

Detección de la enfermedad gota en cultivos de papa en Colombia usando Deep Learning

María Alejandra Roa Delgado

Asesora

Ingeniera Paola Andrea Mateus Abaunza

Ingeniera Electrónica

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias Básicas, Tecnología E Ingeniería

Ingeniería de Telecomunicaciones

2023

Dedicatoria

Dedico el resultado de este trabajo a mi familia, quienes han sido mi mayor motivación y apoyo en todo momento. En especial, quiero agradecer a mi querida madre, quien ha sido mi motor durante muchos años y, aunque ya no se encuentra conmigo físicamente, su ejemplo y fe continúan guiándome en cada paso del camino y en cada decisión importante de mi vida. Gracias por construir en mí y en mi hermana la fuerza para ser grandes personas.

También quiero dedicar este trabajo a mi hijo Samuel, quien es mi principal motivación para seguir adelante y para quien espero ser un ejemplo digno de admiración. Gracias por ser mi luz en los momentos más oscuros y por recordarme que la dedicación y el sacrificio siempre llevan a frutos significativos.

A mi esposo Jorge, le dedico este trabajo por su paciencia, comprensión y motivación en los momentos más difíciles. Gracias por estar a mi lado y apoyarme en cada paso que doy, por ser mi inspiración, por exigirme cada día más y así ver que soy capaz de grandes cosas.

A mi hermana Luisa le dedico este trabajo por su constante apoyo y confianza en mis capacidades. Gracias por seguir creyendo en mí y por ser un pilar fundamental en mi vida. Este logro también es tuyo.

Además, quiero dedicar este trabajo a mi tía María Cecilia, quien confió en mí para trabajar en sus cultivos y me dio la oportunidad de conocer su excelente trabajo y dedicación a sus labores.

También quiero agradecer a todos los integrantes de mi familia, quienes han logrado grandes cosas y siempre me han brindado su apoyo incondicional. Este trabajo es para ustedes, gracias por impulsarme a seguir adelante en mi camino hacia el éxito.

Agradecimientos

Quiero expresar primero mi agradecimiento a Dios, quien me brindó las fuerzas y la determinación necesarias para completar este trabajo, incluso en los momentos más difíciles.

Agradezco de manera especial a la ingeniera Paola, mi asesora de proyecto, por su confianza en

mí y por ayudarme a llevar a cabo este proyecto con éxito. Gracias por compartir sus conocimientos y por trabajar conmigo a pesar de los obstáculos y limitaciones de tiempo. Fue una experiencia enriquecedora para mí.

También quiero expresar mi gratitud a mi esposo Jorge, quien me brindó su apoyo constante y

motivación en los momentos en que perdía la paciencia y la motivación. Gracias por tu paciencia, amor y comprensión.

Agradezco a mi hijo Samuel por brindarme su tiempo y por ser una fuente de inspiración y

motivación en todo momento. Su apoyo ha sido invaluable, espero seguir siendo un buen ejemplo para él y continuar compartiendo momentos especiales juntos.

Por último, quiero agradecer a mi familia, quienes confían en mis habilidades y siempre me

desean lo mejor. Su apoyo y motivación son fundamentales para mí y me ayudan a seguir adelante en la búsqueda de mis objetivos.

Resumen

En Colombia, la enfermedad de “La Gota” en cultivos de papa representa un problema importante que afecta la productividad y la economía de los agricultores. Para dar una solución a esta problemática, este proyecto de investigación propone un algoritmo basado en técnicas de procesamiento de imágenes e inteligencia artificial para detectar esta enfermedad en cultivos de papa. La solución es desarrollada por medio de un algoritmo basado en técnicas de procesamiento de imágenes tales como, segmentación, binarización, cambio de espacios de color y operaciones morfológicas, para analizar e interpretar el contenido de las imágenes y así lograr identificar las características que indiquen la presencia de la enfermedad. Posteriormente se implementa un algoritmo de inteligencia artificial utilizando aprendizaje profundo o "Deep Learning", el cual entrena una red neuronal convolucional y se realiza una clasificación de las imágenes bajo las etiquetas “gota” y “sana”. Los resultados obtenidos con este algoritmo demuestran una precisión del 98.11% al momento de identificar una imagen con la enfermedad de la gota, lo que permite una alerta temprana y ayuda a los agricultores a tomar medidas preventivas. Esto es especialmente importante en la protección de los cultivos y en la reducción de las pérdidas económicas asociadas con la enfermedad. En conclusión, este proyecto de investigación ofrece una solución innovadora y efectiva para abordar la problemática de la enfermedad de "La Gota" en los cultivos de papa en Colombia, lo que contribuye significativamente a la sostenibilidad y la competitividad del sector agrícola en el país.

Palabras Clave: Aprendizaje profundo, binarización, inteligencia artificial, Matlab, operaciones morfológicas, procesamiento de imágenes, segmentación de imágenes, umbralización.

Abstract

In Colombia, the "La Gota" disease in potato crops represents an important problem that affects the productivity and economy of farmers. To provide a solution to this problem, this research project proposes an algorithm based on image processing techniques and artificial intelligence to detect this disease in potato crops. The solution is developed by means of an algorithm based on image processing techniques such as image segmentation, thresholding, binarization, and morphological operations, to analyze and interpret the content of the images and thus identify the characteristics that indicate the presence of the disease. Subsequently, an artificial intelligence algorithm is implemented using Deep Learning, which trains a convolutional neural network, and a classification of the images is carried out under the labels "gota" and "sana". The results obtained with this algorithm demonstrate an accuracy of 98.11% when identifying an image with gout disease, which allows early warning and helps farmers take preventive measures. This is especially important in crop protection and in reducing economic losses associated with the disease. In conclusion, this research project offers an innovative and effective solution to address the problem of "La Gota" disease in potato crops in Colombia, which significantly contributes to the sustainability and competitiveness of the agricultural sector in the country.

Keywords: Artificial intelligence, binarization, Deep Learning, image processing, image segmentation, Matlab, morphological operations, thresholding.

Tabla De Contenido

Introducción	11
Pregunta de Investigación	14
Planteamiento del Problema	15
Justificación	17
Objetivos	19
Objetivo General	19
Objetivos Específicos	19
Marco Conceptual	20
Técnicas de Segmentación	22
Técnicas de inteligencia artificial	25
Desarrollo del Algoritmo	27
Estudio del Arte	27
Construcción Base de datos	31
Características de la Enfermedad de “Gota de Papa” en los Cultivos	32
Técnicas de Segmentación de Imágenes	34
Selección Espacio de Color	34
Transformación Espacio de Color CIELAB	36
Umbralización, Binarización y Operación Morfológica	40

Segmentación Final	41
Automatización de segmentación y uniformidad para la Base de datos.	42
Algoritmo Entrenamiento de la Red Neuronal Convolutacional.	44
Resultados.....	49
Conclusión	52
Referencias.....	53

Lista de Figuras

Figura 1 <i>Síntoma típico de la enfermedad Gota en una hoja</i>	20
Figura 2 <i>Síntoma típico de la enfermedad de la Gota a lo largo del tallo</i>	21
Figura 3 <i>Síntoma típico de la enfermedad Gota causado por Phytophthora infestans en una planta</i>	21
Figura 4 <i>Hoja de Papa con la enfermedad de la Gota</i>	32
Figura 5 <i>Base de datos imágenes de hojas de cultivos de papa con la enfermedad</i>	33
Figura 6 <i>Base de datos imágenes de hojas de cultivos de papa sanas.</i>	33
Figura 7 <i>Espacio de color HSV y binarización para imagen sana</i>	35
Figura 8 <i>Espacio de color CIELAB y binarización para imagen sana</i>	35
Figura 9 <i>Espacio de color HSV y binarización para imagen con Gota</i>	35
Figura 10 <i>Espacio de color CIELAB y binarización para imagen con Gota</i>	35
Figura 11 <i>Imagen Sana aplicando operación morfológica</i>	36
Figura 12 <i>Componentes transformación sRGB a CIELAB en imagen con la enfermedad</i>	37
Figura 13 <i>Componentes transformación sRGB a CIELAB en imagen Sana</i>	37
Figura 14 <i>Componentes transformación RGB a CIELAB en imagen con la enfermedad</i>	38
Figura 15 <i>Componentes transformación RBG a CIELAB en imagen Sana</i>	38
Figura 16 <i>Capa A binarizada, en imagen con la enfermedad y sin la enfermedad</i>	39
Figura 17 <i>Imagen LB, en imagen con la enfermedad y sin la enfermedad</i>	39
Figura 18 <i>Imagen binarizada y resultado operación morfológica en una imagen que presenta la enfermedad</i>	40
Figura 19 <i>Reconocimiento de bordes en imagen original en escala de grises</i>	41
Figura 20 <i>Segmentación final</i>	42

Figura 21 <i>Imágenes sanas segmentadas</i>	43
Figura 22 <i>Imágenes con la enfermedad segmentadas</i>	44
Figura 23 <i>Proceso de entrenamiento</i>	46
Figura 24 <i>Matriz de confusión</i>	47
Figura 25 <i>Proceso de Aprendizaje. Presión 98.11%</i>	49
Figura 26 <i>Matriz de Confusión. Presión 98.11%</i>	50

Lista de Tablas

Tabla 1 <i>Resumen Analítico.</i>	28
Tabla 2 <i>Tabla comparativa segmentación de imágenes por medio de HSV vs segmentación de imágenes por medio de CIELAB</i>	35

Introducción

Una de las enfermedades más agresivas en los cultivos de papa, es el de “La Gota” o “Tizón tardío”, de acuerdo con el artículo “Alternativas de control biorracionales sobre *Phytophthora infestans*, fitopatógeno causante de la gota en papa”, la enfermedad puede llegar a destruir la planta en poco tiempo, lo cual ocasiona pérdidas económicas (Cruz Trujillo et al., 2021).

El presente trabajo de investigación se enfoca en realizar el diagnóstico de la enfermedad de “La Gota” en los cultivos de papa en Colombia mediante el uso de técnicas de procesamiento de imágenes, algoritmos de aprendizaje y Deep Learning. Se ha desarrollado un algoritmo que procesa imágenes y determina si las hojas de la planta están afectadas por la enfermedad. Durante la ejecución del algoritmo, la imagen se somete a varias etapas de procesamiento para obtener una segmentación ideal.

Para conseguirlo, se ha empleado la transformación del espacio de color RGB y sRGB a CIELAB, la cual permite separar las diferentes capas y eliminar la dimensión de color amarillo y rojo (componente "a") en la transformación de sRGB a CIELAB, dejando únicamente los componentes de luminosidad y la dimensión del color verde y azul (componente "b"). De esta forma, se ha logrado obtener el umbral y generar la binarización de la imagen, a la que se ha aplicado un filtro para eliminar el ruido, utilizando una operación morfológica de dilatación y erosión con un elemento estructurante con forma de diamante, lo que ha permitido mejorar la segmentación.

Además, en la transformación de RGB a CIELAB, se utiliza la binarización del componente "a" para multiplicarlo por la imagen obtenida del filtro previo. De este modo, se logra una binarización final de alta calidad, cuyos bordes son identificados por el algoritmo y se

sobreponen en la imagen original en escala de grises. Así, se verifica que el algoritmo esté reconociendo la zona afectada en los casos en que la enfermedad se evidencia en la imagen, lo que permite obtener la segmentación final y almacenarla para su utilización en el entrenamiento de la red neuronal.

Una vez obtenida la segmentación de cada imagen, se procede al entrenamiento de una red neuronal convolucional (CNN) para clasificar las imágenes en dos etiquetas, “gota” y “sana”. Para lograr una uniformidad en la base de datos, es necesario redimensionar todas las imágenes. La arquitectura de la CNN se define con tres capas de activación ReLU, una capa de agrupamiento máximo, una capa completamente conectada, una capa softmax y una capa de clasificación. Las opciones de entrenamiento para la CNN se determinan utilizando un algoritmo de optimización “sgdm” (Stochastic Gradient Descent with Momentum), con una tasa de aprendizaje inicial de 0,01. El entrenamiento se detendrá después de cuatro épocas y se realiza una validación cruzada después de cada época.

Durante el proceso de entrenamiento de la CNN, se utiliza el 70% del conjunto de datos de entrenamiento junto con las condiciones y opciones de entrenamiento definidas. Luego, se utiliza el 30% restante de la base de datos para clasificar las imágenes del conjunto de datos de validación, almacenando las etiquetas de clase reales en una variable. Para calcular la precisión del modelo, se compara el vector de etiquetas de predicción con el vector de etiquetas reales para determinar cuántas de las etiquetas predichas son correctas. El algoritmo cuenta cuántas etiquetas han sido predichas correctamente utilizando la función 'sum'. Posteriormente, se divide este número por el número total de etiquetas en el conjunto de validación (obtenido con 'numel(YValidation)') para obtener la precisión del modelo. En resumen, la precisión del modelo

representa la proporción de imágenes correctamente clasificadas por el modelo en el conjunto de validación.

El algoritmo de aprendizaje finaliza con la creación de una matriz de confusión que evalúa el rendimiento del clasificador en el conjunto de datos, obteniendo una precisión del 98.11%. Esta matriz se muestra en un gráfico para obtener una mejor visualización de los resultados obtenidos por el modelo.

Pregunta de Investigación

¿Es posible realizar un reconocimiento de los síntomas de la enfermedad Gota en los cultivos de papá utilizando Deep Learning?

Planteamiento del Problema

En los cultivos de papa hay gran variedad de enfermedades, sin embargo, esta investigación se basa específicamente en la enfermedad conocida comúnmente como “Gota de papa” o “Tizón tardío”, dicha enfermedad se produce debido al agente conocido científicamente como *Phytophthora infestans*, el cual es uno de los organismos fitopatógenos más limitantes en la producción de papa, no solo por los altos costos de su control a causa de las condiciones ambientales que favorecen su desarrollo y diseminación, sino también por las pérdidas económicas que ocasiona ya que cerca del 6% de los costos totales de la producción de la papa están representados en los fungicidas para la prevención y el control de esta enfermedad. (*Plagas y Enfermedades de La Papa*, n.d.)

La enfermedad de la Gota en los cultivos de papa ocasionan pérdidas parciales, aunque no se pierde la planta completamente, es necesario eliminar un 40% de las hojas, lo que afecta sobre todo a los productores que venden por peso (Pineda Giraldo et al., 2020), por otro lado, en diferentes investigaciones se ha encontrado que el *Phytophthora infestans* (la Gota o tizón tardío de la papa) es una enfermedad grave en la producción de papa en el norte de Europa, el control de la enfermedad a menudo requiere 10 o más aplicaciones de fungicidas durante la temporada de crecimiento.

En la década de 1840 en Europa la enfermedad de la Gota causó una devastación de alimentos en todo el continente; en Irlanda los pobres dependían abrumadoramente de la papa, por lo que hubo hambruna y más de un millón de personas murieron y muchas más se vieron obligados a migrar. (Cruz Trujillo et al., 2021), en Colombia el cultivo de papa se destaca a nivel nacional como una de las actividades agropecuarias más importantes ya que debido a su explotación se genera el desarrollo de muchos sectores, al igual que en Irlanda, la papa es el

producto de consumo masivo sobre todo en la dieta de los estratos de menor ingreso.

(Betancourth G. et al., 2008)

Los síntomas de la enfermedad de la Gota en cultivos de papa se pueden presentar en las hojas, el tallo y en el tubérculo, generalmente en las hojas se reconoce debido a que se presentaran manchas necróticas de color marrón claro a oscuro, en los tallos es posible reconocer manchas alargadas lo cual hace que se vuelva quebradizo y finalmente, en el tubérculo se reconocerá por las manchas irregulares de color marrón rojizo y de apariencia húmeda en su superficie. Al momento de realizar un corte longitudinal se podrá observar unas estrías necróticas que irán de la superficie al centro del tubérculo; por otro lado, el signo más representativo es la presencia de una pelusilla blanquecina en el envés de las hojas. (Perez, 2012).

Actualmente el reconocimiento de los diferentes síntomas de la enfermedad de la Gota en los cultivos de papa se realiza visualmente, lo cual requiere de un seguimiento continuo y por ende consume mucho tiempo, genera mayores costos y puede arrojar datos inexactos, a partir de los reprocesos que se pueden presentar en el reconocimiento de los síntomas de la enfermedad. Por lo tanto, se plantea la siguiente pregunta de investigación: ¿Es posible realizar un reconocimiento de los síntomas de la enfermedad Gota en los cultivos de papá utilizando Deep Learning?

Justificación

La planta de papa dependiendo de sus variedades presenta un crecimiento erecto a semierecto, los tubérculos son tallos modificados y constituyen los órganos de reserva de la planta, varían en tamaño, forma, color y masa, sus hojas son compuestas y la flor es bisexual; tiene fruto que cuando madura es una baya generalmente de color verde oscuro, el cual contiene las semillas, que se conocen como semillas botánicas. (Márquez-Vasallo et al., 2020). Las papas se cultivan en diferentes suelos que varían de arenosos a arcillosos, con diferente capacidad de retención de agua, es preferible que estos suelos tengan PH 5.5 y 7.0 de baja salinidad, debido a que sus raíces no miden más de 60cm de largo, no tienen mucha facilidad para aprovechar los nutrientes y la humedad en las profundidades de un perfil de suelo.

El cultivo de papa es uno de los más representativos de los Andes colombianos, sin embargo, tiene altos costos de producción, entre los cuales se encuentran las semillas, enmiendas, abonos orgánicos, reguladores fisiológicos y fertilizantes que representa el 36%; su producción se concentra en 8 departamentos; adicional a esto, es un gran generador de empleo, fuente de ingreso y sustento alimentario para una gran parte de la población colombiana sobre todo en el sector campesino.(Torres-Hernandez et al., 2020).

En la actualidad el precio de la papa en Colombia ha sido motivo de debate nacional, de acuerdo con las declaraciones del ciclista y campesino Nairo Quintana y el gerente de la Federación Colombiana de Productos de Papa Germán Palacio, indican que la causa principal del alza en la papa ha sido por los altos costos de los insumos, adicional a esto el líder gremial también indica que debido a la poca oferta que altera los precios también se debe a la renuncia del 15% de los productores a este cultivo, agrega que otra razón de este incremento es debido a que: “Hace dos años, producir una hectárea de papa valía 21 millones de pesos, este año,

producir la misma hectárea vale 32 millones de pesos. Un pequeño productor no puede invertir estos 11 millones de más, lo que ha generado que muchos se hayan ido del cultivo”. (LEISOL, 2022)

Esta investigación se realiza para poder hacer un reconocimiento de los diferentes síntomas que puede presentar un cultivo de papa cuando tiene la enfermedad de la Gota o Tizón Tardío utilizando Deep Learning. Por medio del procesamiento de imágenes e inteligencia artificial, se plantea entrenar una máquina que identifique si una imagen de la hoja del cultivo posee la enfermedad de la Gota o es una imagen de una hoja sana, en una fase mucho más temprana para que los expertos en agricultura tomen las decisiones respecto al tratamiento de la enfermedad, puedan ahorrar gastos en fungicidas y no tengan pérdidas en la producción.

Objetivos

Objetivo General

Diseñar un algoritmo para la detección de la enfermedad Gota en cultivos de papa en Colombia usando Deep Learning.

Objetivos Específicos

Realizar una búsqueda del estado del arte sobre detección de enfermedades en diferentes cultivos usando procesamiento de imágenes y Deep Learning.

Obtener una base de datos que contenga imágenes de cultivos de papa con y sin la enfermedad de la Gota.

Implementar algoritmos de procesamiento de imágenes para la segmentación de los objetos de interés.

Seleccionar las características que permitan la identificación de la enfermedad de la GOTA en las imágenes de los cultivos de papa.

Marco Conceptual

Cuando se tratan de temas relacionados con los cultivos, se puede decir que parte de las investigaciones se enfocan en el reconocimiento de enfermedades y plagas, debido a que este es un proceso que el agricultor ha venido practicando durante años de manera visual y manual, por lo que ha generado mayores costos y poca precisión. Actualmente, se han desarrollado diferentes técnicas en el procesamiento de imágenes y desarrollo de algoritmos que ayuden a automatizar el reconocimiento por medio de inteligencia artificial, y de esta manera lograr a través de herramientas tecnológicas reconocer en una fase inicial determinadas enfermedades o plagas en los cultivos.

En el caso del cultivo de papa, la enfermedad de la Gota se reconoce debido a las lesiones que esta deja ya que son oscuras y necróticas de forma circular a lesiones de forma irregular, generalmente aparece primero en el borde de las hojas inferiores, extendiéndose a las hojas superiores y al tallo finalizando en los tubérculos

Figura 1

Síntoma típico de la enfermedad Gota en una hoja



Fuente. (Pineda Giraldo et al., 2020)

Figura 2

Síntoma típico de la enfermedad de la Gota a lo largo del tallo



Fuente. (Pineda Giraldo et al., 2020)

Figura 3

*Síntoma típico de la enfermedad Gota causado por *Phytophthora infestans* en una planta*



Fuente. (Pineda Giraldo et al., 2020)

Tal y como se muestra en las imágenes es posible realizar un reconocimiento visual de la enfermedad, ahora bien, se requiere que la máquina pueda realizar dicho reconocimiento, es por esta razón, que se utilizan técnicas de procesamiento de imagen e inteligencia artificial, con el fin de que la máquina pueda reconocer un cultivo afectado por la enfermedad y un cultivo sano. Para ello, se debe realizar la ejecución de diferentes pasos, entre estos, la recolección de imágenes de

tal manera que se tenga una cantidad determinada de dichas imágenes, tanto del cultivo sano, como del cultivo afectado por la enfermedad, puesto que la máquina debe entender las características de ambos casos. Dichas imágenes deben estar con parámetros establecidos, como el tamaño y resolución, de tal manera, que no afecte el resultado esperado, teniendo en cuenta, que la enfermedad tiene una fase inicial en la hoja, nos centraremos en ella, puesto que cuando la enfermedad ya llega al tallo está en una fase avanzada.

Una vez obtenida la recolección de imágenes, se define tanto las técnicas de segmentación como las técnicas de inteligencia artificial las cuales se desean implementar, para ello, es necesario reconocer algunas:

Técnicas de Segmentación

Conversión del modelo de color RGB a imagen gris: Es un proceso que forma parte del procesamiento de imágenes con el fin de buscar mejorar las propiedades de una imagen y facilitar la extracción de determinadas características, por medio de la binarización que se realiza luego de la conversión de la imagen a color en su respectiva escala de grises. (Cortés Osorio et al., 2011)

Espacio de color RGB: Se utiliza ampliamente en las gráficas por computadora. El rojo, verde y azul son tres colores aditivos primarios. Un sistema diseñado con el espacio de color RGB se puede aprovechar una gran cantidad de rutinas existentes de software. (Bodhe & Mukherji, 2013)

Espacio de color YUV: Se utiliza en transmisiones de televisión europeas. Los componentes Y, U, V transmiten la información de color y también pueden reducir las interdependencias de los componentes RGB. (Bodhe & Mukherji, 2013)

Espacio de color YIQ: Es similar al espacio YUV, se utiliza en los sistemas de televisión estadounidenses. La señal “Y” representa la intensidad de eliminación mientras que la señal “I” y “Q” describen conjuntamente el matiz y la saturación.(Bodhe & Mukherji, 2013)

Espacio de color HSI: Es compatible con la percepción humana. H da información de color, S refleja la pureza del color (saturación) y el brillo se denota por I que es la intensidad.(Bodhe & Mukherji, 2013)

Espacio de color $I_1 I_2 I_3$ en donde,

$$I_1 = 0,333R + 0,333G + 0,333B$$

$$I_2 = 0,500R + 0,500G - 0,500B$$

$$I_3 = -0,250R + 0,500G - 0,250B$$

(Bodhe & Mukherji, 2013)

Espacio de color HSV: Es similar a HSI, donde el valor del componente V esta dado por una transformación alternativa como el máximo componente RGB.

Efecto en la calidad de segmentación: Se utilizan diferentes espacios de color porque cada espacio indica una cantidad diferente de información en una imagen por lo que se selecciona el componente de espacio de color más adecuado por la segmentación.(Bodhe & Mukherji, 2013)

Umbral de Histograma Basado en Entropía Algoritmo: La segmentación de imágenes en color mediante el umbral basado en la entropía depende del contenido de información el cual es medido por la entropía que se utiliza para seleccionar el dominio del espacio de color de modo que sea el más grande entre otros espacios de color bajo prueba.(Bodhe & Mukherji, 2013)

Umbralización o binarización: Permite separar los pixeles de una imagen en escala de grises, estas pueden ser de dos categorías dependiendo el valor del umbral de intensidad; umbral

global, es único sobre toda la imagen, es decir es fijo, se utiliza generalmente cuando se tiene una iluminación homogénea en toda la imagen y un histograma bimodal, por otro lado, el umbral local, tiene generalmente la imagen cambios de iluminación y una distribución no bimodal, por lo que, se debe dividir la imagen en sub-imágenes para poder encontrar el umbral adecuado para cada una de ellas, es decir, se tiene múltiples umbrales, uno para cada sub-imagen.(Triana et al., 2016)

K-means: Es un algoritmo de aprendizaje automático no supervisado, es utilizado para segmentar una región de interés a partir de las imágenes, ya que agrupa objetos en k grupos basándose en determinadas características y sus similitudes.(Gómez-Camperos et al., 2022)

Detección de bordes: Esta técnica busca cambios en la función de intensidad de una imagen, de tal manera, que los bordes que se detectan correspondan a los píxeles en donde la función cambie abruptamente, por lo que, considera la aproximación más común para detectar discontinuidades significativas en la intensidad de la imagen. Generalmente se utilizan derivadas de primer y segundo grado para determinar estos cambios de intensidad, sin embargo, solo sirve para funciones de imágenes escalares, por ejemplo, imágenes en escala de grises, no es posible en imágenes vectoriales como RGB.(Montero de Juan et al., 2019)

Morfología Matemática: comúnmente denota de una rama de la biología que trata de la forma y la estructura de animales y plantas; y es una herramienta para extraer componentes de la imagen que son útiles en la representación de regiones. El lenguaje como tal de la morfología matemática es teoría de conjuntos, los cuales representan las formas de objetos de una imagen.(Cazorla Quevedo, 1999)

Técnicas de inteligencia artificial

Entrenamiento de SVM (máquinas de soporte vectorial): Generalmente se emplea para realizar tareas de clasificación y regresión. Consiste en encontrar un hiperplano óptimo como la función que separa dos clases de datos. La clasificación con menor error es la que consigue el hiperplano, es decir, la distancia entre el plano y los vectores soporte sea la mayor posible.(Sánchez Martínez, 2018)

Redes neuronales: Capaces de solucionar problemas de modo conjunto, esto quiere decir, que el conocimiento se halla distribuido entre todos los elementos que componen la red de manera implícita en la estructura de la propia red. En una red neuronal es muy posible encontrar características como:

Capacidad de aprendizaje: Para esto se han creado algoritmos de aprendizaje inductivo que permite su entrenamiento a partir de un conjunto de ejemplos.

Velocidad de procedimientos: Generalmente el tiempo de activación de una neurona es de 1 ms, pero es mucho mayor en un componente eléctrico, pueden ser nano segundos, sin embargo, hay ciertas tareas como el reconocimiento de imágenes, en donde el cerebro es mucho más rápido.

Tolerancia a fallos: los sistemas conexionistas presentan un fenómeno de degradación gradual de la respuesta a causa del ruido en la señal de entrada o fallos en las propias neuronas.
(Cazorla Quevedo, 1999)

En resumen, una red neuronal es una herramienta que modela de forma matemática el funcionamiento de las neuronas del cerebro. Para ello se realiza simulando un procesador de datos, realizando operaciones entre información entrante y saliente, para ambos casos en forma de números.(Sánchez Martínez, 2018).

Redes Neuronales Convolucionales (CNN): Realiza operaciones de convolución entre una capa de entrada y un filtro, dando como resultado, un mapa de características. Dicho procedimiento se repite con varias capas intermedias, con el objetivo de extraer características de la imagen con distintos niveles de abstracción, de tal manera, que la propia red convolucional actúa tanto de extractor de características como de clasificador. (Sánchez Martínez, 2018)

Deep Learning: Consiste en el aprendizaje de un algoritmo mediante ejemplos, es utilizado para realizar tareas como clasificación de imágenes, sonido o texto. Se necesita entrenar dicho modelo mediante una gran cantidad de datos etiquetados, también requiere de una arquitectura de red neuronal, con un determinado número de capas y parámetros característicos. La gran ventaja de este modelo es que tiene una precisión muy alta, en donde, en ocasiones puede superar al ser humano. (Sánchez Martínez, 2018)

Machine Learning: Es el desarrollo de técnicas que permitan el aprendizaje a una máquina, en donde se pueden destacar diferentes tipos de aprendizaje automático como:

Aprendizaje Supervisado: Se basa en datos etiquetados previamente por el ser humano.

Aprendizaje no Supervisado: El algoritmo no requiere de intervención humana para poder etiquetar las muestras de entrenamiento.

Aprendizaje por Refuerzo: El algoritmo aprende mediante interacción con el entorno. (Sánchez Martínez, 2018)

Desarrollo del Algoritmo

Estudio del Arte

Para lograr la detección de la enfermedad de “La Gota” en los cultivos de papa mediante el procesamiento de imágenes, se lleva a cabo una búsqueda de trabajos de investigación en los que se emplean tanto el procesamiento de imágenes como el uso de Deep Learning para la detección de enfermedades en diversos cultivos. En la tabla 1, se muestra un resumen analítico y de cada trabajo de investigación que se consultó.

Tabla 1*Resumen Analítico.*

Título	Año	Autor	Cultivo	Plaga/ Enfermedad	Espacio de Color	Técnica Segmentación	Técnica IA	Resultados	Referencia
Selection of Color Space for Image Segmentation in Pest Detection	2013	Bodhe & Mukherji	Cultivos de invernadero	Plaga mosca blanca	RGB HSV YIQ YUV I ₁ I ₂ I ₃ HSI	Segmentación basada en la entropía para la detección de plagas.	Fuzzy c- means	La segmentación es satisfactoria y resalta la plaga, sin embargo, en algunas imágenes se resalta la plaga junto con las venas de una hoja, por lo tanto, no queda bien	(Bodhe & Mukherji, 2013)

								definida la plaga.	
Pest Detection on Leaf using Image Processing	2021	Nagar & Sharma	Cultivos de Mostaza y Frijol	Plaga Oruga Esponjosa	N/A	Transformación discreta de ondaletas	Algoritmo de Warping de Tiempo Dinámico	91,89% de presición	(Nagar & Sharma, 2021)
An Image Recognition Algorithm of Soybean Diseases and Insect Pests Based on Migration Learning and Deep	2020	Xin & Wang		Mildiu polvoriento de la soja. Mancha marrón de la soja. Mancha gris de la soja	RGB	N/A	SVM Red Fast R-CNN	100% de presición.	(Xin & Wang, 2020)

Convolution				Mancha					
Network				bacteriana de					
				la soja.					
Precision	2020	Reddy et	Cultivos en	Enfermedades	RGB	OTSU	K-means	Realiza el	(Reddy et
Method for		al	general	en general	HIS			cálculo del	al., 2020)
Pest Detection								área afectada	
in Plants								de la imagen	
using the								procesada	
Clustering									
Algorithm in									
Image									
Processing									

Nota. Se lleva a cabo un análisis de algunos de los artículos consultados para el estudio del arte con el fin de tomar ejemplos claros que puedan ayudar a la construcción de este proyecto de investigación.

Construcción Base de datos

Para construir la base de datos, fue necesario recolectar imágenes de cultivos de papa con y sin la enfermedad de la Gota de diferentes fuentes. En total, se recolectaron 232 imágenes, en su mayoría de un invernadero en la ciudad de Bogotá, otras en cultivos cercanos a La Reserva Natural “El Pajonal” en Cogua, Cundinamarca y unas pocas fueron tomadas de Internet. Para garantizar la calidad de las imágenes, se utilizaron las cámaras traseras del iPhone 12, que cuentan con dos lentes de 12 megapíxeles cada una. La configuración de la cámara se ajustó manualmente para optimizar la calidad de las imágenes, utilizando el modo de exposición ‘Automático’ y ajustando el valor de ISO para evitar imágenes demasiado oscuras o sobreexpuestas. Las imágenes se capturaron en formato HEIF para reducir el tamaño del archivo sin comprometer la calidad de la imagen. Además, se verificó que la lente de la cámara estuviera limpia y libre de obstrucciones antes de tomar cada imagen.

Antes de llevar a cabo el análisis de detección de la enfermedad “La Gota” en los cultivos de papa, se realiza un proceso de análisis visual en el que se evalúa la calidad de cada imagen, tanto de plantas sanas como afectadas por la enfermedad. A través de este análisis, se seleccionan cuidadosamente aquellas imágenes que muestran la enfermedad de manera más clara y representativa. Este proceso garantiza la confiabilidad y precisión del análisis posterior mediante el procesamiento de imágenes e inteligencia artificial. Además, gracias a la selección de las imágenes, los algoritmos de segmentación de imagen y Deep Learning pueden identificar y reconocer de manera más efectiva las características relevantes para la detección de la enfermedad en cuestión.

Características de la Enfermedad de “Gota de Papa” en los Cultivos

La enfermedad conocida como "Gota de papa" o "Tizón tardío" es causada por el agente conocido científicamente como *Phytophthora infestans*, y sus síntomas se manifiestan en las hojas, el tallo y los tubérculos. Los primeros signos de la enfermedad se observan comúnmente en las hojas, donde aparecen manchas necróticas de color marrón oscuro a claro, tal como se muestra en la Figura 4.

Figura 4

Hoja de Papa con la enfermedad de la Gota.



Fuente. Autoría Propia

Se ha determinado que la característica a analizar por el algoritmo es la mancha de color marrón oscuro a claro. En consecuencia, las imágenes se etiquetan y organizan en carpetas separadas según su estado de salud: "GOTA" para las imágenes que muestran la enfermedad y "SANA" para aquellas que no presentan síntomas, tal como se muestra en las figuras 5 y 6.

Figura 5

Base de datos imágenes de hojas de cultivos de papa con la enfermedad



Fuente. Autoría Propia

Figura 6

Base de datos imágenes de hojas de cultivos de papa sanas.



Fuente. Autoría Propia

En la siguiente etapa, se determina la técnica de segmentación apropiada para eliminar los fondos y sombras no deseados y reducir la región de interés. Al hacerlo, se logra un reconocimiento más preciso de la característica distintiva de la enfermedad.

Técnicas de Segmentación de Imágenes

Selección Espacio de Color

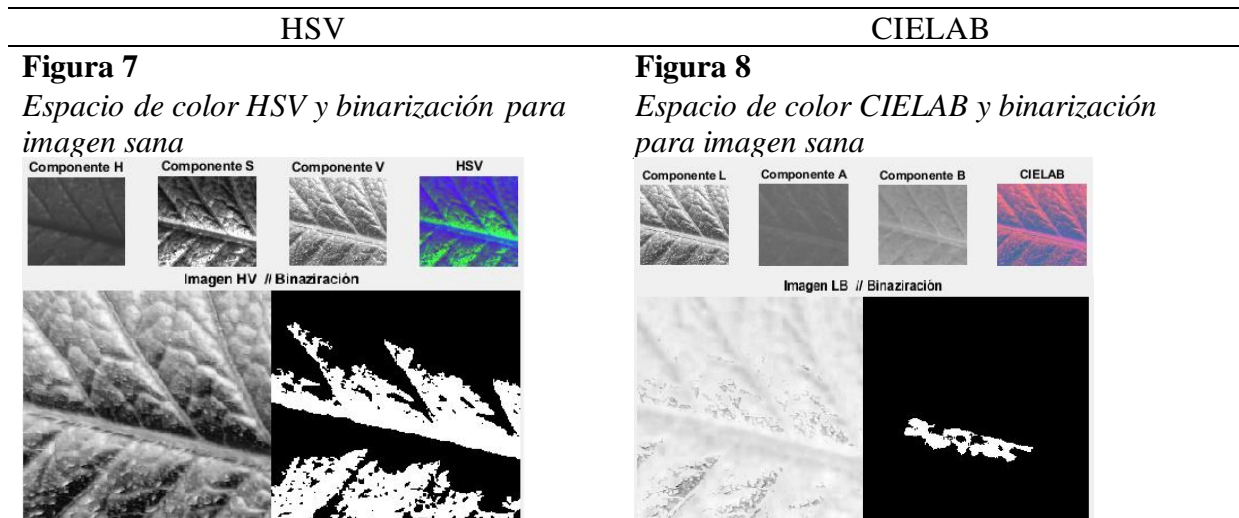
En esta etapa del proyecto, se busca determinar la técnica más adecuada para la extracción de características, tras haber obtenido y etiquetado la base de datos de imágenes.

Para segmentar los objetos de interés en las hojas de los cultivos de papa, se evaluaron dos opciones de espacio de color: CIELAB y HSV. Después de analizar los resultados obtenidos, se concluyó que CIELAB es la opción más apropiada debido a su mejor segmentación de los objetos de interés (ver figuras 8 y 10) en comparación con HSV (ver figuras 7 y 9). CIELAB está basado en la percepción humana del color, lo que permite una distinción precisa de los colores, especialmente en este proyecto donde los colores verde y negro son relevantes. Además, se observa que la binarización de las imágenes utilizando HSV genera una imagen con demasiado ruido. Por lo tanto, se emplea la segmentación de imágenes con el espacio de color CIELAB y operaciones morfológicas, lo que permite una detección más efectiva y precisa de las características de la enfermedad.

En la siguiente tabla comparativa se muestran los resultados obtenidos en la primera fase de segmentación de imágenes utilizando HSV y CIELAB

Tabla 2


Tabla comparativa segmentación de imágenes por medio de HSV vs segmentación de imágenes por medio de CIELAB



Fuente. Autoría Propia


Fuente. Autoría Propia

Figura 9
Espacio de color HSV y binarización para imagen con Gota



Fuente. Autoría Propia

Figura 10
Espacio de color CIELAB y binarización para imagen con Gota



Fuente. Autoría Propia

Nota. Se evaluaron dos opciones de espacio de color: CIELAB y HSV y se realiza la comparación con respecto a los resultados obtenidos.

El uso del espacio de color CIELAB ha permitido destacar claramente la enfermedad en algunas imágenes, sin embargo, en las imágenes etiquetadas como sanas, se ha observado la presencia de ruido, aunque en menor medida que con el espacio de color HSV. Para solucionar este problema, se ha utilizado la herramienta de procesamiento de imágenes conocida como operaciones morfológicas, que permite modificar la forma y estructura de los objetos de interés en una imagen. En particular, se ha empleado la operación de erosión para eliminar el ruido y las imperfecciones en las imágenes. Esto ha mejorado significativamente los casos en que la imagen es de una hoja sana (ver figura 11).

Figura 11

Imagen Sana aplicando operación morfológica



Fuente. Autoría Propia


Transformación Espacio de Color CIELAB

El algoritmo utilizado en este proyecto realiza una transformación de espacio de color sRGB a CIELAB, que consta de una capa de luminosidad 'L' o brillo, una capa de cromaticidad 'A' que indica dónde se ubica el color a lo largo del eje rojo-verde y una capa de cromaticidad 'B' que indica la ubicación del color a lo largo el eje azul-amarillo. Para realizar esta conversión, se utiliza la función “*makecform*” de Matlab para crear una matriz de transformación y,

posteriormente, la función “*applyform*” para aplicar dicha matriz a la imagen original y obtener una imagen convertida al espacio de color CIELAB. Luego se separan los componentes L, A y B para su posterior análisis (ver figuras 12 y 13).

Figura 12


Componentes transformación sRGB a CIELAB en imagen con la enfermedad.



Fuente. Autoría Propia

Figura 13

Componentes transformación sRGB a CIELAB en imagen Sana.




Fuente. Autoría Propia

Cabe destacar que el espacio de color sRGB es un estándar utilizado en dispositivos electrónicos como monitores, cámaras digitales y otros dispositivos, ya que cuenta con una curva de transferencia de gamma estandarizada que describe cómo los valores de los píxeles en una imagen se convierten en valores de brillo en una pantalla (The MathWorks, n.d.-c). A diferencia del espacio de color RGB, el sRGB es específico para estos dispositivos.

Así mismo se almacenan en diferentes variables las capas obtenidas en la conversión de RGB a CIELAB (ver figuras 14 y 15)

Figura 14

Componentes transformación RGB a CIELAB en imagen con la enfermedad.



Fuente. Autoría Propia

Figura 15

Componentes transformación RGB a CIELAB en imagen Sana



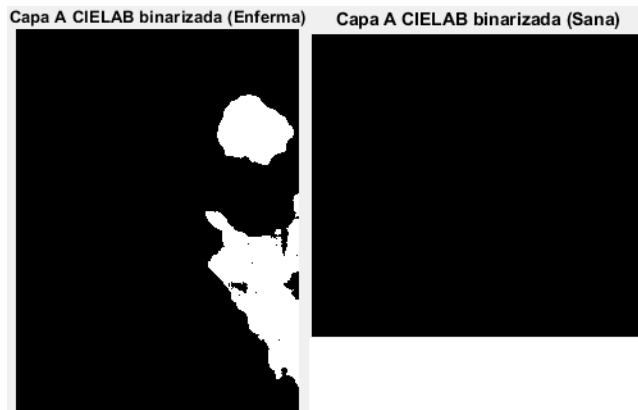
Fuente. Autoría Propia

En el caso de la transformación de RGB a CIELAB, se binariza la capa A para facilitar la segmentación de los objetos en la imagen (ver figura 16). Por otro lado, en la transformación de sRGB a CIELAB se realiza una operación aritmética en los componentes de la imagen CIELAB. Se suma el componente B, que representa la cantidad azul-verde, al componente L, que representa la luminosidad, y luego se resta el componente A, que representa la cantidad rojo-verde, a la suma anterior (ver figura 17). Esta operación permite resaltar las diferencias de color

entre las diferentes partes de la imagen, lo que mejora la segmentación de los objetos presentes en la imagen.

Figura 16


Capa A binarizada, en imagen con la enfermedad y sin la enfermedad



Fuente. Autoría Propia

Figura 17

Imagen LB, en imagen con la enfermedad y sin la enfermedad.



Fuente. Autoría Propia


Umbralización, Binarización y Operación Morfológica

Después de llevar a cabo la operación aritmética mencionada, se determina el umbral de la imagen resultante utilizando la función “*graythresh*”. Esta función calcula un umbral global empleando el método de Otsu a partir de la imagen en escala de grises. A continuación, se binariza la imagen utilizando la función “*imbinarize*”, pero se invierte la imagen binaria para que los objetos sean blancos y el fondo sea negro. Finalmente, se eliminan los objetos con un área menor que el umbral especificado utilizando la función “*bwareaopen*”.

Para reducir el ruido, se aplica una operación morfológica creando un objeto de dilatación mediante la función “*strel*”, el cual se crea a partir de una matriz de tamaño definido. Luego, se realiza la erosión utilizando la función “*imerode*” y se aplica a la imagen binaria junto con el objeto de dilatación. Se genera el contorno de la imagen binaria utilizando función “*bwperim*”, y se sobrepone el contorno a la imagen original utilizando otra función, en este caso “*labeloverlay*” (ver figura 18).

Figura 18

Imagen binarizada y resultado operación morfológica en una imagen que presenta la enfermedad.




Fuente. Autoría Propia

Además, se realiza una multiplicación de la Capa A que se binarizó anteriormente con la imagen final filtrada obtenida a través de la operación morfológica. Este proceso produce la binarización más refinada, a partir de la cual se pueden obtener los bordes mediante la función “*bwperim*”, la cual busca el perímetro si su valor es distinto de cero y está conectado al menos a un píxel cuyo valor es cero (MATLAB *Bwperim* - MathWorks América Latina, n.d.). A continuación, se sobrepone la imagen de bordes sobre la imagen en escala de grises para identificar las características relevantes de la enfermedad (ver figura 19).

Figura 19

Reconocimiento de bordes en imagen original en escala de grises



Fuente. Autoría Propia

Segmentación Final

Para lograr la segmentación final, primero se convierte la imagen original en un valor de punto flotante utilizando la función “*im2double*”. A continuación, se crea una matriz de segmentación final de tres dimensiones que utiliza tanto la imagen binarizada como la imagen original. Cada canal de la imagen original (rojo, verde y azul) se multiplica elemento por elemento con la imagen binarizada, y los resultados se almacenan en la matriz de segmentación final. Este proceso garantiza que sólo se mantengan los valores de píxeles en la imagen original que corresponden a los píxeles activos (blancos en la imagen binarizada), eliminando así los

píxeles inactivos y conservando los píxeles de interés en la imagen original. Esta técnica permite la separación de los objetos de interés de la imagen original (ver figura 20).

Figura 20

Segmentación final



Fuente. Autoría Propia

Automatización de segmentación y uniformidad para la Base de datos.

Una vez desarrollado el código para la segmentación de imágenes, se procede a la automatización del algoritmo para realizar la segmentación de manera masiva. Para ello, se organizan las imágenes de cultivos enfermos en la carpeta "GOTA" y las imágenes de cultivos sanos en la carpeta "SANA". De esta forma, el código puede leer las imágenes de ambas carpetas y definir una lista con los nombres de cada una de las imágenes.

Para procesar las imágenes de la carpeta "SANA", el código utiliza un ciclo "for" que recorre la lista de archivos y redimensiona cada imagen a un ancho de 306 píxeles y un alto de 286 píxeles, que es el tamaño promedio aproximado de las 235 imágenes que el código debe

procesar. Luego, el algoritmo de segmentación se aplica a cada imagen, generando una imagen segmentada final. Esta imagen se guarda en un archivo en la ruta "\dataset\sana" (ver figura 21).

El proceso para las imágenes de la carpeta “GOTA” es similar. El código recorre la lista de archivos y redimensiona cada imagen. Después, se aplica el algoritmo de segmentación para obtener la imagen segmentada final, que se guarda en un archivo en la ruta “\dataset\gota” (ver figura 22).

Figura 21


Imágenes sanas segmentadas



Fuente. Autoría Propia

Figura 22

Imágenes con la enfermedad segmentadas



Fuente. Autoría Propia

Algoritmo Entrenamiento de la Red Neuronal Convolutacional.

Para detectar la enfermedad Gota en cultivos de papa en Colombia usando Deep Learning, se diseñó un algoritmo que se inicia con el entrenamiento de una red neuronal convolutacional (CNN), la cual se considera uno de los modelos más eficientes para el aprendizaje profundo. La CNN cuenta con capas de convolución y agrupación que incluyen filtros para detectar características esenciales en la entrada (He, 2020). El proceso de entrenamiento utiliza el 70% del conjunto de datos de entrenamiento junto con las condiciones y opciones de entrenamiento definidas, mientras que el 30% restante se utiliza para clasificar las imágenes del conjunto de datos de validación. De esta manera, se asegura que el modelo esté adecuadamente ajustado y que la precisión de la clasificación sea lo suficientemente alta para su aplicación práctica.


Generalmente la arquitectura de la CNN incluye una capa de entrada, donde se especifica el tamaño y el formato de las imágenes; capas de convolución, donde se aplican filtros para producir mapas de características; capas de Unidad Lineal Rectificada (ReLU), que aplican una operación de umbral a la entrada; capas de agrupación máxima, que reducen el tamaño espacial de los mapas de características; y una capa de salida fina. (He, 2020).

Por consiguiente, se entrenó la CNN para clasificar imágenes en dos etiquetas: “gota” y “sana”. Para ello, se redimensionaron todas las imágenes de la base de datos para darles uniformidad. La arquitectura de la CNN incluye 3 capas ReLU, una capa de agrupación máxima, una capa completamente conectada, una capa softmax y una capa de clasificación. (The MathWorks, n.d.-a).

Las opciones de entrenamiento para la CNN se establecen mediante el uso de un algoritmo de optimización llamado "sgdm", que significa "Stochastic Gradient Descent with Momentum" o "Gradiente Estocástico Descendente con Momento" en español (The MathWorks, n.d.-b) La tasa de aprendizaje inicial se fija en 0,01. El entrenamiento se detiene después de 4 épocas y se realiza una validación cruzada después de cada una de ellas. Durante el entrenamiento, se utiliza el conjunto de validación para evaluar el rendimiento de la red. La red se evalúa en el conjunto de validación cada 30 iteraciones, lo que se conoce como la frecuencia de validación. Esta información se presenta en una gráfica generada por el software durante el proceso de entrenamiento (ver figura 23).

Figura 23

Proceso de entrenamiento.



Fuente. Autoría Propia

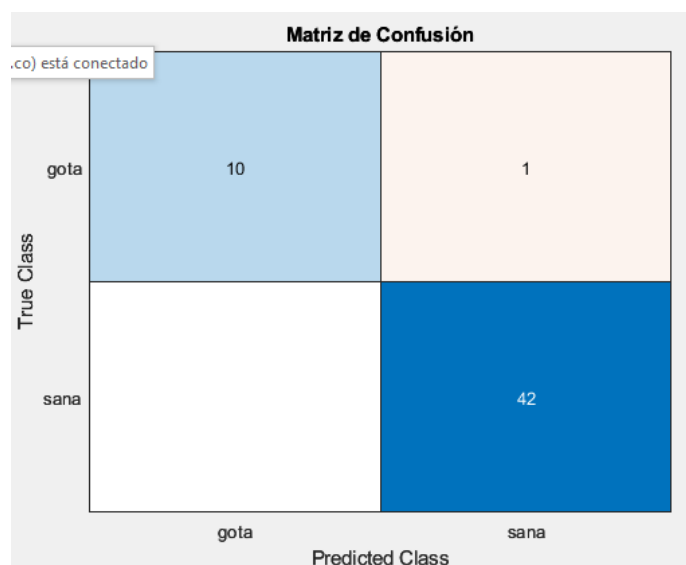
Para proceder a entrenar la CNN con los datos de entrenamiento, las condiciones de entrenamiento y las opciones de entrenamiento definidas anteriormente, para luego realizar la clasificación de las imágenes del conjunto de datos de validación utilizando la CNN entrenada y se almacenan las etiquetas de clase reales en la variable “YValidation”; así mismo, se realiza un cálculo para determinar la precisión del modelo entrenado. En donde primero se compara el vector de etiquetas de predicción “Ypred” con el vector de etiquetas reales “YValidation” utilizando el operador de igualdad “==”. Esta operación devuelve un vector de valores lógicos donde los valores verdaderos indican que la etiqueta predicha y la etiqueta real son iguales y los valores falsos indican que son diferentes. Luego la función sum es utilizada para contar el número total de valores verdaderos, lo que indica la cantidad de etiquetas predichas

correctamente, para finalizar se divide este número por el número total de etiquetas para obtener la precisión del modelo.

Finalmente se calcula la matriz de confusión del modelo, para evaluar el rendimiento del clasificador en el conjunto de datos, para este caso la función toma como entrada el vector de etiquetas verdaderas y el vector de etiquetas predichas, para almacenar la matriz de confusión en una variable que luego es mostrada en un gráfico (ver figura 24)

Figura 24

Matriz de confusión.



Fuente. Autoría Propia

En la matriz de confusión, la diagonal principal (de arriba a la izquierda a abajo a la derecha) representa los aciertos en la clasificación, mientras que los elementos fuera de la diagonal principal representan los errores en la clasificación. La visualización de la matriz de confusión como un gráfico proporciona una representación más intuitiva de las predicciones correctas e incorrectas en cada clase, lo que facilita la interpretación y evaluación del rendimiento del clasificador.

Para calcular la precisión y exactitud del modelo, se utilizan las siguientes ecuaciones:

$$\text{Precisión} = \frac{VP}{VP + FP}$$
$$\text{Exactitud} = \frac{VP + VN}{VP + FP + FN + VN}$$

En el caso específico de este modelo y teniendo en cuenta los valores de la matriz de confusión de la figura 24, se obtienen los siguientes resultados:

$$\text{Precisión} = \frac{10}{10 + 1} = \frac{10}{11} = 0.9$$
$$\text{Exactitud} = \frac{10 + 42}{10 + 1 + 0 + 42} = \frac{42}{53} = 0.9811$$

Estos valores concuerdan con la figura 23, donde se muestra que la exactitud del modelo es del 98.11%.

Resultados

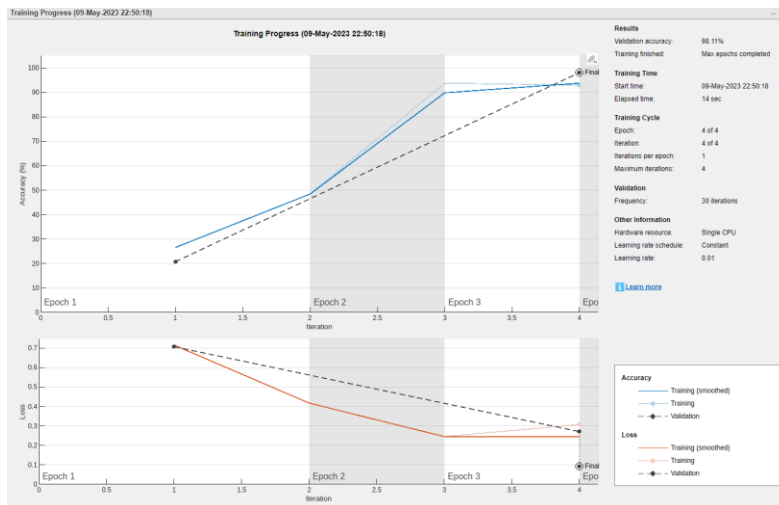
En el presente proyecto de investigación se utiliza un enfoque para la detección de la enfermedad de la Gota en cultivos de papa en Colombia, que emplea técnicas de segmentación de imágenes tales como la conversión de espacios de color, binarización y la aplicación de operaciones morfológicas. Además, se emplean técnicas de Deep Learning basadas en redes neuronales convolucionales (CNN) para la clasificación de imágenes.

Los algoritmos para la segmentación de imágenes y Deep Learning se ejecutan en Matlab Online, utilizando una máquina con sistema operativo Windows 10 Pro de 64 bits, procesador Core i5 y el navegador Microsoft Edge Versión 113.0.1774.35. El algoritmo Deep Learning se ejecuta alrededor de 30 veces, utilizando las imágenes de la base de datos.

Los resultados obtenidos demuestran una precisión del 98,11% (ver figuras 25 y 26).

Figura 25

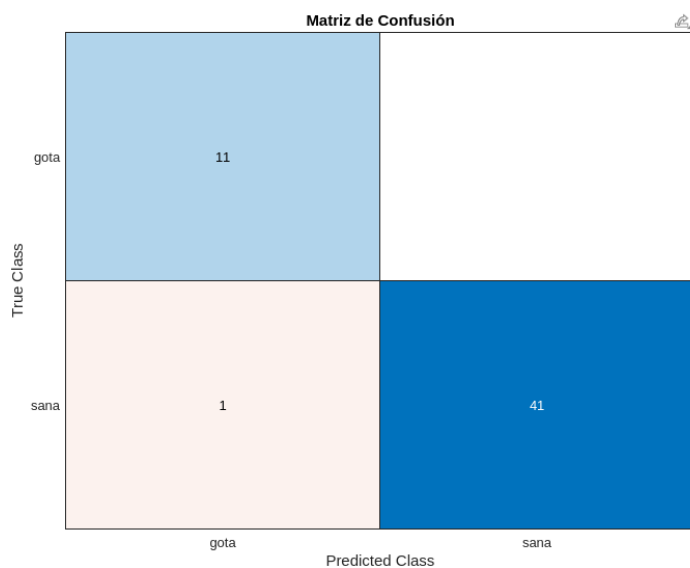
Proceso de Aprendizaje. Presión 98.11%.



Fuente. Autoría Propia

Figura 26

Matriz de Confusión. Presión 98.11%.



Fuente. Autoría Propia

En donde podemos interpretar esta matriz de la siguiente manera:

La clase "Gota" tiene 11 muestras correctamente clasificadas como positivas (verdaderos positivos, TP).

La clase "Gota" tiene 0 muestras incorrectamente clasificadas como negativas (falsos negativos, FN).

La clase "Sana" tiene 1 muestras incorrectamente clasificadas como positivas (falsos positivos, FP).

La clase "Sana" tiene 41 muestras correctamente clasificadas como negativas (verdaderos negativos, TN).

En resumen, el modelo ha clasificado correctamente 11 muestras de la clase "Gota" y 42 muestras de la clase "Sana". No ha cometido errores en la clasificación de la clase "Gota", pero ha cometido 1 error en la clasificación de la clase "Sana".

Para mejorar la investigación, se podría ampliar la base de datos de imágenes utilizada en el entrenamiento y evaluación de la red neuronal, lo que podría contribuir a mejorar la precisión del modelo en la detección de la enfermedad en los cultivos de papa.

Conclusión

El objetivo del proyecto consiste en el diseño de un algoritmo que utiliza técnicas de Deep Learning para la detección de la enfermedad de la Gota en cultivos de papa en Colombia. El enfoque de la investigación se centra en la implementación de algoritmos de procesamiento de imágenes que emplean técnicas de segmentación para la identificación de las manchas necróticas presentes en las hojas de los cultivos de papa, las cuales constituyen características distintivas de la enfermedad.

Para la construcción de la base de datos, se realizan visitas a un invernadero ubicado en la ciudad de Bogotá y a cultivos cercanos a La Reserva Natural "El Pajonal" en Cogua, Cundinamarca, donde se capturan diversas fotografías. Estas imágenes son sometidas a un proceso de preselección para descartar aquellas de baja resolución. A continuación, se lleva a cabo la segmentación correspondiente y se utiliza un algoritmo de Deep Learning para clasificar las imágenes, obteniendo una precisión del 98.11%.

Adicionalmente, se genera una matriz de confusión que permite realizar un análisis y cálculo de precisión para validar los resultados obtenidos.

Referencias

- Bodhe, T. S., & Mukherji, P. (2013). Selection of color space for image segmentation in pest detection. *2013 International Conference on Advances in Technology and Engineering (ICATE)*, 1–7. <https://doi.org/10.1109/ICAdTE.2013.6524753>
- Cazorla Quevedo, M. A. (1999). *Técnicas de inteligencia artificial*. Digitalia.
<https://bibliotecavirtual.unad.edu.co/login?url=https://search.ebscohost.com/login.aspx?direct=true&db=nlebk&AN=317998&lang=es&site=eds-live&scope=site>
- Cortés Osorio, M. S. J. A., Ardila Urueña, M. S. W., & Mendoza Vargas, M. S. J. A. (2011). Técnicas alternativas para la conversión de imágenes a color a escala de grises en el tratamiento digital de imágenes. *Scientia et Technica Año XVII*, 47.
- Cruz Trujillo, J. J., Hernández Gutiérrez, V., Sánchez Leal, L. C., & Fuentes Quintero, L. S. (2021). Alternativas de control biorracionales sobre *Phytophthora infestans*, fitopatógeno causante de la gota en papa. *Nova*, 19(36), 31–48. <https://doi.org/10.22490/24629448.5287>
- Gómez-Camperos, J. A., Jaramillo, H. Y., & Guerrero-Gómez, G. (2022). Digital image processing techniques for detection of pests and diseases in crops: a review. *Ingeniería y Competitividad*, 24(1), 1–17.
<https://bibliotecavirtual.unad.edu.co/login?url=https://search.ebscohost.com/login.aspx?direct=true&db=asn&AN=154991106&lang=es&site=eds-live&scope=site>
- He, Z. (2020). Deep Learning in Image Classification: A Survey Report. *2020 2nd International Conference on Information Technology and Computer Application (ITCA)*, 174–177.
<https://doi.org/10.1109/ITCA52113.2020.00043>
- MATLAB bwperim - MathWorks América Latina*. (n.d.). Retrieved April 23, 2023, from <https://la.mathworks.com/help/images/ref/bwperim.html>

- Montero de Juan, J., Gómez González, D., & Rodríguez González, J. T. (2019). *Problemas de segmentación y detención de bordes en imágenes digitales con información borrosa*.
<https://eprints.ucm.es/id/eprint/55256/1/T41074.pdf>
- Nagar, H., & Sharma, R. S. (2021). Pest Detection on Leaf using Image Processing. *2021 International Conference on Computer Communication and Informatics (ICCCI)*, 1–5.
<https://doi.org/10.1109/ICCCI50826.2021.9402606>
- Pineda Giraldo, J. M., Calderón Quintero, A., & Castaño Zapata, J. (2020). *Guía ilustrada de enfermedades y patógenos en cultivos hortícolas*. Universidad De Caldas.
<https://bibliotecavirtual.unad.edu.co/login?url=https://search.ebscohost.com/login.aspx?direct=true&db=nlebk&AN=2656157&lang=es&site=eds-live&scope=site>
- Reddy, K. A., Reddy, N. V. M. C., & Sujatha., S. (2020). Precision Method for Pest Detection in Plants using the Clustering Algorithm in Image Processing. *2020 International Conference on Communication and Signal Processing (ICCSP)*, 894–897.
<https://doi.org/10.1109/ICCSP48568.2020.9182190>
- Sánchez Martínez, M. (2018). *Detección de personas mediante técnicas de aprendizaje automático: SVM y CNN*.
<https://bibliotecavirtual.unad.edu.co/login?url=https://search.ebscohost.com/login.aspx?direct=true&db=edsoai&AN=edsoai.on1088720134&lang=es&site=eds-live&scope=site>
- The MathWorks, Inc. (n.d.-a). *Create Simple Deep Learning Neural Network for Classification - MATLAB & Simulink Example - MathWorks*. Retrieved April 9, 2023, from
<https://la.mathworks.com/help/deeplearning/ug/create-simple-deep-learning-network-for-classification.html?lang=en>

The MathWorks, Inc. (n.d.-b). *Training options for stochastic gradient descent with momentum - MATLAB - MathWorks América Latina*. Retrieved April 6, 2023, from

<https://la.mathworks.com/help/deeplearning/ref/nnet.cnn.trainingoptionssgdm.html>

The MathWorks, Inc. (n.d.-c). *Understanding Color Spaces and Color Space Conversion - MATLAB & Simulink - MathWorks América Latina*. Retrieved April 6, 2023, from

<https://la.mathworks.com/help/images/understanding-color-spaces-and-color-space-conversion.html>

Triana, N., Jaramillo, A. E., Gutiérrez, R. M., & Rodríguez, C. A. (2016). Técnicas de umbralización para el procesamiento digital de imágenes de GEM-Foils. *Scientia et Technica*, 21(4), 352–359.

<https://bibliotecavirtual.unad.edu.co/login?url=https://search.ebscohost.com/login.aspx?direct=true&db=asn&AN=122337615&lang=es&site=eds-live&scope=site>

Xin, M., & Wang, Y. (2020). An Image Recognition Algorithm of Soybean Diseases and Insect Pests Based on Migration Learning and Deep Convolution Network. *2020 International Wireless Communications and Mobile Computing (IWCMC)*, 1977–1980.

<https://doi.org/10.1109/IWCMC48107.2020.9148331>