Figuras

Para mostrar los resultados de las pruebas de la clasificación automática, fue utilizada una matriz de confusión presentada con anterioridad, de tal manera que se calculó la precisión, exactitud, sensibilidad, especificidad, tiempo de procesamiento. Teniendo en cuenta que para la obtención de resultados se utilizó un ordenador cuyas especificaciones son: Intel (R) Core (TM) i7-6700HQ CPU @ 2.60GHz, 12 GB RAM, tarjeta gráfica NVidia GeForce GTX 960M de 4gb con sistema operativo Windows 10 de 64 bits.

Para el cálculo de del tiempo de entrenamiento el modelo fue entrenado con 480 imágenes. Tomando en cuenta que el entrenamiento inició a las 4:45 pm con 37 segundos y finalizó a las 5:00 pm con 40 segundos el tiempo total del procesamiento en la fase de entrenamiento se midió de la siguiente manera:

$$T_{procesamiento} = t_{final} - t_{inicial}$$

$$T_{procesamiento} = 5:00:40 - 4:45:37$$

$$T_{procesamiento} = 0:15:03$$

Obteniendo como resultado 15 minutos con 03 segundos para la fase de entrenamiento de la imagen.

La primera prueba se realizó con 152 imágenes que fueron distribuidas de tal manera que 80 imágenes sean tallos enfermos y 72 imágenes sean tallos sanos. De la clasificación se obtuvo que verdaderamente eran positivos 71 y falsamente positivos era 1. Se encontró 3 falsos negativos, y se encontraron 77 imágenes que eran verdaderamente negativo.

Tabla 2

Matriz de confusión de resultados obtenidos en la fase de prueba.

TOTAL = 152		Resultados de Clasificación	
		SANO	ENFERMO
Resultados reales	SANO	VP = 69	FN = 3
	ENFERMO	FP = 1	VN = 79

A partir de esta matriz de confusión se evalúan los siguientes indicadores:

Precisión

$$P = \frac{VP + VN}{Total\ Imágenes}$$

$$P = \frac{69 + 79}{152}$$

$$P = 0.97$$

Este modelo en la etapa de pruebas obtuvo una precisión de 0.97, es decir, cuando predice que un tallo está enfermo o un tallo está sano, acierta en un 97% de las veces.

Exactitud

$$E = \frac{VP}{VP + FN}$$

$$E = \frac{69}{69 + 3}$$

$$E = 0.95$$

La exactitud en la etapa de pruebas arrojó 0.95%. Eso significa que, de las 152 imágenes sometidas, 72 imágenes de tallos sanos y 80 tallos enfermos. De las 72 imágenes de tallos que no están enfermos, el modelo identificó correctamente 69 imágenes de tallos como sanas. Por otro lado, de 80 objetos que están enfermos, el modelo identificó correctamente 79 como enfermos. Esto es un resultado muy bueno ya que identificó 79 enfermas a las imágenes que en realidad estaban enfermas y 3 como enferma cuando en realidad estaban sanas.

Sensibilidad

$$S = \frac{VP}{VP + FN}$$

$$S = \frac{69}{69 + 3}$$

$$S = 0.95$$

El modelo propuesto arrojó en la etapa de pruebas una sensibilidad de 0.95. Es decir, identifica correctamente 95% de imágenes de tallos sanos.

Especificidad

$$Es = \frac{VN}{VN + FP}$$

$$Es = \frac{79}{79 + 1}$$

$$Es = 0.98$$

En la etapa de pruebas el modelo propuesto obtuvo 0.98 de especificidad. Esto quiere decir que hay un 98% que el clasificador determine que un tallo es sano cuando la enfermedad está ausente en una imagen.

La etapa de validación fue realizada con 152 imágenes que fueron distribuidas de tal manera que 80 imágenes sean tallos enfermos y 72 imágenes sean tallos sanos. De la clasificación se obtuvo que verdaderamente eran positivos 69 y falsamente positivos

eran 3. Se encontraron 3 falsos negativos y se encontraron 79 imágenes que eran verdaderamente negativo.

Tabla 3

Matriz de confusión de resultados obtenidos en la fase de validación.

TOTAL = 168		Resultados de Clasificación	
		SANO	ENFERMO
Resultados reales	SANO	VP = 77	FN = 3
	ENFERMO	FP = 1	VN = 87

A partir de esta matriz de confusión se evalúan los siguientes indicadores:

Precisión

$$P = \frac{VP + VN}{Total\ Imágenes}$$

$$P = \frac{77 + 87}{168}$$

$$P = 0.98$$

Este modelo en la etapa de validación obtuvo una precisión de 0.98, es decir, cuando predice que un tallo está enfermo, acierta en un 98% de las veces.

Exactitud

$$E = \frac{VP}{VP + FN}$$

$$E = \frac{77}{77 + 3}$$

$$E = 0.96$$

La exactitud en la etapa de validación arrojó un 96 o 96%. Eso significa que, de las 168 imágenes sometidas, 88 imágenes de tallos enfermos y 80 tallos están sanos. De las 80 imágenes de tallos que no están enfermos, el modelo identificó correctamente 77 imágenes de tallos como sanas, esto es muy bueno. Por otro lado, de 88 imágenes que están enfermos, el modelo identificó correctamente 87 como enfermos, esto es un resultado excelente ya que identificó como enfermas casi todas las imágenes que en realidad estaban enfermas a excepción de una.

Sensibilidad

$$S = \frac{VP}{VP + FN}$$

$$S = \frac{77}{77 + 3}$$

$$S = 0.96$$

El modelo propuesto arrojó en la etapa de validación una sensibilidad de 0.96. Es decir, identifica correctamente el 96% de imágenes de tallos sanos.

Especificidad

$$Es = \frac{VN}{VN + FP}$$

$$Es = \frac{87}{87 + 1}$$

$$Es = 0.98$$

En la etapa de validación el modelo propuesto obtuvo 0.98 de especificidad. Esto quiere decir que hay un 98% que el clasificador determine que un tallo es sano cuando la enfermedad está ausente en una imagen.

De los resultados de las pruebas y la validación que se obtuvieron anteriormente, se concluyó que en ambas fases el comportamiento de los resultados en cuanto a la precisión fue similar dándose un 1% de diferencia. En cuanto a la exactitud se pudo observar que hay una diferencia de 2% en la fase de prueba con respecto a la fase de validación. Para la sensibilidad se observó la diferencia de 2% en la fase de prueba con respecto a la fase de validación. En cuanto a la especificidad se observó que son similares en ambas fases respecto de la fase de pruebas.

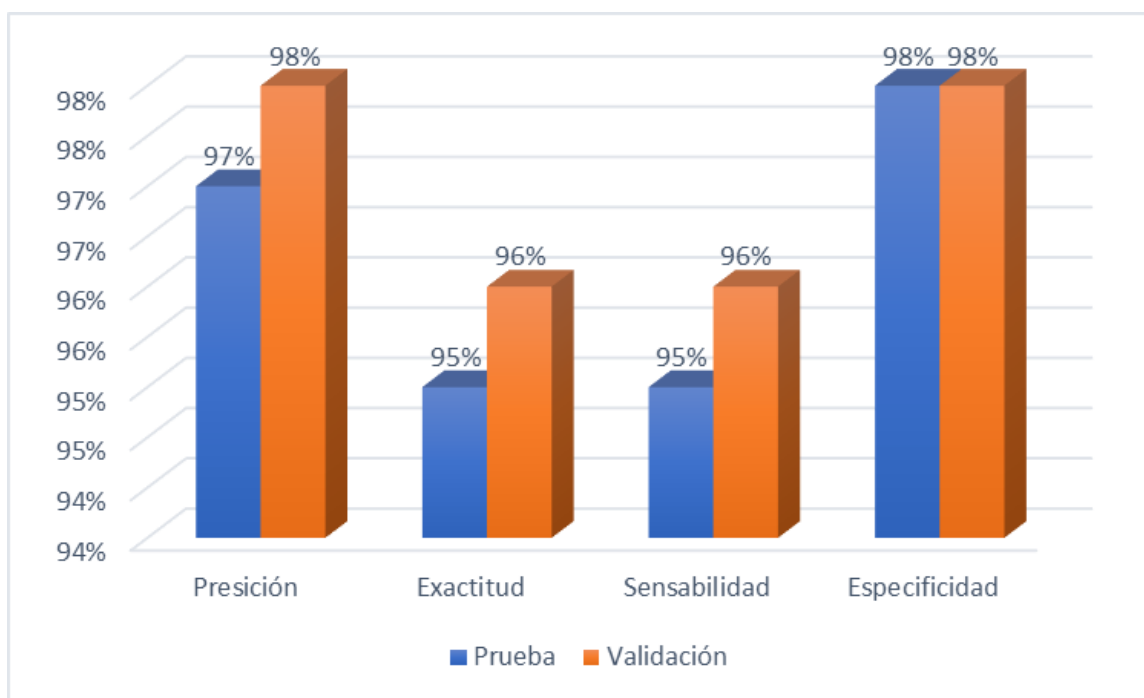


Figura 22. comparación entre los resultados obtenidos en pruebas y validación.

3.2 Discusión de resultados

Para la discusión de resultados se realizó la comparación con los resultados que fueron obtenidos de la investigación “Identification of Lasiodiplodia Theobromae in avocado trees through image processing and machine learning” (Flores et al., 2020) donde de 30 muestras en fase de validación arrojó como resultados un 93% de precisión, 100% de exactitud, 100% de sensibilidad y 83% de especificidad. En comparación con la presente investigación, se dedujo que en la precisión hay una diferencia de 5% con respecto de la investigación de Flores. Los resultados de la

exactitud y sensibilidad fueron tuvieron una diferencia de 4%. En cuanto a la especificidad se observó una importante diferencia de 5% de diferencia de la presente investigación con respecto de la investigación comparada.

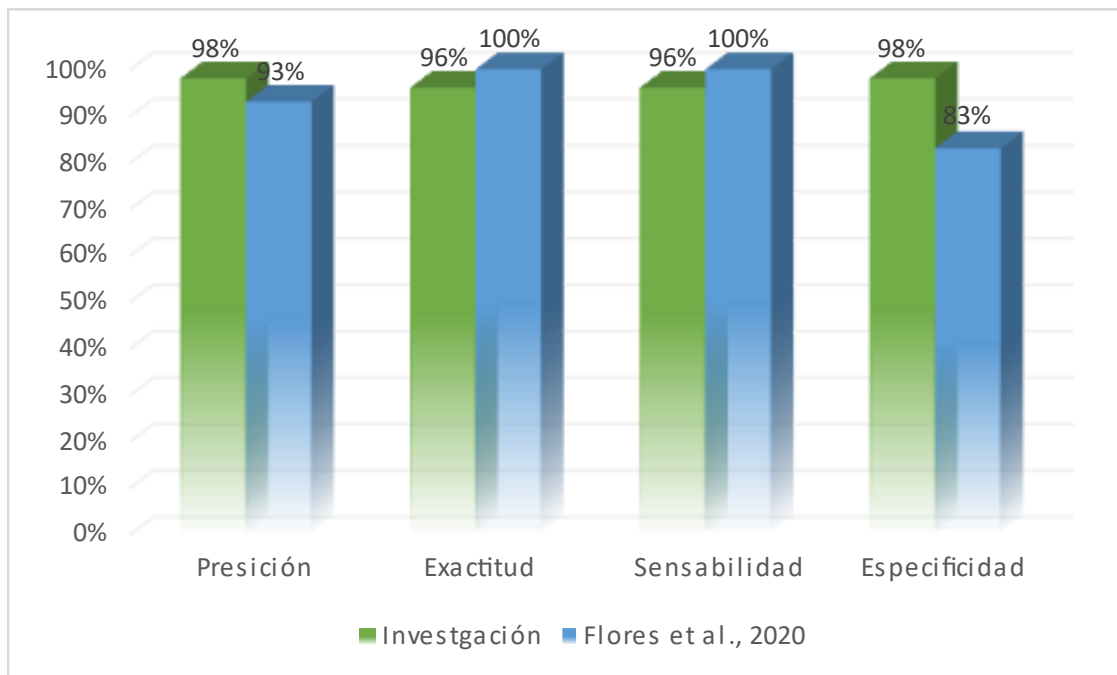


Figura 23. Comparación de resultados obtenidos en la presente investigación y la investigación de (Flores et al., 2020).

De la comparación que se realizó anteriormente se dedujo que la presente investigación es más precisa ya que cuando predice que un tallo es sano, acierta un 98% de las veces. El modelo comparado es menos exacto al de la investigación presente, lo que quiere decir que esta investigación realiza la predicción correctamente en un 98%, dando como sanos a los que eran sanos y dando como enfermos a los que eran enfermos. También se dedujo que el modelo comparado menos sensible que el de la presente investigación en un 4%. La investigación presente es menos específica, ya que el modelo de la investigación comparada obtuvo un 83% de especificidad, esto quiere decir que el clasificador determinó que un tallo es sano cuando la enfermedad está ausente en una imagen.

3.3 Aporte práctico

En esta investigación, el método propuesto fue estructurado en 5 pasos. Inició en la adquisición de imágenes del tallo del palto en un ambiente no controlado. En la parte segunda se realizó una revisión de la literatura para conocer las características principales de la enfermedad. En el tercer paso se pre procesaron las imágenes para corregir defectos que en estas se encontraban, así como también resaltar zonas de interés. Para la cuarta fase se elaboró el dataset con el repositorio de imágenes anteriormente obtenidas. En la quinta y última fase se implementó la técnica de procesamiento de imágenes.

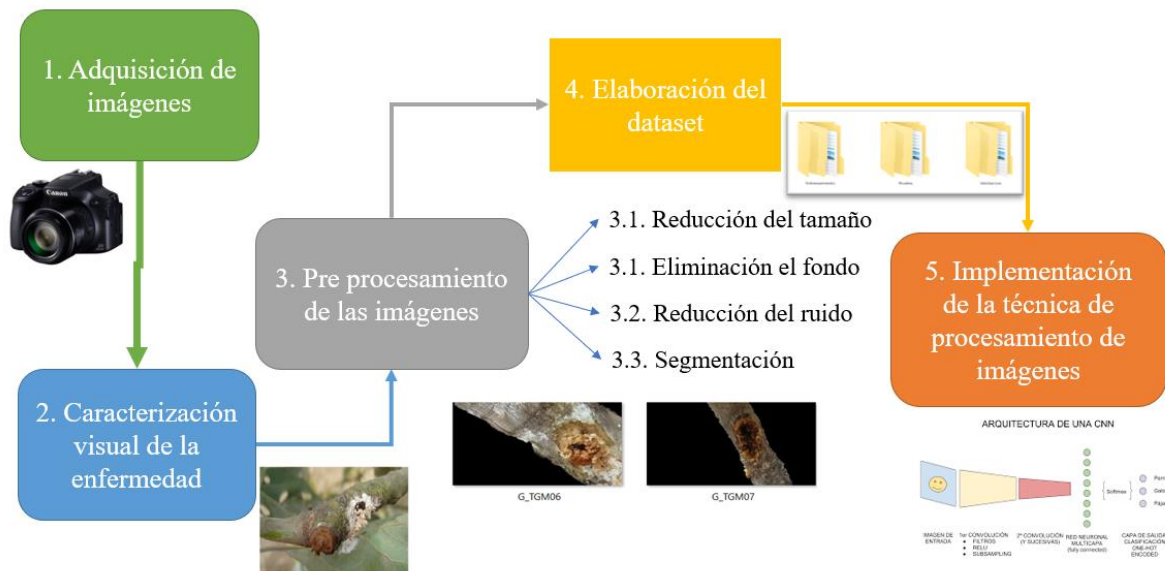


Figura 24. Método propuesto de la investigación.

Adquisición de imágenes digitales en campo del tallo del palto

Para la adquisición de imágenes digitales se logró la colaboración de la asociación de palta Hass “Augusta López Arenas” ubicándose en el distrito de Pítipo, provincia de Ferreñafe, Departamento de Lambayeque cuyas coordenadas son -6.560002, -79.777984. luego se estableció un riguroso protocolo con los siguientes pasos: En un ambiente no controlado, se consideró una distancia prudente de 20 cm entre la zona afectada y la lente, con ángulos distintos ya que según (Antón et al., 2020) la toma

desde varios ángulos hace que la imagen tenga nuevas características, la distancia fue controlada con una regla graduada de 30 cm, siendo útil para la toma de imágenes una cámara de marca canon semiprofesional, modelo SX50 HS de 12.1 MP(Mega-Pixeles). La cámara fue configurada con un enfoque automático sin zoom, sin flash, sin filtros con una apertura del cámara automático entre el f/3 – f/5, para hacer las fotografías se necesitó cierta cantidad de luz que ingresaba por la lente, esto se calculó de manera automática con una oscilación entre el ISO 120 – 160.

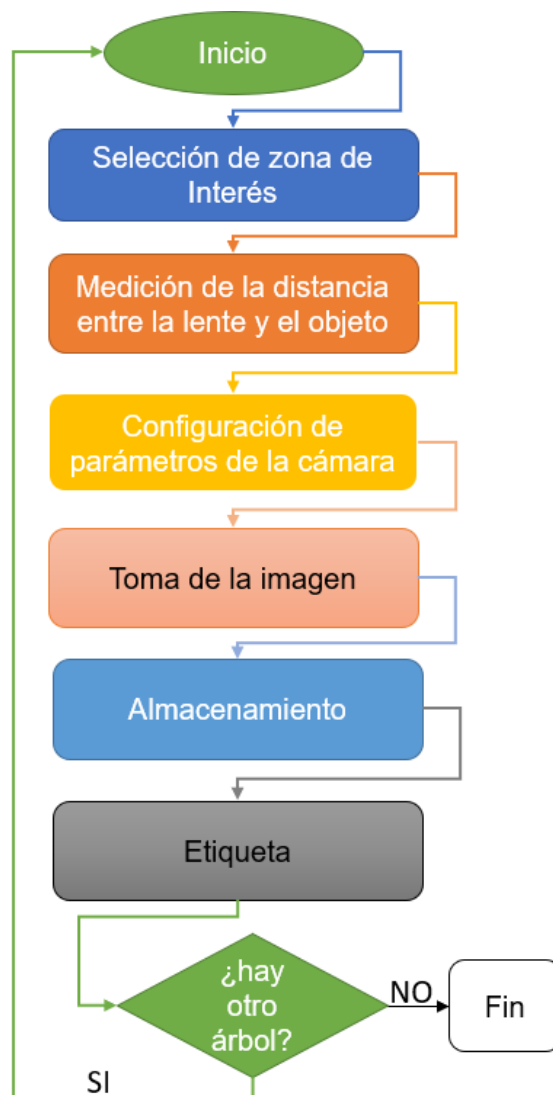


Figura 25. Pasos del protocolo de adquisición de imágenes digitales.

La toma de las imágenes se realizó de tal manera que los síntomas de la enfermedad eran visibles y se manifestaban principalmente en los tallos, por lo que se capturó las imágenes principalmente sobre ellos. se etiquetaron los tallos sanos y tallos enfermos, estas principales divisiones se subdividieron en tallos buenos de grosor pequeño, tallos malos de grosor pequeño, tallos buenos de grosor grande, tallos malos de grosor grande, tallos con nudos buenos y tallos con nudos malos. Considerando los de grosor pequeño a los tallos de dimensiones menores a 20 cm de grosor, los cuales era tallos secundarios que salían de los principales. De la misma forma se consideró a los tallos de grosor grandes a los tallos con dimensiones mayores a 20 cm de grosor quienes en su mayor parte eran tallos principales. Para la captura la posición de la cámara se consideró la forma en que se presentaba la enfermedad en el tallo, de esta manera se logró cubrir toda la zona afectada en diferentes tallos en las que se presentaba visualmente, considerándose la posición a nivel normal, en posición picado, contrapicado y cenital, cubriendo longitudinalmente y transversalmente las zonas visualmente enfermas. De dicha forma es que se logró la adquisición de las imágenes en campo, las cuales fueron alojadas en una memoria micro SDHC sandisk de 32 gb para que posteriormente se pueda realizar la elaboración del dataset para entrenamiento y procesamiento de las imágenes digitales de los tallos del palto.



Figura 26. Protocolo de Adquisición de imágenes digitales en campo del tallo del palto.

Caracterización visual de la enfermedad lasiodiplodia theobromae en las imágenes digitales.

Lasiodiplodia theobromae o muerte regresiva se desarrolla cuando la planta ha sufrido estrés hídrico, debido a que es un hongo que eventualmente puede permanecer en el interior del tejido sin que la planta muestre síntomas, se expresa cuando los tejidos están débiles debido al estrés hídrico (Delgado Junchaya, 2018).

La afección más notable es la manifestación de chancros en conjunto de grumosos y blanquecinos exudados de visible tamaño, encontrados en distintas formas de las ramas y troncos de plantas afectadas. Otro de los síntomas que se observaron con frecuencia fue la necrosis de ramillas y follaje, fueron quienes justamente presentaron total muerte del tejido con basipetal avance, creando así un típico síntoma de *Lasiodiplodia Theobromae*. Un tercer síntoma observado fue la pudrición de las paltas afectadas, observándose una interna pudrición que comprometía mesocarpio en gran medida (Alama et al., 2006).

Tabla 4

Caracterización visual de Lasiodiplodia Theobromae en el Tallo

Figura	Fase	Descripción	observación
	Asintomática	Tallo en estado normal aparente sano	Sano
	Inicial	Zona con un pequeño chancro de con zonas de color amarillo, mostaza, y blanco	Enferma
	Leve	Cancros amarillentos ubicados longitudinalmente en el tallo	
	Moderada	Cancros de color marrón oscuro en el centro de la zona afectada	
	Severa	Necrosis marrón oscuro a negro.	

Pre procesamiento de las imágenes digitales de los tallos del palto.

Redimensionamiento de imágenes.

Para realizar las pruebas experimentales, se procedió a redimensionar las imágenes. Debido a que las imágenes con altas resoluciones consumen más memoria al momento del procesamiento, estas fueron reducidas a un tamaño reducido cuyas resoluciones fueron de 450 pixeles de ancho y 252 pixeles de largo. El conjunto de imágenes está formado por el mismo número de regiones infectadas y sanas.



TChB08



TChB09

Figura 27. Imágenes redimensionadas con resolución 252 x 450.

Código fuente del redimensionamiento de las imágenes:

```
foo = Image.open("D:\Paltitas\TChB01.jpg")  
foo = foo.resize((450,252),Image.ANTIALIAS)  
foo.save("D:\Paltitas\TChB01.png",quality=95)
```

Segmentación del fondo de la imagen.

Iniciando con el pre procesamiento de imágenes, fue conveniente retirar el fondo de las imágenes, ya que según (Ramírez J. et al., 2012) en “Segmentación de imagen a color basada en el algoritmo grabcut” Los resultados obtenidos para retirar el fondo de una imagen son muy buenos, sin embargos frente a ambientes no controlados no arrojan buenos resultados, siendo el algoritmo de grabcut el ideal para este tipo de ambientes dejando así sólo la zona de interés para la investigación. Esta técnica permite la segmentación semiautomática de una imagen de forma rápida En esta técnica se marca la región de interés mediante un cuadrado o línea y luego mediante Gaussian Mixture Models se calculan las probabilidades de los píxeles del objeto obteniendo la segmentación. Si la segmentación es incorrecta, se marcan zonas del fondo y se repite el proceso hasta obtener un resultado correcto (Rother et al., 2004). Dicho procedimiento permitió obtener la zona del primer plano de manera semi automática usando las fórmulas siguientes:

Asigna fondo del primer plano GMM

$\alpha_n = 0$ and $\alpha_n = 1$ respectively

Asigna componentes GMM pixeles

$$k_n := \arg \min_{k_n} D_n(\alpha_n, k_n, \theta, z_n).$$

Aprender parámetros GMM de daros Z

$$\underline{\theta} := \arg \min_{\underline{\theta}} U(\underline{\alpha}, \mathbf{k}, \underline{\theta}, \mathbf{z})$$

Estimar la segmentación: utilizar corte min para resolver:

$$\min_{\{\alpha_n: n \in TV\}} \min_{\mathbf{k}} E(\underline{\alpha}, \mathbf{k}, \underline{\theta}, \mathbf{z}).$$



Figura 28. Segmentación del fondo de las imágenes digitales del tallo con el algoritmo de grabcut.

Aplicación del algoritmo de Grabcut:

```
if (self.rect_or_mask == 0): # grabcut con rectangulo
    bgdmodel = np.zeros((1, 65), np.float64)
    fgdmodel = np.zeros((1, 65), np.float64)
```

```

cv.grabCut(self.img2, self.mask, self.rect, bgdmodel, fgdmodel, 1,
cv.GC_INIT_WITH_RECT)
self.rect_or_mask = 1
elif self.rect_or_mask == 1:    # grabcut con mask
    bgdmodel = np.zeros((1, 65), np.float64)
    fgdmodel = np.zeros((1, 65), np.float64)
    cv.grabCut(self.img2, self.mask, self.rect, bgdmodel, fgdmodel, 1,
    cv.GC_INIT_WITH_MASK)

```

Segmentación

Una vez separada la rama del fondo, se realizó una nueva segmentación para aislar la región afectada por el hongo. Para ello se estudió en qué canal del espacio RGB era mayor la diferencia entre el color del hongo y el de la rama. Como se puede ver en la figura 29. Los canales del espacio de color RGB están representados por:

$$r = \frac{R}{R + G + B}$$

$$g = \frac{G}{R + G + B}$$

$$b = \frac{B}{R + G + B}$$




Figura 29. Imágenes de los componentes de color del espacio RGB del tallo de aguacate en la Figura 28. a. Rojo. b. Verde. C. Azul

Código Fuente para mostrar los espacios de color RGB.

```

rgb = cv2.imread('D:/TESIS/Desarrollo/IMAGENES/Paltitas/Imagnes Sin
fondos/G_TChM02.png')

#rgb = cv2.cvtColor(bgr,cv2.COLOR_BGR2RGB)

C1 = rgb[:, :, 0]

C2 = rgb[:, :, 1]

C3 = rgb[:, :, 2]

cv2.imshow('RGB', np.hstack([C1, C2, C3]))

```

De la figura anterior se observó que no hay una gran diferencia entre los dos en ningún canal. Según (Pujari et al., 2010) El espacio de Color HSV se usa para extraer el componente de valor de brillo (V) y los de crominancia (H y S). El componente V se usa el cálculo de bordes nítidos, mediante el enfoque de gradiente. El enfoque HSV

extrae nueve características: siete invariantes de momento para la forma y dos momentos estadísticos para el color. Por esta razón, la imagen se convirtió al espacio HSV, donde se encontró que el hongo se distingue mucho más fácilmente en el componente S, como se ilustra en la figura 30. Los canales del espacio de color HSV están representadas por las siguientes fórmulas matemáticas:

$$H = \begin{cases} \frac{(G - B) * 60}{MAX - MIN} & SI R = MAX \\ \frac{(B - R) * 60}{MAX - MIN} + 120 & SI G = MAX \\ \frac{(R - G) * 60}{MAX - MIN} + 240 & SI B = MAX \end{cases}$$

$$S = \frac{MAX - MIN}{MAX}$$

$$V = MAX$$

Donde $MAX = \max\{R, G, B\}$ y $MIN = \min\{R, G, B\}$. el valor de H se calcula según el cuadrante en RGB respecto a la línea de grises




Figura 30. Imágenes de los componentes de color del espacio HSB del tallo de aguacate en la Figura 28. a. Componente H. Se ha aumentado el brillo para facilitar la visualización. b. Componente S. c. Componente V.

Código fuente para convertir a espacios de color HSV

```
hsv = cv.cvtColor(canalAzul, cv.COLOR_BGR2HSV)
```

Por lo tanto, se tomó el canal S para la segmentación. Esto se hace utilizando el umbral de Máxima Entropía, ya que según (Díaz, 2016) para conseguir un umbral óptimo esta técnica es la ideal ya que la imagen es escala de grises se binarice permitiendo que la imagen en dos regiones, como se ilustra en la Figura 31. La imagen obtenida se utiliza como una máscara que se superpone a la original, como se ilustra en la Figura 32, lasiodiplodia infección.




Figura 31. Imagen segmentada utilizando el método de umbralización de máxima entropía, donde la región afectada por el hongo se separa del fondo

Código fuente para extraer la máxima entropía

```
ruta = "Ruta"
```

```
H = list(paths.list_images(ruta))
```

```
theta = np.zeros(256)
```

```
Hf = np.zeros(256)
```

```
Hb = np.zeros(256)
```

```
for T in range(1,255):
```

```
    Hf[T] = - np.sum( entp(H[:T-1] / np.sum(H[1:T-1])) )
```

```
    Hb[T] = - np.sum( entp(H[T:] / np.sum(H[T:])) )
```

```
    theta[T] = Hf[T] + Hb[T]
```




Figura 32. Resultado obtenido al superponer la imagen de la Figura 31, utilizada como máscara, sobre la original de la figura 28. Estas imágenes se utilizan como entradas clasificadoras para identificar si el área segmentada está infectada por lasiodiplodia

Elaborar el dataset para entrenamiento y procesamiento de las imágenes digitales de los tallos del palto.

Para la elaboración de este objetivo se diseñó el dataset de imágenes, donde se utilizó un repositorio de imágenes que fueron separadas en 3 carpetas que fueron nombradas respectivamente como: entrenamiento, pruebas y validación.

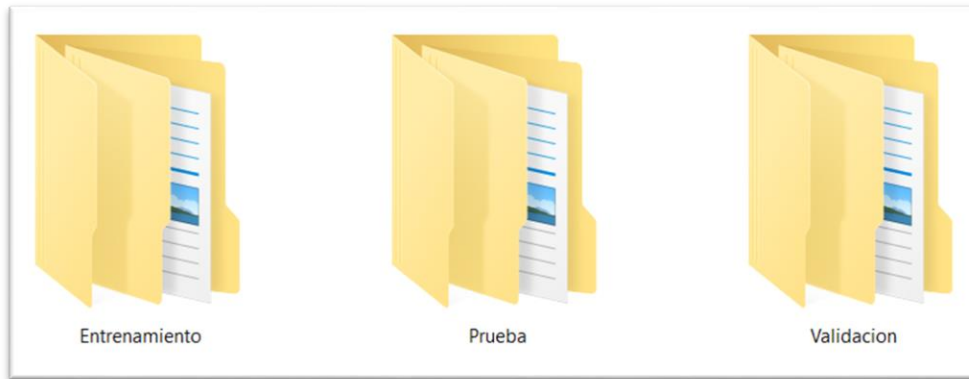


Figura 33. Dataset donde se encuentran almacenadas las imágenes a utilizar, separadas en 3 carpetas.

Dentro de cada carpeta se sub dividieron en 2 carpetas más que fueron nombradas respectivamente como: enfermas y sanas.




Figura 34. Subdivisión de carpetas donde se almacenan las imágenes de tallos enfermos y tallos sanos.

El número de imágenes que se consideraron fueron 800 imágenes, entre las cuales se encuentran muestras tomadas con la enfermedad y sin la enfermedad. De manera siguiente se nombraron a las imágenes de tal manera que indicaran una cualidad específica de estas, tales como: G_TChBXX.png en el caso de tallos chicos buenos, G_TChMXX.png para los tallos chicos malos, G_TGBXX.png en el caso de los tallos grandes buenos, G_TGMXX.png para los tallos grandes malos, G_TIBXX.png en el

caso de los tallos con intersección buenos y G_TIMXX.png en el caso de los tallos con intersección malos. Donde XX representa los números.




Figura 35. Diseño general de la elaboración del dataset para el procesamiento y clasificación de imágenes.

Implementar la técnica de procesamiento de imágenes para detectar la presencia de la enfermedad.

Par este objetivo se implementó la técnica de aprendizaje profundo Redes Neuronales Convolucionales (CNN) ya que según (Lozada-portilla et al., 2020) en “Aplicación de redes neuronales convolucionales para la detección del tizón tardío *Phytophthora infestans* en papa *Solanum tuberosum*” concluyó con las redes neuronales

convolucionales se obtienen resultados ampliamente precisos en tiempo real, en otras palabras son perfectas para el análisis de imágenes. La CNN está conformada por una función matemática

$$y = f(x)$$

Donde X representa la entrada y transformarnos en una salida Y. Para este caso las CNN fueron utilizadas para clasificar la enfermedad del palto. Las imágenes obtenidas de la etapa de segmentación se utilizaron para el proceso de clasificación, en el que se determina si una planta está afectada por Lasiodiplodia. Para ello, cada imagen segmentada se utiliza como entrada del clasificador. Para la clasificación se utilizó una Red Neuronal Convolucional. Dado el bajo número de muestras de entrenamiento, 480, se construyó una CNN poco profunda, se usó el modelo "Sequential". Se usó 2 capas de convolución la primera convolución con 128 neuronas, la segunda convolución se creó con 256 neuronas, y se aplica el Pooling de tipo max (max pooling) para el redimensionamiento de las imágenes. En la segunda capa, la primera convolución fue creada con 128 neuronas, la segunda convolución se creó con 64 neuronas y el poolin de tipo max y al final de ambas capas se creó una neurona con activación sigmoid para representar las probabilidades de ser enferma o sana. Para acelerar el entrenamiento, las imágenes se redujeron a una cuarta parte, es decir, a un tamaño de 113 x 63 píxeles. Se entrenó la técnica CNN con un 60% de las características de Lasiodiplodia y se utilizó un 40% para las pruebas de clasificación. El desempeño de la técnica de clasificación se evaluó mediante validación cruzada de 5 veces, y la obtención de una matriz de confusión, que permite evaluar el desempeño de técnicas o modelos de clasificación automática mediante la obtención de una serie de medidas como la tasa de verdaderos positivos (TPR) , tasa de verdaderos negativos (TNR), tasa de falsos negativos (FNR) y tasa de falsos positivos (FPR).

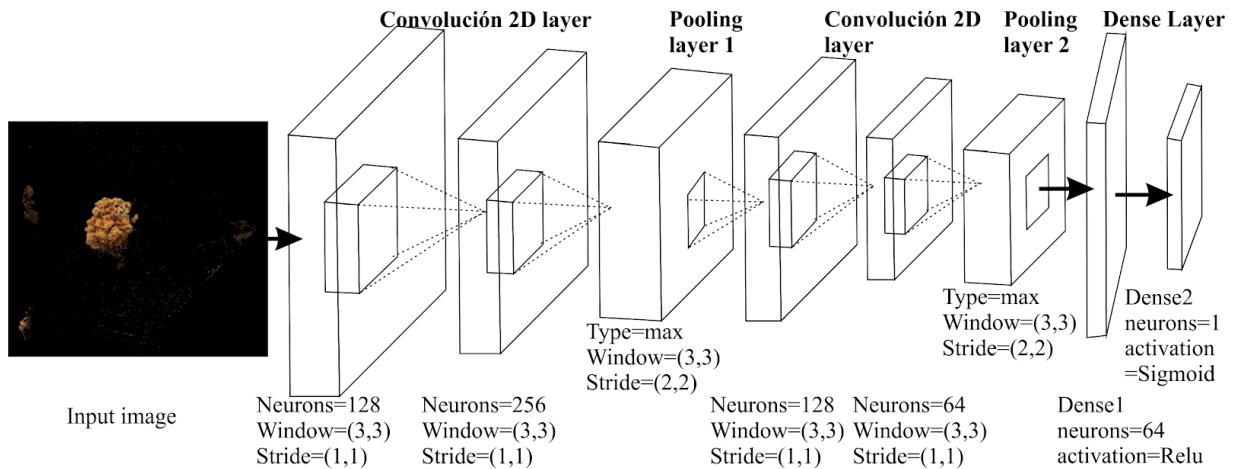


Figura 36. Arquitectura de la red neuronal convolucional.

En cada una de las capas el algoritmo clasificador al momento de entrenar las dos clases, pudo identificar al objeto por las características que las CNN fueron encontrando en cada pixel, para esto se determinó que el modelo se realizaría con 2 capas de convolución para la mejor obtención de resultados. Donde la imagen de entrada fue ingresada a la CNN y esta pasó a las capas de convolución, donde el algoritmo buscó el mismo patrón en cada pixel en distintas posiciones de la imagen, moviendo una ventana a lo largo de la imagen. Una vez que terminó su tarea en la capa de convolución, la imagen entró a la capa de pooling que es una capa que se dedica exclusivamente a reducir las dimensiones de la imagen, en este caso también mueve una ventana, pero la reducción se realizó cogiendo el valor máximo o el valor medio de cada ventana. Es así como se realizó el entrenamiento de la red neuronal. Posteriormente fueron puestas a prueba y a validarlas

IV. CONCLUSIONES Y RECOMENDACIONES

4.1. Conclusiones

Luego que se realizó la adquisición de las imágenes del tallo del palto se concluyó que si bien es cierto tomar las imágenes en un ambiente no controlado sirvió para la detección de la enfermedad, éstas deben ser tomadas en un ambiente controlado o al menos que se coloque un fondo blanco o negro como segundo plano de la toma para así evitar el tedioso proceso de eliminar el fondo o segundo plano de la imagen.

Después de analizar y consultar varias fuentes para la caracterización visual de la enfermedad, se determinó que la principal característica de la enfermedad estudiada es el color que está toma en diferentes niveles de su enfermedad, siendo características chancros sobre los tallos de color blanquecino y amarillento.

Si bien es cierto que el pre procesamiento es muy necesario para someter las imágenes a clasificar, es mejor que la fase de extracción de características la haga la misma red neuronal convolucional, ya que justamente la extracción de características de manera interna es una de las cualidades principales de una CNN.

Al momento que se elaboró el dataset se concluyó que esta debe estar organizada de manera equitativamente lo que quiere decir que el mismo número de imágenes con tallos enfermos debe ser igual al número de las imágenes de tallos sanas para cada clase, para una mejor obtención de resultados.

La técnica de aprendizaje automático profundo red neuronal convolucional es efectiva para la clasificación digital, sin embargo, el repositorio de imágenes debe ser más grande para que así la clasificación arroje mejores resultados.

4.2 Recomendaciones

Para aquellos investigadores que deseen obtener los mismos resultados que fueron obtenidos en la presente investigación, se recomienda que se trabaje con el lenguaje de programación Python en su versión 3.7 ya que se encontraron problemas con versiones anteriores, debido a que las librerías están en constante actualización y cada

vez más se agrega más características para que se puedan realizar más actividades. También se utilizó la versión 4.1.2 de OpenCV ya que esta es una biblioteca que es de gran ayuda con la visión artificial y es la versión más reciente lanzada hasta la finalización de este proyecto.

A los investigadores futuros se les recomienda implementar mejoras en el algoritmo de redes neuronales convolucionales para que éstas no necesiten de tanta data para poder realizar la clasificación de las enfermedades en diferentes partes de la planta ya sea tallo y/o hojas.

Se recomienda implementar diferentes algoritmos de clasificación, bajo el mismo escenario del problema expresado en la presente investigación y que se realicen comparaciones entre ellas.

REFERENCIAS

- Alama, I., Maldonado, E., & Rodríguez-Galvez, E. (2006). Lasiodiplodia theobromae affect the cultivation of Palto (Persea americana) under the conditions of Piura , Peru. *Universalía*, 11(2), 4–13.
- Andrew, N. (2018). *What is Machine Learning? - Introduction | Coursera*.
<https://es.coursera.org/learn/machine-learning/lecture/Ujm7v/what-is-machine-learning>
- Antón, R. J., Flores, J. N., Mejía Cabrera, H. I., Tuesta, V. A., & Forero, M. G. (2020). *New method for subject identification based on palm print*. August, 17.
<https://doi.org/10.1117/12.2567196>
- Balcázar Guerrero, M. (2006). *DESARROLLO DE UN MÓDULO SIG PARA EL MANEJO DE IMÁGENES MULTIESPECTRALES ORIENTADO A LA AGRICULTURA DE PRECISIÓN*.
http://tesis.pucp.edu.pe/repositorio/bitstream/handle/123456789/5122/CEPEDA_LORENA_ESTUDIO_PRE-FACTIBILIDAD_IMPLEMENTACION_CADENA_COMIDAS_RAPIDAS_POLLO_LIMA_NORTE.pdf?sequence=4
- Beltrán-Peña, H., Soria-Ruiz, J., Téliz-Ortiz, D., Ochoa-Martínez, D. L., Nava-Díaz, C., & Ochoa-Ascencio, S. (2014). Detección satelital y molecular del viroide de la mancha de sol del aguacate (Avocado sunblotch viroid, ASBVd). *Revista Fitotecnia Mexicana*, 37(1), 21–29.
- Delgado Junchaya, M. A. (2018). *Manejo integrado de enfermedades en palto*.
- Devaraj, A., Rathan, K., Jaahnavi, S., & Indira, K. (2019). Identification of Plant Disease using Image Processing Technique. *2019 International Conference on Communication and Signal Processing (ICCSP)*, 749–753.
- Díaz, M. Q. (2016). *Detección de bordes por umbralización basada en entropía sobre imágenes multidimensionales en GPU*.

- Dirección General De Información Agraria. (2008). *Estudio de palta en Perú y el Mundo*. 1–23.
- Flores, J. N., Mejía Cabrera, H. I., Sigueñas, J. B., Tuesta, V. A., & Forero, M. G. (2020). *Identification of Lasiodiplodia Theobromae in avocado trees through image processing and machine learning*. August, 83.
<https://doi.org/10.1117/12.2567322>
- Géron, A. (2017). *Hands-On Machine Learning with Scikit-Learn and TensorFlow* (O. R. M. Inc (ed.)). O'Reilly Media.
- Isasi Viñuela, P., & Galván León, I. M. (2004). *Redes neuronales artificiales. Un enfoque práctico* (P. EDUCACIÓN (ed.); 1st ed.).
- Li, H., Lee, W. S., & Wang, K. (2013). Spectral mixture analysis based citrus greening disease detection using satellite image of Florida. *Proceedings of the 5th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, 3–6.
- Li, H. N., Feng, J., Yang, W. P., Wu, X. S., Li, Z. D., & Liu, W. (2011). Spectrum-based method for quantitatively detecting diseases on cucumber leaf. *Proceedings - 4th International Congress on Image and Signal Processing, CISP 2011*, 4, 1971–1974. <https://doi.org/10.1109/CISP.2011.6100651>
- Lozada-portilla, W. A., Suarez-barón, M. J., & Avendaño-fernández, E. (2020). *Aplicación de redes neuronales convolucionales para la detección del tizón tardío Phytophthora infestans en papa Solanum tuberosum Application of convolutional neural networks for detection of the late blight Phytophthora infestans in potato Solanum tuber*. 2, 1–9.
- Meyyappan, S. (2018). *Plant Infection Detection Using Image Processing*. August.
- Ministerio Agricultura y Riego Peru. (2015). Tendencias de la producción y el comercio de Palta en el mercado internacional y Nacional. *Minagri - Dgpa*, 81.
<http://minagri.gob.pe/portal/analisis-economico/analisis->

2015?download=6825:informe-palta-peruana.

Ministerio Agricultura y Riego Peru. (2019). La Situación del Mercado Internacional de la Palta. *Ministerio de Agricultura y Riego-MINAGRI*, 41.

<https://bibliotecavirtual.midagri.gob.pe/index.php/analisis-economicos/estudios/2019/28-la-situacion-del-mercado-internacional-de-la-palta/file>

Moghadam, P., Ward, D., Goan, E., Jayawardena, S., Sikka, P., & Hernandez, E. (2017). Plant Disease Detection Using Hyperspectral Imaging. *2017 International Conference on Digital Image Computing: Techniques and Applications (DICTA)*, 1–8. <https://doi.org/10.1109/DICTA.2017.8227476>

Pérez, L. (2014). *Identificación de Vegetación en Imágenes Satelitales*.

Pujari, J., Pushpalatha, S. N., & Desai, P. D. (2010). Content-based image retrieval using color and shape descriptors. *Proceedings of the 2010 International Conference on Signal and Image Processing, ICSIP 2010, December 2010*, 239–242. <https://doi.org/10.1109/ICSIP.2010.5697476>

Quintero, C., Merchán, F., & Cornejo, A. (2018). *Uso de Redes Neuronales Convolucionales para el Reconocimiento Automático de Imágenes de Macroinvertebrados para el Biomonitorio Participativo*. February. <https://doi.org/10.18502/keg.v3i1.1462>

Ramírez J., E., Martínez R., D., & Carmona S., R. (2012). Segmentación de imagen a color basada en el algoritmo grabcut. *Revista de Ingeniería*, 15(March 2014), 21–38.

Roa, E., & Menses, G. (2014). *Automated System for Classifying Hass Avocados Based on Image Processing Techniques*. 3, 2008–2014.

Rother, C., Kolmogorov, V., & Blake, A. (2004). “GrabCut: interactive foreground extraction using iterated graph cuts.” *ACM Transactions on Graphics (TOG)*, 23(3), 309–314. <https://doi.org/10.1145/1015706.1015720>

Russell, R. (2018). *Machine Learning: Guia Paso a Paso Para Implementar Algoritmos de Machine Learning Con Python*. 1, 21–21. <https://bit.ly/3mjE17s>

Trueba, S. (2017). *Análisis de imágenes multiespectrales aéreas de vegetación Analysis of multispectral aerial images of vegetation Para acceder al Título de Graduado en Ingeniería de Tecnologías de Telecomunicación*.

Andrew, N. (3 de 10 de 2018). *Coursera.org*. Obtenido de <https://es.coursera.org/learn/machine-learning/lecture/Ujm7v/what-is-machine-learning>

Christian, S., Vincent, V., Ioffe, S., Jonathon, S., & Zbigniew, W. (2015). *Rethinking the Inception Architecture for Computer Vision*. Estados Unidos: Cornell University.

Gonzales. (1987).

Hart, P., Robert, T., & Jerome, F. (2008). *The elements of statistical learning*. Estados Unidos: Springer.

Leemans, V., Magein, H., & Destain. (1998).

Vilet, J. R. (2005). *Procesamiento Digital de Imágenes*. Potosí.

ANEXOS

Resolución de Ampliación de vigencia de tesis

FACULTAD DE INGENIERÍA, ARQUITECTURA Y URBANISMO
RESOLUCIÓN N°0570-2022/FIAU-USS

Pimentel, 19 de septiembre de 2022

VISTO:

El Acta de reunión N°0509-2022 del Comité de investigación de la Escuela profesional de INGENIERÍA DE SISTEMAS remitida mediante Oficio 0195-2022/FIAU-IS-USS de fecha 5 de septiembre de 2022, y;

CONSIDERANDO:

Que, de conformidad con la Ley Universitaria N° 30220 en su artículo 48° que a letra dice: "La investigación constituye una función esencial y obligatoria de la universidad, que la fomenta y realiza, respondiendo a través de la producción de conocimiento y desarrollo de tecnologías a las necesidades de la sociedad, con especial énfasis en la realidad nacional. Los docentes, estudiantes y graduados participan en la actividad investigadora en su propia institución o en redes de investigación nacional o internacional, creadas por las instituciones universitarias públicas o privadas.";

Que, de conformidad con el Reglamento de grados y títulos en su artículo 21° señala: "Los temas de trabajo de investigación, trabajo académico y tesis son aprobados por el Comité de Investigación y derivados a la facultad o Escuela de Posgrado, según corresponda, para la emisión de la resolución respectiva. El periodo de vigencia de los mismos será de dos años, a partir de su aprobación. En caso un tema perdiera vigencia, el Comité de Investigación evaluará la ampliación de la misma."

Que, de conformidad con el Reglamento de grados y títulos en su artículo 24° señala: La tesis es un estudio que debe denotar rigurosidad metodológica, originalidad, relevancia social, utilidad teórica y/o práctica en el ámbito de la escuela profesional. Para el grado de doctor se requiere una tesis de máxima rigurosidad académica y de carácter original. Es individual para la obtención de un grado; es individual o en pares para obtener un título profesional. Asimismo, en su artículo 25° señala: "El tema debe responder a alguna de las líneas de investigación institucionales de la USS S.A.C."

Que, mediante documentos de vistos, el Comité de investigación de la referida Escuela profesional acordó aprobar la ampliación de la vigencia de las tesis que se detallan en el Acta de reunión N° 0509 - 2022, de la línea de investigación de INFRAESTRUCTURA, TECNOLOGÍA Y AMBIENTE, a cargo de los estudiantes y /o egresados del Programa de estudios INGENIERÍA DE SISTEMAS, hasta la fecha que indica la presente resolución.

Estando a lo expuesto, y en uso de las atribuciones conferidas y de conformidad con las normas y reglamentos vigentes;

SE RESUELVE:

ARTÍCULO ÚNICO: AMPLIAR VIGENCIA, de la Tesis a cargo de los estudiantes y /o egresados del Programa de estudios de **INGENIERÍA DE SISTEMAS** que se detallan en el anexo de la presente Resolución.

FACULTAD DE INGENIERÍA, ARQUITECTURA Y URBANISMO
RESOLUCIÓN N°0570-2022/FIAU-USS

Pimentel, 19 de septiembre de 2022

ANEXO

APELLIDOS	TESIS	AMPLIACION HASTA
FLORES TELLO JAIME NICOLAS	DETECCIÓN AUTOMÁTICA DE LA ENFERMEDAD LASIODIPLDIA THEOBROMAE DEL PALTO UTILIZANDO IMÁGENES DIGITALES CON REDES NEURONALES CONVOLUCIONALES	31 DE DICIEMBRE DEL 2022

Recolección de imágenes







Implantación del algoritmo de Grabcut

```
# importamos librerías
from __future__ import print_function

import numpy as np
import cv2 as cv

import sys

# configuramos las líneas, rectángulos que se dibujaran
class App():
    BLUE = [255,0,0]      #color del rectángulo
    RED = [0,0,255]      #color del fondo
    GREEN = [0,255,0]    #color de primer plano
    BLACK = [0,0,0]      #trazo en 2do plano
    WHITE = [255,255,255] #trazo en primer plano

    DRAW_BG = {'color' : BLACK, 'val' : 0}
    DRAW_FG = {'color' : WHITE, 'val' : 1}
    DRAW_PR_FG = {'color' : GREEN, 'val' : 3}
```

```

DRAW_PR_BG = {'color' : RED, 'val' : 2}

# configurando flags
rect = (0,0,1,1)
dibujo = False      # flag para dibujar curvas
rectangulo = False  # flag para dibujar rectangulos
rect_over = False   # flag para verificar rectangulo dibujado
rect_or_mask = 100  # flag para seleccionar el modo de rect o máscara
value = DRAW_FG     # iniciado dibujo a primer plano
thickness = 3       # gorsor de la línea

def onmouse(self, event, x, y, flags, param):
    # dibujar rectangulo
    if event == cv.EVENT_RBUTTONDOWN:
        self.rectangulo = True
        self.ix, self.iy = x,y

    elif event == cv.EVENT_MOUSEMOVE:
        if self.rectangulo == True:
            self.img = self.img2.copy()
            cv.rectangulo(self.img, (self.ix, self.iy), (x, y), self.BLUE, 2)
            self.rect = (min(self.ix, x), min(self.iy, y), abs(self.ix - x), abs(self.iy - y))
            self.rect_or_mask = 0

        elif event == cv.EVENT_RBUTTONUP:
            self.rectangulo = False
            self.rect_over = True
            cv.rectangulo(self.img, (self.ix, self.iy), (x, y), self.BLUE, 2)
            self.rect = (min(self.ix, x), min(self.iy, y), abs(self.ix - x), abs(self.iy - y))
            self.rect_or_mask = 0
            print(" presione la tecla 'n' para hacer los cambios \n")

# dibujar curvas de retoque

if event == cv.EVENT_LBUTTONDOWN:
    if self.rect_over == False:
        print("Primero dibujo el rectangulo \n")
    else:
        self.dibujo = True
        cv.circle(self.img, (x,y), self.thickness, self.value['color'], -1)
        cv.circle(self.mask, (x,y), self.thickness, self.value['val'], -1)

elif event == cv.EVENT_MOUSEMOVE:
    if self.dibujo == True:
        cv.circle(self.img, (x, y), self.thickness, self.value['color'], -1)
        cv.circle(self.mask, (x, y), self.thickness, self.value['val'], -1)

elif event == cv.EVENT_LBUTTONUP:
    if self.dibujo == True:
        self.dibujo = False
        cv.circle(self.img, (x, y), self.thickness, self.value['color'], -1)
        cv.circle(self.mask, (x, y), self.thickness, self.value['val'], -1)

def run(self):
    # cargando imágenes

```

```

if len(sys.argv) == 2:
    filename = sys.argv[1] # comenzar a dibujar

else:
    print("no se ha proporcionado imagen de entrada, por lo que se carga imagen predeterminada
D:/invll/procesamiento imagenes/imagenes/TChB12.png \n")
    filename = 'D:/Paltitas/invll/procesamiento imagenes/imagenes/TIM12.png'

self.img = cv.imread(cv.samples.findFile(filename))
self.img2 = self.img.copy() # una copia de la imagen original
self.mask = np.zeros(self.img.shape[:2], dtype = np.uint8) # mascara inicializada en PR_BG
self.output = np.zeros(self.img.shape, np.uint8) # imagen de salida a mostrar

# ventanas de entrada y salida
cv.namedWindow('salida')
cv.namedWindow('entrada')
cv.setMouseCallback('entrada', self.onmouse)
cv.moveWindow('entrada', self.img.shape[1]+10,90)

print(" Instrucciones: \n")
print(" dibuja un rectangulo alrededor del objetivo con le boton derecho del mouse \n")

while(1):

    cv.imshow('salida', self.output)
    cv.imshow('entrada', self.img)
    k = cv.waitKey(1)

    # combinaciones de teclas
    if k == 27: # esc para salir
        break
    elif k == ord('0'): # dibujando fondo
        print(" marcar reiones de fondo con el botón izquierdo del mouse \n")
        self.value = self.DRAW_BG
    elif k == ord('1'): # dibijando primer plano
        print(" marcar las reciones de primer plano con el botón izquierdo del mouse \n")
        self.value = self.DRAW_FG
    elif k == ord('2'):
        self.value = self.DRAW_PR_BG
    elif k == ord('3'):
        self.value = self.DRAW_PR_FG
    elif k == ord('s'): # guardar imagen
        bar = np.zeros((self.img.shape[0], 5, 3), np.uint8)
        #
        res = np.hstack((self.img2, bar, self.img, bar, self.output))
        #
        cv.imwrite('D:/Paltitas/invll/procesamiento imagenes/resultado/G_TIM12.png', res)
        print(" Resultado guardado como imagen \n")
    elif k == ord('r'): # restablecer todo
        print("reiniciando \n")
        self.rect = (0,0,1,1)
        self.dibujo = False
        self.rectangulo = False
        self.rect_or_mask = 100
        self.rect_over = False

```

```

self.value = self.DRAW_FG
self.img = self.img2.copy()
self.mask = np.zeros(self.img.shape[:2], dtype = np.uint8) # mask inicializada a PR_BG
self.output = np.zeros(self.img.shape, np.uint8) # salida de imagen para ser
mosytrada
elif k == ord('n'): # segmentar imagen
print(""" Para retoque más finos, marque el primer plano y el fondo después de presionar las
teclas 0-3
y presionar de nuevo 'n' \n""")
try:
if (self.rect_or_mask == 0): # grabcut con rect
bgdmodel = np.zeros((1, 65), np.float64)
fgdmodel = np.zeros((1, 65), np.float64)
cv.grabCut(self.img2, self.mask, self.rect, bgdmodel, fgdmodel, 1,
cv.GC_INIT_WITH_RECT)
self.rect_or_mask = 1
elif self.rect_or_mask == 1: # grabcut con mask
bgdmodel = np.zeros((1, 65), np.float64)
fgdmodel = np.zeros((1, 65), np.float64)
cv.grabCut(self.img2, self.mask, self.rect, bgdmodel, fgdmodel, 1,
cv.GC_INIT_WITH_MASK)
except:
import traceback
traceback.print_exc()

mask2 = np.where((self.mask==1) + (self.mask==3), 255, 0).astype('uint8')
self.output = cv.bitwise_and(self.img2, self.img2, mask=mask2)

print('Hecho')

if __name__ == '__Menu__':
print(__doc__)
App().run()
cv.destroyAllWindows()

```

Código fuente del pre procesamiento de las imágenes

```

import numpy as np
import cv2 as cv

imagen = cv.imread('D:/Paltitas/invll/procesamientoImágenes/resultado/G_TIB03.png')
cv.imshow('img',imagen)

#Convertir imgane a espacio de color LAB
colorLab = cv.cvtColor(imagen, cv.COLOR_BGR2LAB)
cv.imshow("Espacio de color Lab", colorLab)

#Dejar el canal Azul
canalAzul = cv.cvtColor(colorLab, cv.COLOR_RGB2BGR)
canalAzul[:, :, 1] = 0
canalAzul[:, :, 2] = 0

cv.imshow("Canal Azul", canalAzul)

```

```

#Pasar a HSV
hsv = cv.cvtColor(canalAzul, cv.COLOR_BGR2HSV)
cv.imshow("Espacio de color HSV", hsv)

#segmentacion de la imagen
#valores maximos y minimos obtenidos:
#min H = 120 , min S=255, min V = 148; max H = 120, max S = 255, Max V = 174
minEnfermo = np.array([120,255,148])
maxEnFermo = np.array([120,255,174])

mascara = cv.inRange(hsv, minEnfermo, maxEnFermo)
cv.imshow("ImagenSegmentada con los valores de color maximos y minimos", mascara)

res = cv.bitwise_and(imagen, imagen, mask=mascara)
cv.imshow("Se Muestra Zona de Interés", res)
cv.imwrite('D:/Paltitas/invll/procesamientoImagenes/GaussianBlur/ColorHSV_TIB03.png', res)

cv.waitKey(0)

```

código fuente de aplicación de las redes neuronales

```

import numpy as np
import keras
from keras.preprocessing.image import ImageDataGenerator

# Indicamos Cada correspondiente carpeta
TRAIN_FOLDER = 'D:/Paltitas/ImagnesSinFondo/Entrenamiento/'
VAL_FOLDE = 'D:/Paltitas/ImagnesSinFondo/Prueba/'

# Indicamos como se cogeran las imagenes de entrenamiento y si habrá data-aumentation.
# Basicamente para tener más ejemplos,
# modificaremos un poco los actuales haciendo transformaciopnes que sabemos que no modificaran
totalmente la imagen
# - zoom
# - pequeños cambios deformacion
# - flip horizontal
# Además normalizaremos los datos de entrada a un rango de [0-1]
train_datagen = ImageDataGenerator(
    rescale=1./255,
    shear_range=0.2,
    zoom_range=0.2,
    horizontal_flip=True
)

# En validacion unicamente normalizaremos los datos
val_datagen = ImageDataGenerator(
    rescale=1./255
)

#Indicamos como tomaremos los datos.
# El tamaño que tendrán las imágenes
# El tipo de espacio de color que usaremos

```

```

# Para aprender con más fiabilidad no actualizaremos la red con un único ejemplo (y si ese ejemplo es
poco común... Podría hacerla aprender mal)
# Usaremos batch_size para coger N ejemplos y promediar la corrección. Así nos aseguraremos ir por
el buen camino.
train_generator = train_datagen.flow_from_directory(
    directory=TRAIN_FOLDER,
    target_size=(32, 32),
    color_mode="rgb",
    batch_size=32,
    class_mode="binary",
    shuffle=True,
    seed=1
)

# Mostramos los labels que luego nos serán interesantes para saber si perro corresponde a la
probabilidad =1 o =0.
)
print('Labels:', dict([(i, k) for i, k in enumerate(train_generator.class_indices)]))

val_generator = val_datagen.flow_from_directory(
    directory=VAL_FOLDER,
    target_size=(32, 32),
    color_mode="rgb",
    batch_size=32,
    class_mode="binary",
    shuffle=True,
    seed=1
)

# Cargamos la clase para generar modelos secuenciales
from keras.models import Sequential
# Cargamos las siguientes capas
from keras.layers import Conv2D, MaxPooling2D, Dense, Flatten

model = Sequential()
# Bloque 1:
# - Conv1a: neuronas=128, ventana=(3,3), activacion=ReLU.
# - Conv1b: neuronas=256, ventana=(3,3), activacion=ReLU.
# - Max-pooling: ventana=(3,3), stride=2.
model.add(Conv2D(128, (3, 3), strides=(1, 1), activation='relu', input_shape=(32, 32, 3)))
model.add(Conv2D(256, (3, 3), strides=(1, 1), activation='relu'))
model.add(MaxPooling2D(3, strides=(2, 2)))

# Bloque 2:
# - Conv2a: neuronas=128, ventana=(3,3), activacion=ReLU.
# - Conv2b: neuronas=64, ventana=(3,3), activacion=ReLU.
# - Max-pooling: ventana=(3,3), stride=2.
model.add(Conv2D(128, (3, 3), strides=(1, 1), activation='relu'))
model.add(Conv2D(64, (3, 3), strides=(1, 1), activation='relu'))
model.add(MaxPooling2D(3, strides=(2, 2)))
# Convertimos lo que quede (HxWxC) a un vector-columna
model.add(Flatten())

# Bloque Fully-Connected
# - FC1: neuronas=64, activacion=ReLU

```



```
# - FC2: neuronas=1, activacion=Sigmoid
model.add(Dense(64, activation='relu'))
model.add(Dense(1, activation='sigmoid'))
```