



DIAGNÓSTICO DEL HONGO FoCR4T EN PLANTAS MUSÁCEAS MEDIANTE UNA RED
NEURONAL CONVOLUCIONAL

FoCR4T fungus diagnosis in Musaceae plants through a convolutional neural network

YEIMY ANDREA CIFUENTES GALVIS

INSTITUCIÓN UNIVERSITARIA POLITÉCNICO GRANCOLOMBIANO

BOGOTÁ

FACULTAD DE INGENIERÍA, DISEÑO E INNOVACIÓN

INGENIERÍA DE SISTEMAS

2021

DIAGNÓSTICO DEL HONGO FoCR4T EN PLANTAS MUSÁCEAS MEDIANTE UNA RED
NEURONAL CONVOLUCIONAL

FoCR4T fungus diagnosis in Musaceae plants through a convolutional neural network

YEIMY ANDREA CIFUENTES GALVIS

0812040472

Trabajo de Grado para optar al título de Ingeniera de Sistemas

Asesor Temático:

GABRIEL EDUARDO ÁVILA BUITRAGO, MsC

INSTITUCIÓN UNIVERSITARIA POLITÉCNICO GRANCOLOMBIANO

BOGOTÁ

FACULTAD DE INGENIERÍA, DISEÑO E INNOVACIÓN

INGENIERÍA DE SISTEMAS

2021

AGRADECIMIENTOS

El presente proyecto de grado constituye un hito muy importante en la culminación de mis estudios como Ingeniera de Sistemas, permitiéndome avanzar para cumplir mis sueños. Sin embargo, este no es un camino que yo hubiese podido recorrer sola y es por ello que quiero agradecer enormemente a todas las personas que caminaron junto a mí en este proceso. A mi profesor Gabriel Eduardo Ávila, por sus ideas, su conocimiento, su paciencia y la confianza que depositó en mí. Sin él no hubiese podido materializar este proyecto.

A mis padres Paulo y Jaqueline, por brindarme siempre su apoyo y amor y por enseñarme que vale la pena luchar por los sueños. A Jeison porque merece todo lo bueno que su hermana le pueda brindar.

Así mismo, quiero agradecer al profesor Jhon Alexander Peñafiel por permitirme creer que sí era posible.

A Alejandro por su amor sincero y apoyo en cada paso de la vida.

Infinitas gracias.

RESUMEN

El presente Proyecto de grado tiene como objetivo abordar los conceptos relacionados con las redes neuronales y su uso práctico aplicado al procesamiento y análisis de imágenes en el proceso de diagnóstico de la infección por la Raza 4 Tropical de *Fusarium Oxysporum* (Foc R4T) en plantas musáceas (bananos y plátanos). Pretende también comprobar cómo la tecnología y el saber pueden crear herramientas que contribuyen al desarrollo de la agricultura en un país como Colombia e indirectamente propender por la seguridad alimentaria.

Palabras Clave: Redes Neuronales, Machine Learning, Procesamiento de Imágenes, Inteligencia Artificial, Python, Hongos, Hojas de plantas de banano.

ABSTRACT

The present degree project aims to address the concepts related with neural networks and their practical use applied to image processing and analysis as a useful tool in the diagnosis of infection by *Fusarium Oxysporum* tropical race 4 (Foc TR4) in musaceous plants (bananas and plantains). It also aims to prove how technology and knowledge can create tools that contribute to the development of agriculture in a country like Colombia and indirectly contribute to food security.

Keywords: Neural Networks, Machine Learning, Image processing, Artificial Intelligence, Python, fungus, Banana leaf.

Contenido

AGRADECIMIENTOS	3
RESUMEN	4
ABSTRACT.....	5
Tabla de Ilustraciones	8
Listado de Tablas	10
INTRODUCCIÓN	11
OBJETIVOS	13
General.....	13
Específicos	13
CAPÍTULO I: Descripción del Proyecto	14
1.1. PLANTEAMIENTO DEL PROBLEMA.....	14
1.1. JUSTIFICACIÓN	16
1.2. ALCANCE DEL PROYECTO	18
1.3. ESTADO DEL ARTE	19
CAPÍTULO II: Marco Teórico	21
2. MARCO TEÓRICO.....	21
2.1. La columna vertebral del proyecto: Las redes Neuronales.....	21
2.2. Arquitectura de las redes neuronales	23
i. La unidad básica de las redes neuronales artificiales: El Perceptrón simple.....	23
i. El Perceptrón multicapa o las Redes neuronales FeedForward.....	24
ii. Redes Neuronales Profundas	25
iii. Redes Neuronales Convolucionales	25
Componentes de la red neuronal convolucional	26
2.3. Conceptos asociados a las Redes Neuronales.....	27
i. Capa de Entrada.....	27
ii. Época (Epoch)	27
iii. Batch size.....	27
iv. Funciones de Activación	28
v. Función de Pérdida	28
vi. Herramientas para el manejo de redes neuronales y Deep Learning.....	28
CAPÍTULO III: DISEÑO METODOLÓGICO	29
3. ESTRATEGIA METODOLÓGICA.....	29
3.1. Fase 1.....	29

3.2.	Fase 2.....	30
3.3.	Fase 3.....	30
3.4.	Fase 4.....	31
CAPÍTULO IV: DESARROLLO DEL PROYECTO		31
4.	Antecedentes	31
4.1.	Revisión de literatura y búsqueda de información	37
	Etapa 1: Construcción de la pregunta de investigación	38
	Etapa 2: Búsqueda de información y evidencia.....	39
	Etapa 3: Aplicación de criterios de exclusión.....	39
4.4.	Visitas de campo.....	43
	Tena, Cundinamarca	43
	La Mesa, Cundinamarca	45
	Guamo, Tolima	48
4.5.	Captura de imágenes y creación de un dataset	50
4.6.	Criterios de preprocesamiento de las imágenes.....	52
4.7.	Diseño de la red neuronal convolucional.....	53
	4.7.1. Requerimientos de alto nivel.....	53
	4.7.2. Herramientas y Librerías Existentes	53
4.8.	Definición de Casos de Uso	55
4.9.	Implementación o desarrollo de la red neuronal convolucional	56
	4.9.1. Preprocesamiento de las imágenes	56
	4.9.2. Arquitectura implementada.....	59
	4.9.3. Especificaciones del Dataset	60
	4.9.4. Proceso de Entrenamiento de la red neuronal	60
	4.9.5. Matriz de Confusión.....	60
	4.9.6. Función de pérdida.....	62
	4.9.7. Accuracy o Exactitud del modelo	63
CAPÍTULO V: RESULTADOS OBTENIDOS		64
5.	Resultados	64
5.1.	Entregables	64
CAPÍTULO VI: CONCLUSIONES		65
6.	Conclusiones.....	65
CAPÍTULO VII: TRABAJO FUTURO		69
7.	Trabajo Futuro	69
Referencias y Bibliografía		71

Tabla de Ilustraciones

Ilustración 1: Imagen de una planta musácea con clorosis en sus hojas. Tomado por Jeimy Andrea Cifuentes en la finca San Diego, Vereda Alto Grande, La Mesa Cundinamarca.	18
Ilustración 2: Diagrama de un Perceptrón simple con 5 entradas.....	23
Ilustración 3: Arquitectura del perceptrón multicapa o Red FeedForward de múltiples capas. (Simplilearn, 2021)	24
Ilustración 4: Diagrama general de una Red Neuronal convolucional. (Íconos tomados de Flaticon.com, diseñados por Icongeek26)	26
Ilustración 5: Proyecto propuesto en Semillero SIRT - Diagnóstico de Foc R4T en Plantas de banano.	32
Ilustración 6: Presentación del proyecto, diseñada para la 4a Semana TIC (primer semestre de 2021).	33
Ilustración 7: Infografía que describe el proyecto – 4a Semana TIC, primer semestre de 2021..	34
Ilustración 8: Descripción del modo de acción del hongo Foc R4T.....	35
Ilustración 9: Portada de la presentación empleada durante el taller "Una red neuronal con Tensorflow".	37
Ilustración 10: Revisión Sistemática y sus etapas. (íconos gratuitos, propiedad de icons8).	37
Ilustración 11: Marchitamiento y clorosis de la hoja, avanza desde el borde hacia el centro de esta. Finca San Diego. Tomado por: Jeimy Andrea Cifuentes.	41

Ilustración 12: Hoja seca y suspendida. Unida a la planta por el pseudotallo. Finca San Diego. Tomado por: Jeimy Andrea Cifuentes.	41
Ilustración 13: Hoja en posición vertical debido a la pérdida de turgencia. Finca San Diego. Tomado por: Jeimy Andrea Cifuentes	42
Ilustración 14: Ruta hacia la vereda Peña Negra, desde Bogotá (Cundinamarca). Finca "El Caimo".	44
Ilustración 15: Ruta hacia la vereda Alto Grande, desde Bogotá (Cundinamarca). Finca "San Diego".	45
Ilustración 16: Racimo de plátano "popocho", cosechado en la finca "San Diego". Foto por: Jeimy Andrea Cifuentes.	47
Ilustración 17: Planta de banano afectada por clorosis en sus hojas y lesiones visibles en hojas y tallos. Finca "San Diego". Tomada por: Jeimy Andrea Cifuentes.	48
Ilustración 18: Ruta hacia la vereda Cerro Gordo, desde Bogotá (Cundinamarca).	49
Ilustración 19: Hoja de planta musácea, tomada en la Finca San Diego. Por: Jeimy Andrea Cifuentes.	52
Ilustración 20: Detalle de la hoja de planta musácea (Ilustración 15) sin fondo.	52
Ilustración 21: Imagen de 200x200px, en escala de grises y con detección de bordes.	58
Ilustración 22: Resumen del modelo para la fase de extracción de características de las imágenes	59
Ilustración 23: Matriz de confusión asociada al proyecto.	62
Ilustración 24: Función de pérdida en las fases de entrenamiento y validación.	63
Ilustración 25: Exactitud durante las fases de entrenamiento y validación.	63

Listado de Tablas

Tabla 1: Caso de uso "Seleccionar Imagen"	55
Tabla 2: Caso de Uso "Analizar Imagen"	56
<i>Tabla 3: Caso de Uso: Clasificar Imagen</i>	56

INTRODUCCIÓN

El crecimiento económico en Colombia se encuentra cimentado en la vocación y el potencial del sector agropecuario y el subsector agrícola (entre otros), desempeñando un importante rol en la generación de ingresos, de puestos de trabajo e impulsando a la economía nacional, ya que el sector agropecuario cuenta con una importantísima participación en el PIB del país.

Según el DANE, el sector agropecuario fue la actividad económica que más creció en 2020, con una variación de 2.8%. Esto, teniendo en cuenta que fue durante un año atípico en el cual la economía en general del país se vio seriamente afectada por la llegada del COVID 19.

En este orden de ideas, para el ministro de Agricultura y Desarrollo Rural, Rodolfo Zea Navarro, “el sector agropecuario jalonó la economía y no permitió que ésta decreciera más profundamente” (Soto, 2021).

Teniendo en cuenta lo anterior, es posible evidenciar la importancia del sector agropecuario y todos sus subsectores para la economía del país, el bienestar de los trabajadores del campo y la generación de riqueza. Sin embargo, no todo son cifras en crecimiento que conlleven al desarrollo de las zonas rurales, puesto que es bien sabido que el subsector agrícola en nuestro país enfrenta grandes y variados retos relacionados con:

- El cambio climático (control de la producción y cosecha de alimentos y productos vegetales en condiciones climáticas adversas y variables).
- Las dificultades a nivel de infraestructura que implican inconvenientes para los productores y campesinos al comercializar sus productos.

- El uso indiscriminado de agroquímicos y pesticidas (los cuales afectan la calidad del agua, del aire y la salud de los trabajadores del campo).
- El control de plagas, a saber, bacterias, virus y hongos.

Se pretende entonces abordar la problemática asociada al monitoreo y control de las plagas en el proceso de producción de alimentos e insumos de origen vegetal desde la agricultura de precisión, poniendo la tecnología al servicio del desarrollo del subsector agrícola brindando herramientas a los trabajadores del campo con el objetivo de optimizar su labor a través de la toma rápida de decisiones.

OBJETIVOS

General

Proponer un método que utilice aprendizaje de máquina para diagnosticar la presencia del hongo Foc R4T en plantas musáceas (Bananos y plátanos) empleando el procesamiento y análisis de imágenes, como apoyo para procesos de diagnóstico y control de la enfermedad.

Específicos

- Identificar las características del hongo Foc R4T, como apoyo a los procesos de clasificación de lesiones producidas por el patógeno en las plantas musáceas.
- Establecer el diseño de red neuronal a utilizar, enfocado al reconocimiento de lesiones en imágenes de plantas.
- Implementar la red neuronal previamente diseñada.
- Evaluar el funcionamiento de la red neuronal diseñada para las tareas de reconocimiento del hongo.
- Documentar los resultados asociados al proceso de entrenamiento y pruebas.

CAPÍTULO I: Descripción del Proyecto

1.1. PLANTEAMIENTO DEL PROBLEMA

¿Cómo se pueden aplicar métodos de aprendizaje de máquina para diagnosticar la presencia del hongo *Fusarium Oxysporum* Raza 4 Tropical (Foc R4T o Fusariosis) en plantas musáceas ubicadas en algunas zonas de Cundinamarca (Colombia)?

Es importante tener en cuenta que en 2019 se confirmó la presencia del hongo *Fusarium Oxysporum* Raza 4 Tropical (Foc R4T) en Colombia, específicamente en plantaciones de banano ubicadas en el departamento de La Guajira, en donde se identificaron al menos 175 hectáreas de cultivo como afectadas por la infección. Debido a ello, el ICA (Instituto Colombiano Agropecuario) emitió una alerta declaratoria de emergencia nacional con el fin de “incrementar los controles y disponer de medidas adicionales para atender la zona afectada y mitigar el riesgo de contagio a otras regiones”.

Respecto al contagio por Foc R4T, esta es una infección que ataca las plantas musáceas. Su complejidad radica en la amplia capacidad de diseminación del patógeno mediante el movimiento de las partículas del suelo infectadas (por medio del aire, las llantas de vehículos, los zapatos de las personas y el andar de los animales), el agua, a través de los rizomas¹ de las plantas infectadas, el movimiento de material vegetal infectado, el uso de herramientas que han sido empleadas previamente en plantas infectadas, entre otros.

¹ Tallo subterráneo con varios brotes embrionarios (yemas) que crecen horizontalmente generando raíces.

Hasta aquí parecería ser una plaga común y corriente que se combate con algún tipo de fungicida, sin embargo, aún no existe una sustancia que erradique por completo el Foc R4T de una planta ya infectada. Por ello, la recomendación es actuar de forma rápida ante la sospecha de presencia del hongo, no sólo de manera local en las fincas o plantaciones de plátano y banano, sino en aeropuertos, terminales de transporte y fronteras (una labor compleja y dispendiosa, tomando en consideración que las fronteras de nuestro país son porosas). Por otro lado, es imprescindible también controlar las importaciones agropecuarias, así como el ingreso al país de maquinaria (o herramienta) agrícola usada y asegurar su pertinente desinfección.

Aunado a lo anterior, el manejo se hace mucho más difícil en la medida en que las clamidosporas² son capaces de sobrevivir en el suelo por periodos de tiempo de hasta 10 años, permaneciendo en estado de latencia hasta que genere algún síntoma visible en las plantas afectadas. Así mismo, es capaz de infectar otras plantas (distintas a las musáceas) de manera asintomática.

La presencia de este hongo no es nueva, pues había sido detectado en Asia hace al menos 30 años, afectando gravemente la producción de banano en este continente. Hoy por hoy, la infección por Foc R4T se considera una de las enfermedades más devastadoras y supone una gravísima amenaza para la producción global de banano.

Teniendo en cuenta lo anteriormente descrito, se pretende validar la pertinencia de implementar una red neuronal convolucional para el análisis y reconocimiento de imágenes, en

² Las clamidosporas son un tipo de esporas presentes en varias clases de hongos. Son una etapa del ciclo de vida del hongo que es capaz de sobrevivir en condiciones desfavorables (por largos periodos de tiempo en el caso del Foc R4T).

aras de facilitar el diagnóstico temprano de la infección por Foc R4T, disminuyendo los vectores de contagio al minimizar el contacto con plantas infectadas.

1.1. JUSTIFICACIÓN

Las redes neuronales constituyen un recurso muy importante para solucionar problemas asociados al reconocimiento de patrones, de imágenes y al análisis de sonidos, problemas que con métodos clásicos de programación sería particularmente complejo darles una solución eficiente. De manera general, las redes neuronales se fundamentan en una simulación de un proceso de aprendizaje enfocado en el reconocimiento de patrones³ con base en el entrenamiento que haya recibido la red neuronal y el conjunto de datos que se haya empleado en el proceso de entrenamiento.

Actualmente, el único mecanismo con el que cuentan los trabajadores de las plantaciones de musáceas para el diagnóstico efectivo de la infección por Foc R4T son las pruebas de laboratorio llevadas a cabo en muestras de tejido vegetal con sospecha de infección. Estas pruebas de laboratorio las realiza únicamente el Instituto Colombiano Agropecuario (ICA) y requieren contacto directo con la planta por parte del personal especializado del ICA, para obtener la muestra de tejido a analizar. Esto por supuesto supone la activación de un protocolo de bioseguridad para asegurar la no dispersión del patógeno.

³ Reconocimiento de Patrones: Procesamiento de un objeto con la intención de extraer toda la información asociada al conjunto de rasgos propios del mismo para así facilitar su clasificación y su identificación.

Teniendo en cuenta lo anteriormente descrito, se pretende aprovechar las bondades de la Inteligencia Artificial, la visión artificial y los conceptos asociados al Machine Learning para comprobar que el procesamiento y análisis de imágenes mediante una red neuronal convolucional podría ofrecer un diagnóstico de infección por Foc R4T temprano y eficaz, con el principal objetivo de facilitar la toma rápida de decisiones y minimizar los contagios entre plantas asociados al proceso de diagnóstico habitual y del desconocimiento de la presencia de la enfermedad en las plantaciones y fincas.

Principalmente, se pretende identificar:

- a. Clorosis⁴ generalizada en las hojas.
- b. Necrosis⁵ de los tejidos.
- c. Posiblemente, rajaduras en la base del pseudotallo⁶ y quiebre de las hojas en la base del peciolo⁷.

⁴ Amarillamiento del tejido de las hojas de las plantas musáceas debido a la falta de clorofila.

⁵ Muerte prematura de las células del tejido vegetal de las plantas musáceas.

⁶ Se asemeja a un tronco, pero en realidad es un falso tallo compuesto de vainas foliares superpuestas.

⁷ El rabillo que une el limbo de la hoja al pseudotallo de la planta.



Ilustración 1: Imagen de una planta musácea con clorosis en sus hojas. Tomado por Jeimy Andrea Cifuentes en la finca San Diego, Vereda Alto Grande, La Mesa Cundinamarca.

1.2. ALCANCE DEL PROYECTO

El presente trabajo de grado tiene el siguiente alcance:

- a. Recolectar un conjunto de imágenes de plantas con sospecha de infección de Foc R4T.
- b. Recolectar un conjunto de imágenes de plantas sanas.
- c. Definición, diseño y entrenamiento de una red neuronal convolucional para el procesamiento del conjunto de imágenes.
- d. Documentación de los resultados obtenidos.
- e. Comprobar la pertinencia de la hipótesis planteada inicialmente.

1.3. ESTADO DEL ARTE

El uso de visión artificial para analizar y procesar imágenes no es nuevo, pues su evolución se encuentra relacionada con el desarrollo de las cámaras fotográficas. Es así como el primer acercamiento a la visión artificial se remonta a los años 60s, cuando se diseña un prototipo basado en cámaras de visión y sistemas de procesamiento de las imágenes capturadas (Infaimon, 2020). Entendiendo así que el concepto de visión artificial puede ser aplicado al entretenimiento, a las industrias y en este caso a la agricultura.

En este orden de ideas, “Las enfermedades vegetales son factores importantes que derivan en una seria reducción de la calidad y la cantidad de productos que emanan de la agricultura. Por lo tanto, una detección y un diagnóstico temprano de dichas enfermedades es importante. Con este fin proponemos un enfoque basado en Deep learning que automatice el proceso de clasificación de las enfermedades en las hojas de plátano” (Amara, Bouaziz, & Algergawy, 2017) Se entiende entonces que poner el deep learning al servicio de la agricultura es un proceso beneficioso, pues mediante su aplicación es factible lograr la detección de las enfermedades en las hojas de plantas de banano y plátano de manera que se maximice la calidad de las cosechas.

“En India, cerca del 70% de la población depende de la producción agrícola. Las plantas y sus hojas se infectan con algunas enfermedades por medio de insectos que las transmiten de una planta a otra. Mientras tanto, la presencia de plantas infectadas puede reducir el rendimiento de la producción en la granja agrícola. Por lo tanto, es necesario detectar las enfermedades en las hojas y los frutos en una fase temprana.

La detección de enfermedades en la planta del plátano se está convirtiendo en un reto en el campo de la agricultura. La detección de enfermedades y la clasificación de la planta del plátano utilizando el procesamiento de imágenes es efectiva...” (N. Saranya, 2020)

“Se ha observado que la producción de plátano está plagada de numerosas enfermedades que causan grandes pérdidas a los agricultores pobres. Mediante el uso de la tecnología moderna de procesamiento de imágenes y técnicas de computación suave, estos pueden ser identificados en la etapa más temprana, permitiendo tomar las precauciones adecuadas para evitar más daños y, por ende, aumentar la producción saludable.” (A Athiraja, 2021)

CAPÍTULO II: Marco Teórico

2. MARCO TEÓRICO

A continuación, se presentan los conceptos más importantes empleados en el desarrollo del presente proyecto:

2.1. La columna vertebral del proyecto: Las redes Neuronales

Las redes neuronales son modelos simplificados cuya principal función es emular el proceso de aprendizaje del cerebro humano, en particular, imitando el funcionamiento de las redes neuronales biológicas con relación a la manera en la cual se crean conexiones entre neuronas (o se refuerzan conexiones existentes) para “aprender” algo nuevo. Conceptualmente esto suena muy bien, no obstante, las redes neuronales computacionales se basan más bien en un principio un poco más simple: Tomando como base algunos criterios específicos, debe existir una forma (o varias) de combinar dichos criterios con el objetivo de predecir un determinado resultado. Por ejemplo, en el caso particular del presente trabajo de grado, conociendo los píxeles de una hoja de una planta de banano habrá alguna forma de conocer si esta es una planta sana o si, por el contrario, tiene algún tipo de lesión que coincida con alguna enfermedad que hayamos documentado previamente.

Las redes neuronales son entonces el mecanismo que permite encontrar y aplicar la combinación idónea de criterios o parámetros para dar solución al problema y es que ese proceso de encontrar la combinación que mejor se adapte a la red neuronal es en últimas el proceso de **entrenamiento** de la red neuronal. Cuando se tiene una red neuronal ya entrenada, es posible

emplearla para llevar a cabo clasificaciones, predicciones o análisis, lo cual constituye el proceso de **aplicación** de la combinación de criterios.

Tomando en consideración las características de las Redes Neuronales, descritas por Simon Haykin, tenemos que las redes neuronales tienen una tendencia inherente a almacenar conocimiento y hacer posible su utilización posterior. Este mecanismo se asemeja al cerebro en dos aspectos:

- El conocimiento es adquirido por la red mediante un proceso que se denomina Aprendizaje.
- El conocimiento se almacena a través de la modificación de la fuerza (o el peso sináptico) de las diversas uniones entre neuronas. (Haykin, 1994)

Por otra parte, las ventajas que ofrece el uso de modelos computacionales basados en redes neuronales son:

- a. Aprendizaje Adaptativo: Las redes neuronales pueden aprender a realizar tareas con base en el entrenamiento/experiencia inicial. Pueden reconocer patrones mediante dicho entrenamiento, por lo cual no será necesario crear modelos complejos o precisar funciones de distribución de probabilidad.

Durante el proceso de aprendizaje, los pesos de las neuronas se ajustan con la intención de obtener un resultado determinado.

- b. Las redes neuronales tienden a ser tolerante a fallos, de modo tal que si se produce un fallo en algunas de las neuronas que componen el modelo el sistema no sufrirá una caída aunque el comportamiento del sistema se vea afectado.

2.2. Arquitectura de las redes neuronales

i. La unidad básica de las redes neuronales artificiales: El Perceptrón simple

El concepto de Perceptrón simple fue incorporado por **Frank Rosenblat** (Psicólogo estadounidense, quien fuera considerado uno de los padres del Deep Learning) en 1958. El perceptrón constituye el modelo más sencillo de una red neuronal artificial, pues consta de múltiples entradas, con una única capa de neuronas y una salida.




Ilustración 2: Diagrama de un Perceptrón simple con 5 entradas.

El perceptrón tiene varias entradas con cierto peso (pesos sinápticos) cada una, si el valor de salida de la suma y el peso de la entrada es mayor que 0, entonces la salida será 1. Si por el

contrario, el valor de la suma y el peso de la entrada es menor que 0, la salida de la neurona será 0.

$$f(x) = \begin{cases} 1 & \text{si } w \cdot x - u > 0 \\ 0 & \text{en otro caso} \end{cases}$$

i. El Perceptrón multicapa o las Redes neuronales FeedForward

El perceptrón por si solo al tener una única neurona, no será la mejor herramienta para resolver problemas complejos. Por ello, aquí entra un nuevo concepto y son las capas; estas permiten dar solución a problemas no lineales o, dicho de otro modo, permite representar funciones no lineales.

La arquitectura del perceptrón multicapa está compuesta de una capa de entrada, n capas ocultas y una capa de salida, así:

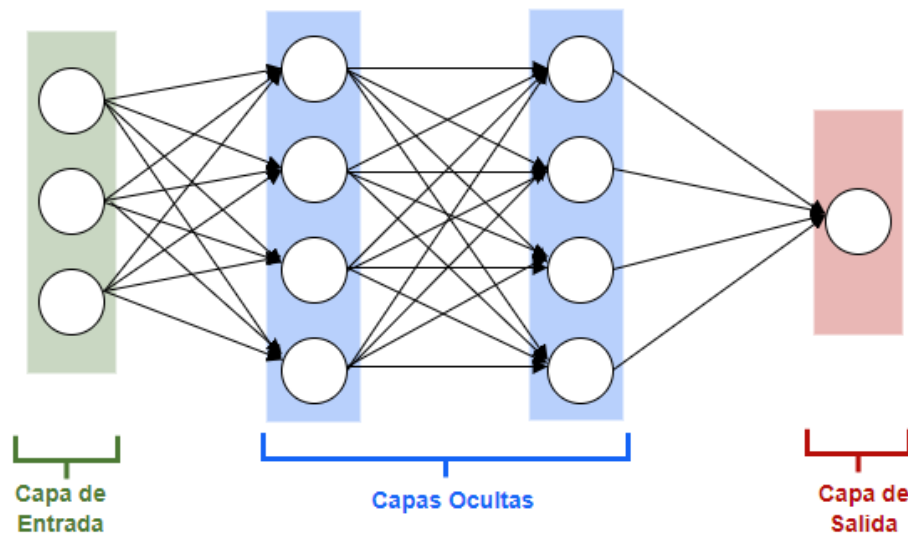


Ilustración 3: Arquitectura del perceptrón multicapa o Red FeedForward de múltiples capas. (Simplilearn, 2021)

Con relación al perceptrón simple, esta arquitectura permite analizar de mejor manera las características provenientes de los datos de entrada mejorando la calidad de los resultados

ii. Redes Neuronales Profundas

Una red neuronal profunda contiene numerosas capas ocultas entre las capas de entrada y las capas de salida. Su objetivo (Así como en las redes neuronales poco profundas) es modelar funciones no lineales complejas.

iii. Redes Neuronales Convolucionales

Las redes neuronales convolucionales son un tipo de red neuronal artificial que procesa la información de entrada imitando a las neuronas de la corteza visual⁸ primaria de un cerebro biológico. Su intención no es otra que distinguir las características específicas presentes en la información de entrada y así facilitar su clasificación o identificación. Se componen de numerosas capas ocultas especializadas altamente efectivas en tareas relacionadas con visión artificial⁹, así como en la clasificación y el reconocimiento de imágenes, por ejemplo.

⁸ Sección de la corteza cerebral responsable del procesamiento de la información visual.

⁹ Campo de la Inteligencia Artificial que permite a las máquinas reconocer imágenes u objetos, facilitando así la toma de decisiones.

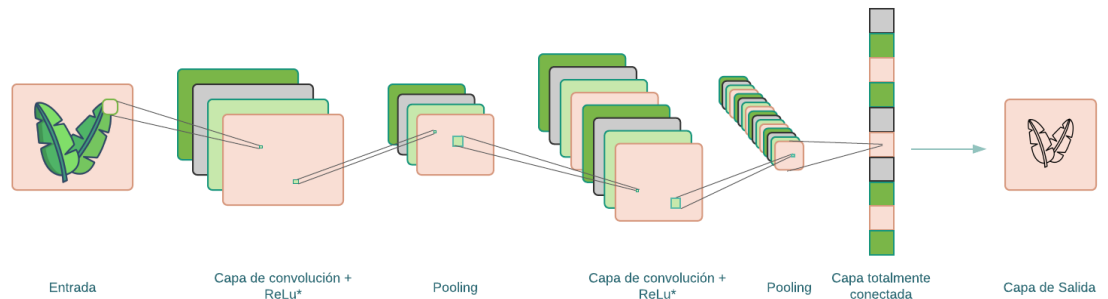


Ilustración 4: Diagrama general de una Red Neuronal convolutiva. (Íconos tomados de Flaticon.com, diseñados por Icongeek26)

Usualmente las redes neuronales convolucionales requieren menor capacidad de procesamiento comparado con otros tipos de redes neuronales como el perceptrón multicapa, así mismo, requieren menos parámetros de entrenamiento para sus capas ocultas, lo cual en definitiva hace que el proceso de identificación de características en una imagen dada, sea un poco más sencillo.

Componentes de la red neuronal convolutiva

La arquitectura de las redes neuronales convolucionales se compone de tres (3) tipos de capas, a saber:

- Capa de Entrada
- Capa Convolutiva
- Capa de Pooling o submuestreo
- Capa Completamente conectada

Adicionar capas convolucionales y capas de pooling permitirá extraer mayor cantidad de características de la imagen. Dichas características extraídas conformarán la salida de esta

etapa y será la entrada a la fase de clasificación que estará compuesta por capas completamente conectadas.

Estas dos etapas en conjunto forman una red neuronal convolucional (convolutional neural network, en inglés).

2.3. Conceptos asociados a las Redes Neuronales

i. Capa de Entrada

Las capas de entrada de una red neuronal son aquellas que reciben la información a analizar.

ii. Época (Epoch)

Corresponde a la cantidad de veces que se pasará cada ejemplo de entrenamiento por la red. En cada uno de los ciclos (Epoch), todos los datos que componen el dataset de entrenamiento pasarán por la red neuronal y así ella podrá extraer características de cada uno de los datos.

Si tenemos una 180 epochs y 3000 datos, durante cada uno de los ciclos los 3000 datos pasarán por la red neuronal.

iii. Batch size

El batch size corresponde a la cantidad de muestras que tomará la red neuronal para llevar a cabo su entrenamiento. Aunque se tenga un total de 3000 datos, se puede ajustar el batch size para que la red neuronal tome sólo algunos de los datos. Si el parámetro batch_size es igual a 30, sólo se entregarán las primeras 30

muestras de todo el conjunto de datos. Es importante tener en cuenta que ante un mayor batch size, se requerirá mayor tiempo de entrenamiento.

iv. Funciones de Activación

Es aquella función que modifica el resultado a la salida de una neurona. Esta función podría modificar el resultado o imponer una condición que debiera cumplirse para pasar a la siguiente capa.

En el presente proyecto se emplearon funciones de activación ReLu y Softmax.

v. Función de Pérdida

La función de pérdida es el indicador que nos dice qué tan bien cumple la red neuronal el objetivo con el cual fue diseñada. Cuanto menor sea el valor producto de esta función, más eficiente será la red neuronal.

vi. Herramientas para el manejo de redes neuronales y Deep Learning

Actualmente se cuenta con una amplia variedad de herramientas que facilitan el desarrollo de modelos de redes neuronales en las cuales se encuentran:

- Theano
- PyTorch
- Torch
- Microsoft Cognitive Toolkit
- Keras
- TensorFlow

CAPÍTULO III: DISEÑO METODOLÓGICO

3. ESTRATEGIA METODOLÓGICA

Para el desarrollo del presente trabajo de grado, se propusieron cuatro (4) fases enfocadas en el cumplimiento de los objetivos específicos.

Durante la primera fase (Fase 1) el propósito fue la investigación en torno al Foc R4T, identificar y poder clasificar las lesiones producidas por el patógeno en las plantas musáceas, así como tomar en consideración los avances en proyectos enfocados a la detección de plagas empleando visión artificial y que se hayan llevado a cabo previamente.

La segunda fase (Fase 2) tendría como objetivo la consecución de conjuntos de imágenes de plantas musáceas con sospecha de afectación por la infección de Foc R4T, así como de plantas afectadas por otras enfermedades y, por último, plantas sanas. Esto, en aras de entrenar la red neuronal.

Para la tercera Fase (Fase 3) se pretende desarrollar la red neuronal convolucional que permita lograr el objetivo de identificar la presencia de Foc R4T en plantas musáceas.

La cuarta fase (Fase 4) permitirá evaluar los resultados obtenidos con base en las variables definidas y el conjunto de imágenes empleado.

3.1.Fase 1

- 3.1.1. Búsqueda de información y construcción del estado del arte que facilite la identificación de los avances llevados a cabo en proyectos de agricultura de precisión enfocados a la detección de plagas empleando visión artificial.

- 3.1.2. Búsqueda de información relacionada con el modo de acción del Foc R4T, el modo de transmisión, así como los mecanismos de diagnóstico disponibles y la identificación visual de las lesiones que produce.
- 3.1.3. Identificación de los mecanismos de preprocesamiento de imágenes.
- 3.1.4. Identificación de los componentes asociados al diseño y construcción de una red neuronal convolucional y cómo estos interactúan para permitir la identificación de patrones en imágenes.

3.2. Fase 2

3.2.1. Visitas de trabajo al municipio de La Mesa, Cundinamarca, particularmente en la vereda Alto Grande para obtener imágenes de plantas enfermas. Fuerte sospecha de presencia de Foc R4T en el territorio.

3.2.2. Visitas de trabajo al municipio de Tena, Cundinamarca, vereda Peña Negra para obtener imágenes de planta sanas. No existe sospecha de Foc R4T en el territorio.

3.2.3. Visitas de trabajo al municipio del Guamo, Tolima, vereda Cerro Gordo para obtener imágenes de planta sanas. No existe sospecha de Foc R4T en el territorio.

3.3. Fase 3

- 3.3.1. Definición de requerimientos funcionales.
- 3.3.2. Definición de los parámetros de preprocesamiento de las imágenes.
- 3.3.3. Diseño y definición de la arquitectura de la red neuronal convolucional a utilizar.
- 3.3.4. Entrenamiento de la red neuronal definida, empleando el conjunto de imágenes de entrenamiento.

3.4. Fase 4

3.4.1. Documentación de resultados obtenidos

CAPÍTULO IV: DESARROLLO DEL PROYECTO

4. Antecedentes

En el marco de las reuniones del semillero SIRT durante el primer semestre de 2021, explorando opciones para encaminar la investigación asociada al *uso de drones para Internet de las cosas*, surgieron tres (3) grandes categorías que agrupaban algunas ideas de proyectos a desarrollar, como son, la seguridad en las ciudades, la descontaminación de fuentes hídricas y la agricultura de precisión. Como parte de esta última categoría, aflora mi propuesta de proyecto *“Diagnóstico de Foc R4T en plantas de banano”* que pretendía de manera general hacer uso de drones (o dispositivos raspberry) para recorrer plantaciones de banano y así capturar imágenes de las plantas a analizar, luego, emplearíamos una fase de preprocesamiento de imágenes para posteriormente enviar las imágenes recolectadas empleando tecnología 3G y 4G (tomando en consideración las restricciones a nivel de distancia de las veredas en donde se encuentran las plantaciones de banano).

Luego, vendría una fase de procesamiento de imágenes y de almacenamiento de los resultados obtenidos.

Por último, pretendíamos que los datos recolectados y la información procesada estuviesen disponibles en un sitio web, para consulta de manera pública por las entidades gubernamentales que así lo requirieran o para los usuarios que quisieran consultar si su zona se encontraba afectada por la plaga, por ejemplo.

Durante sus fases muy tempranas y de manera general, el proyecto lucía similar a lo plasmado en la siguiente imagen:

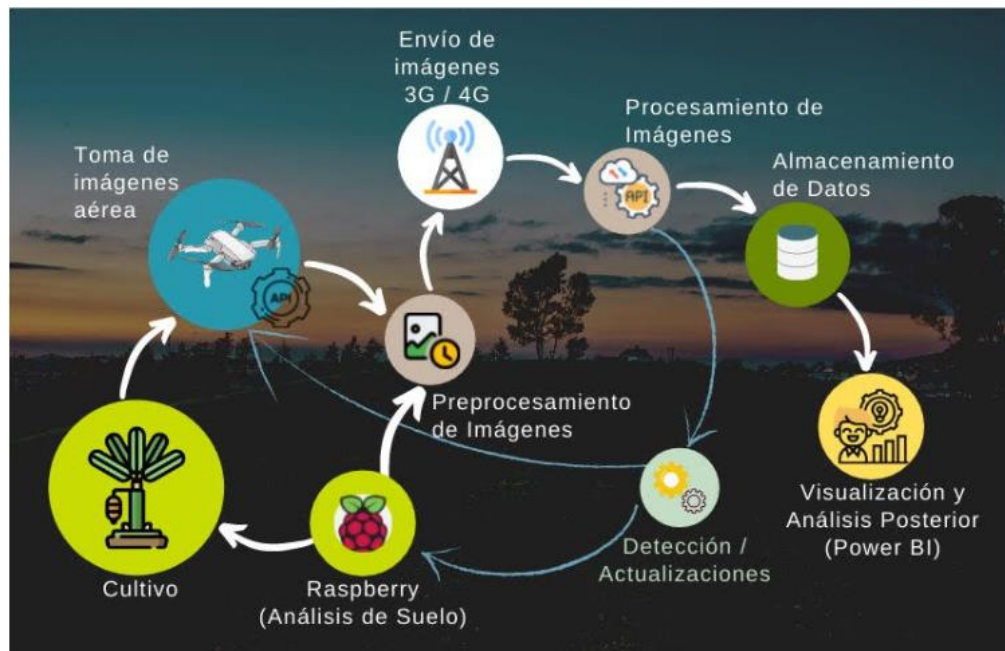


Ilustración 5: Proyecto propuesto en Semillero SIRT - Diagnóstico de Foc R4T en Plantas de banano.

En conjunto con el equipo de estudiantes que conformábamos el semillero, optamos por dividir este gran proyecto en varios subproyectos, como son:

- Captura y Preprocesamiento de Imágenes.
- Envío de Imágenes.
- Procesamiento de Imágenes y Análisis de resultados.
- Almacenamiento de datos
- Visualización (creación de reportes).

Esta estructura nos permitía a los equipos direccionar nuestro trabajo y acciones en torno a los subproyectos definidos.

En cada una de las reuniones de semillero, compartíamos avances, interrogantes, dudas e ideas.

Dicho trabajo, permitió que presentáramos el subproyecto “Detección de Foc R4T en Plantaciones de Banano”, durante la 4ª Semana TIC, llevada a cabo durante el primer semestre de 2021:



Ilustración 6: Presentación del proyecto, diseñada para la 4a Semana TIC (primer semestre de 2021).

Semillero SIRT



Detección de Foc R4T en plantaciones de banano (Variedades Cavendish y Musa AAA)

Diagnóstico y detección de marchitez por Fusarium Oxysporum Raza 4 Tropical (Foc R4T) en plantaciones de banano en Colombia, empleando captura de imágenes mediante dispositivos UAV, procesamiento y análisis de imágenes, así como su respectiva transmisión y almacenamiento.

Descripción

En Colombia, la producción de banano supone una fuente de ingresos muy importante para la economía de las familias campesinas de Colombia, así como también, constituye una fuente básica de alimento en miles de hogares colombianos, garantizando seguridad alimentaria y propendiendo por la reducción de la pobreza en nuestro país.

Teniendo en cuenta el grave problema que supone la infección por Foc R4T en plantaciones de banano, se pretende crear un sistema que facilite el diagnóstico, control y erradicación de las plantas contaminadas.



Subproyectos

Diagnóstico Recolección y procesamiento de imágenes	Hardware Diseño de equipos para recolección de imágenes.	Diseño de API Rest Para transmisión y almacenamiento de datos
Análisis posterior y visualización		

Ilustración 7: Infografía que describe el proyecto – 4a Semana TIC, primer semestre de 2021.

POLI
INSTITUTO TECNOLÓGICO DE COLOMBIA

THE GLOBAL GOALS

2 HAMBRE CERO

9 INDUSTRIA, INNOVACIÓN E INFRAESTRUCTURA

Fusarium Oxisporum Raza 4 Tropical

FOC R4T

Y cómo afecta a las plantaciones de banano (variedad cavendish) a nivel mundial

ES ALTAMENTE CONTAGIOSO

Se propaga fácilmente

Mediante el movimiento de material del suelo que se adhiere al a las llantas de los vehículos o el calzado de las personas, por medio del agua corriente, del uso compartido de herramientas y maquinarias agrícolas.

DIAGNÓSTICO

Se realiza mediante pruebas especializadas de laboratorio

Y dependen exclusivamente de la observación de los cultivos y la notificación al ICA, para llevar a cabo el diagnóstico (Mientras tanto, puede seguir su curso de propagación).

PRODUCE LA MUERTE DE LAS PLANTAS

Sin excepción

Una vez infestada, la planta morirá.

NO EXISTE UNA CURA

y tampoco hay posibilidades de manejo para una planta enferma

No existe un producto que garantice el control químico del patógeno, así como tampoco existe aún una variedad de banano/plátano que sea 100% resistente a la infección.

EL BANANO

garantiza seguridad alimentaria y supone una fuente de ingresos importantísima para los agricultores de nuestro país.

Por ello, enmarcamos nuestro proyecto en los Objetivos de Desarrollo Sostenible del Programa de las Naciones Unidas para el Desarrollo, enfocados en los Objetivos 2: "Hambre Cero" y 9: "Industria, Innovación e Infraestructura".

SEMILLERO SIRT - 2021

Ilustración 8: Descripción del modo de acción del hongo Foc R4T.

Posteriormente, durante el segundo semestre de 2021, determinamos junto a mi asesor (y líder del semillero SIRT), el profesor Gabriel Eduardo Ávila Buitrago, continuar trabajando en el proyecto como mi trabajo de grado. No obstante, dada la magnitud de la propuesta de proyecto original, se delimitó dicha propuesta para dar enfoque al presente trabajo de grado, encaminando las actividades hacia el desarrollo de las fases de recolección, procesamiento y análisis de las imágenes y los resultados obtenidos.

Para apoyar el proceso de aprendizaje acerca del diseño e implementación de redes neuronales y poder apalancar el desarrollo del proyecto, se tomaron los siguientes cursos en la plataforma Platzi:

- Curso de Fundamentos de redes neuronales con Python y Keras.
- Curso de TensorFlow.js

Adicionalmente, participamos en la 5ª Semana TIC, llevada a cabo durante el segundo semestre de 2021, orientando el taller “Una red neuronal con TensorFlow”, en donde procuré abordar los conceptos básicos asociados al deep learning y las redes neuronales artificiales, así como una pequeña muestra en Google Colab. A este taller asistieron 11 personas.

Una red neuronal con Tensorflow

Cuán útiles son las redes neuronales y cómo Tensorflow simplifica su creación.

Por Jeimy Cifuentes



Ilustración 9: Portada de la presentación empleada durante el taller "Una red neuronal con Tensorflow".

4.1. Revisión de literatura y búsqueda de información

De acuerdo con lo mencionado en la metodología propuesta, en la primera fase se desarrolló una revisión de literatura buscando conocer las características de la enfermedad, así como los métodos de diagnóstico existentes. Esta búsqueda se realizó en cuatro etapas:

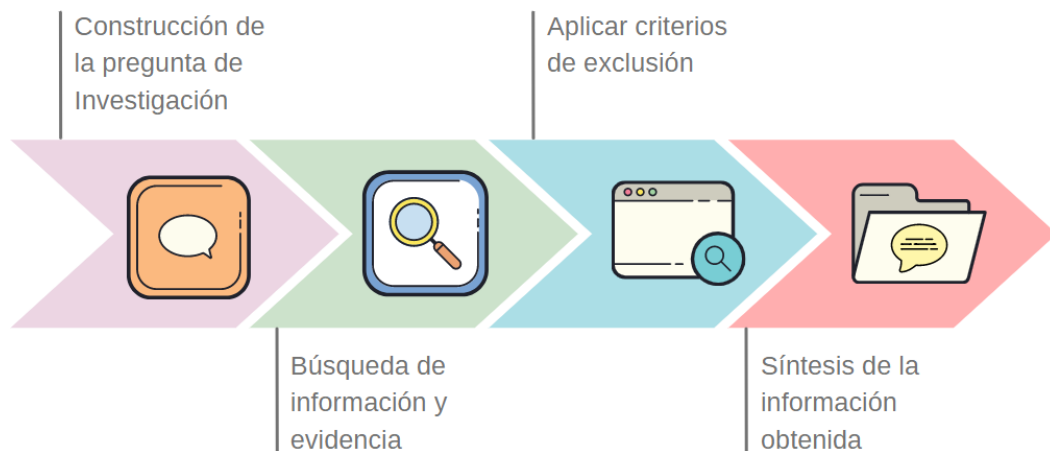


Ilustración 10: Revisión Sistemática y sus etapas. (íconos gratuitos, propiedad de icons8).

Etapa 1: Construcción de la pregunta de investigación

En esta etapa se definió la siguiente pregunta:

*¿Cómo se pueden aplicar métodos de aprendizaje de máquina para diagnosticar la presencia del hongo *Fusarium Oxysporum Raza 4 Tropical (Foc R4T)* en plantas musáceas en plantas ubicadas en algunas zonas de Cundinamarca (Colombia)?*

Adicionalmente, y con el fin de aclarar dudas sobre los métodos a revisar, se plantearon algunos cuestionamientos derivados que, direccionaron el proceso final de búsqueda de información:

- ¿Cuáles son los estudios realizados acerca de la identificación de lesiones producidas por hongos en plantas musáceas, empleando visión artificial?
- ¿Existe algún estudio enfocado a la identificación de lesiones producidas por hongos en plantas musáceas empleando visión artificial en Colombia?
- ¿Qué métodos de procesamiento de imágenes y qué tipos de redes neuronales fueron empleados como soporte para la identificación de lesiones producidas por hongos en plantas musáceas?
- ¿Cuáles son las características de redes neuronales aplicadas en estudios de este tipo?
- Finalmente, ¿Cómo se puede evaluar el correcto funcionamiento de un sistema de detección que use redes neuronales?

Etapa 2: Búsqueda de información y evidencia

Con base en los interrogantes previamente planteados, se ejecutó una búsqueda en bases de datos institucionales tales como ACM Digital Library, SCOPUS y Google Scholar, entre otras.

Se identificaron las siguientes palabras clave para desarrollar el proceso de búsqueda de la información:

- Palabras claves asociadas a las redes neuronales
 - Neural network.
 - Image preprocessing.
 - Convolutional Neural Network.
- Palabras claves asociadas a las plantas musáceas
 - Banana leaf.
 - Banana disease.
- Palabras claves asociadas a las enfermedades que atacan a las plantas musáceas
 - Fusarium Oxysporum Raza 4 Tropical.
 - Black Sigatoka.
 - Yellow Sigatoka.

En esta fase se encontraron 16 artículos de interés relacionados con la temática.

Etapa 3: Aplicación de criterios de exclusión

Se definieron algunos criterios de exclusión de los artículos. El primero de ellos, el año de publicación, dejando únicamente aquellos publicados entre los años 2016 y 2021.

Adicionalmente, se hizo una revisión de resúmenes de los artículos, eliminando aquellos que hablaban de plantas diferentes a las musáceas o que se enfocaran más en el procesamiento de imágenes que en la detección de enfermedades mediante machine learning.

Etapas 4: Síntesis de la información obtenida

La búsqueda de literatura facilitó la obtención de la información necesaria sobre el proceso de captura de imágenes y los mecanismos para el preprocesamiento de las imágenes capturadas.

Igualmente se evidenciaron diferentes métodos de aprendizaje de máquina utilizados en proyectos similares como el denominado “*WTPlant (What’s That Plant?): A Deep Learning System for Identifying Plants in Natural Images*” (Krause, Sugita, Baek, & Lim, 2018) o mediante el análisis “*Research on the Plant Leaf disease Region Extraction*” (Liu, Li, & Sun, 2019), encontrando que las redes neuronales convolucionales son el método que genera mejores resultados para el diagnóstico de lesiones en plantas. Adicionalmente, se encontraron características de diseño de las redes neuronales, así como de los procesos de funcionamiento, construcción y entrenamiento.

4.2. Modo de acción del hongo Foc R4T

La infección por Foc R4T (*Fusarium Oxysporum* Raza 4 Tropical) afecta a plantas de banano y plátano, particularmente al banano de clase Cavendish. El hongo atacará la planta afectando el sistema vascular de la misma, impidiendo el transporte de agua y nutrientes, impidiendo así la fotosíntesis y aniquilando la planta.

Es posible reconocer sus síntomas de la siguiente manera:

- a. Será posible observar el amarillamiento/clorosis en sus hojas. La clorosis avanzará desde el borde de la hoja hasta alcanzar el nervio central de la misma (Senasica, 2019), así:



Ilustración 11: Marchitamiento y clorosis de la hoja, avanza desde el borde hacia el centro de esta. Finca San Diego. Tomado por: Jeimy Andrea Cifuentes.

Posteriormente estas hojas se marchitarán y quedarán completamente secas y de color café, así:



Ilustración 12: Hoja seca y suspendida. Unida a la planta por el pseudotallo. Finca San Diego. Tomado por: Jeimy Andrea Cifuentes.

- b. Pérdida de rigidez (turgencia) de las hojas que colapsarán quedando colgadas del peciolo (Senasica, 2019), así:



Ilustración 13: Hoja en posición vertical debido a la pérdida de turgencia. Finca San Diego. Tomado por: Jeimy Andrea Cifuentes

Es posible encontrar lesiones a nivel del corno y el pseudotallo, no obstante, estas lesiones no serán visibles sin interactuar con la planta (para ver las lesiones a nivel del corno es necesario cortar la planta), por lo que no se consideran parte de este estudio.

4.3. Mecanismos de diagnóstico disponibles

El diagnóstico por Foc R4T actualmente se lleva a cabo por técnicos especializados quienes toman una muestra de la planta afectada, con todo el nivel de asepsia requerido y todos los protocolos de bioseguridad establecidos con el fin de minimizar el riesgo de contagio a otras plantas sanas.

Posteriormente, esta muestra es llevada a los laboratorios designados por el ICA (Instituto Colombiano Agropecuario) en donde se lleva a cabo el análisis del patógeno en la muestra recolectada.

4.4. Visitas de campo

Respecto al proceso de entrenamiento de la red neuronal, se encontró que se requería una vasta colección de imágenes de plantas musáceas (particularmente de sus hojas), incluyendo imágenes de plantas sanas, plantas enfermas con lesiones producidas por otros microorganismos distintos al hongo Foc R4T y por último plantas con sospecha de infección por Foc R4T, por lo que se realizan visitas de campo a zonas donde existe sospecha de la enfermedad.

Se realizaron en total cinco (5) visitas de campo a las regiones de Tena y La Mesa en Cundinamarca, así como a la región del Guamo en el Tolima.

Tena, Cundinamarca

Vereda Peña Negra

Se realizaron dos (2) visitas a la vereda Peña Negra, ubicada en el municipio de Tena en Cundinamarca, con la intención de obtener imágenes de plantas musáceas sanas.

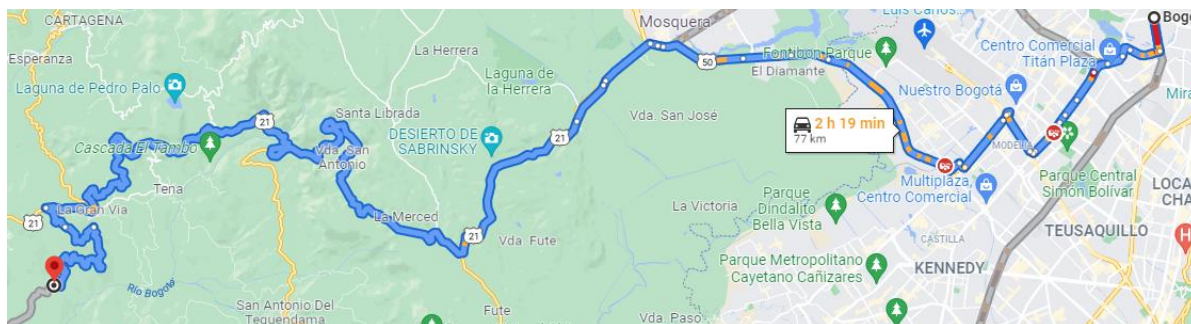


Ilustración 14: Ruta hacia la vereda Peña Negra, desde Bogotá (Cundinamarca). Finca “El Caimo”.

Finca el Caimo	
Ubicación	Vereda: Peña Negra, Municipio: Tena, Departamento: Cundinamarca
Clima	Cálido 21 – 28 ° C
Tipo de Finca	De frutales cítricos y no cítricos.
% de Plantas con sospecha de infección por Foc R4T	0%
Visitas realizadas	2
Fecha de visita 1	Agosto 2021
Fecha de visita 2	Noviembre 2021

Durante la visita se llevaron a cabo entrevistas a los habitantes de la finca “El Caimo”, con el objetivo de conocer si se había evidenciado la presencia del hongo en las plantas de banano. Si la producción habitual de banano se había visto mermada por algún tipo de plaga o infección y si habían recibido algún tipo de alerta por parte del ICA o la UMATA (Unidad Municipal de Asistencia Técnica Agropecuaria) del municipio.

La respuesta de las personas entrevistadas fue un No de forma unánime a las preguntas realizadas, lo que me llevó a considerar únicamente la existencia de plantas sanas en esta ubicación.

Posteriormente, durante la sesión de toma de fotografías, se constató que no existían plantas de banano con lesiones visibles provocadas por el hongo.

La Mesa, Cundinamarca

Vereda Alto Grande

También se realizaron dos (2) visitas a la vereda Alto grande, ubicada en el municipio de La Mesa en Cundinamarca para obtener imágenes de plantas enfermas, con sospecha de infección por Foc R4T.

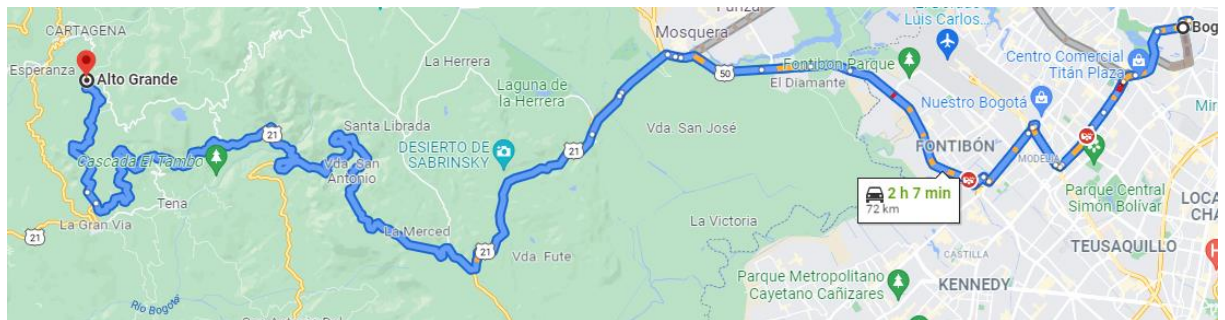


Ilustración 15: Ruta hacia la vereda Alto Grande, desde Bogotá (Cundinamarca). Finca "San Diego".

Finca San Diego	
Ubicación	Vereda: Alto Grande, Municipio: La Mesa, Departamento: Cundinamarca
Clima	Cálido 21 – 28 ° C
Tipo de Finca	De frutales cítricos y no cítricos.
% de Plantas con sospecha de infección por Foc R4T	+ 70%
Visitas realizadas	2
Fecha de visita 1	Agosto 2021
Fecha de visita 2	Noviembre 2021

Durante la visita se llevaron a cabo entrevistas a los habitantes de la finca “San Diego”, con el objetivo de conocer si se había evidenciado la presencia del hongo en las plantas de banano. Si la producción habitual de banano se había visto mermada por algún tipo de plaga o

infección y si habían recibido algún tipo de alerta por parte del ICA o la UMATA (Unidad Municipal de Asistencia Técnica Agropecuaria) del municipio.

La respuesta de las personas entrevistadas, tanto a dueños de la finca “San Diego” como a vecinos de esta, fueron similares a las siguientes:

- *“No sabemos qué está pasando, pero la tierra no volvió a dar bananos. Otros tipos de plátanos (como el popocho o cachaco¹⁰) sí se han podido seguir cultivando, pero los bananos no”.*
- *“Pareciera que hubiese un ‘bicho’ que va matando la planta de banano, aún no sabemos qué es”.*
- *“La planta de banano se va volviendo negra y va muriendo”.*
- *“Las hojas se ven amarillas o cafés, si tomo un machete para cortar el tallo de la planta, se ve negro y ya esa planta no sirve para nada”.*
- *“A la mayoría de las plantas de banano que se han sembrado les pasa eso, ahora quedarán por ahí 3 o 5 plantas de banano en toda la finca que aún dan fruto, pero están alejados de la casa”.*
- *“Se han aplicado pesticidas y fungicidas a las plantas afectadas, sin éxito en el tratamiento de la enfermedad”.*

¹⁰ El nombre científico del plátano popocho (Llamado comúnmente así en la región de Cundinamarca) o plátano cachaco (Llamado comúnmente así en la región del Tolima) es *Musa x Paradisiaca*.



Ilustración 16: Racimo de plátano "popocho", cosechado en la finca "San Diego". Foto por: Jeimy Andrea Cifuentes.

Se evidenció desconocimiento por parte de los vecinos acerca del patógeno que afectaba a las plantas de banano en la región. Algunos consideraban que la plaga era producida por algún tipo de insecto o gusano, otros directamente manifestaban no saber a qué se debía la situación. No obstante lo anterior, todas las personas se encontraban alarmadas por el comportamiento de las plantas de banano que no lograban completar su ciclo productivo.

Posteriormente, durante la sesión de toma de fotografías, se constató que existían plantas de banano con lesiones visibles con sospecha de presencia del hongo.



Ilustración 17: Planta de banano afectada por clorosis en sus hojas y lesiones visibles en hojas y tallos. Finca "San Diego". Tomada por: Jeimy Andrea Cifuentes

Guamo, Tolima

Vereda Cerro Gordo

Se realizó una (1) visita a la finca “Buenos Aires”, ubicada en la vereda Cerro Gordo, en el municipio del Guamo en el Tolima para obtener imágenes de plantas enfermas, con patologías distintas al Foc R4T.




Ilustración 18: Ruta hacia la vereda Cerro Gordo, desde Bogotá (Cundinamarca).

Finca Buenos Aires	
Ubicación	Vereda: Cerro Gordo, Municipio: Guamo, Departamento: Tolima
Clima	Muy Cálido 31 – 36 ° C
Tipo de Finca	De frutales cítricos y no cítricos.
% de Plantas con sospecha de infección por Foc R4T	0%
Visitas realizadas	1
Fecha de visita 1	Octubre 2021

Durante la visita se llevaron a cabo entrevistas a los trabajadores de la finca “Buenos Aires”, con el objetivo de conocer si se había evidenciado la presencia del hongo en las plantas de banano. Si la producción habitual de banano se había visto mermada por algún tipo de plaga o infección y si habían recibido algún tipo de alerta por parte del ICA o la UMATA (Unidad Municipal de Asistencia Técnica Agropecuaria) del municipio.

La respuesta de las personas entrevistadas fue un “No” de forma unánime a las preguntas realizadas, lo que me llevó a considerar únicamente la existencia de plantas sanas en esta ubicación.

Posteriormente, durante la sesión de toma de fotografías, se constató que no existían plantas de banano con lesiones visibles provocadas por el hongo.

4.5. Captura de imágenes y creación de un dataset

Inicialmente, para iniciar el desarrollo del proyecto se empleó un dataset gratuito encontrado en el siguiente enlace <https://github.com/godliver/source-code-BBW-BBS> que contenía imágenes de plantas sanas y de plantas infectadas por Sigatoka Negra, enfermedad causada por el hongo *Micosphaerella Fijiensis*.

A diferencia del tratamiento del Foc R4T, existen fungicidas y prácticas de cultivo que permiten eliminar la infección por *Micosphaerella Fijiensis*. Sin embargo, según la (FAO) Organización de las Naciones Unidas para la Alimentación y la Agricultura, “La Sigatoka negra afecta el crecimiento de la planta, disminuyendo la capacidad de esta de hacer fotosíntesis, reduciendo el llenado del fruto y provocando su maduración prematura”.

Como no se contaba con plantas con lesiones sospechosas de infección por Foc R4T, se decidió entonces, capturar plantas enfermas y sanas localmente, durante las visitas de campo realizadas a las diversas locaciones.

Estas fotografías fueron capturadas empleando los siguientes dispositivos:

Dispositivo	Apple iPhone 7
Tipo de Cámara	Rear camera, 28mm, 12MP

Tamaño Original de las imágenes	3024 x 4032
ISO	20
Tamaño	± 990 px

Dispositivo	GoPro Hero 4
Tipo de Cámara	12MP

Dispositivo	Oppo Reno 5 Lite
Tipo de Cámara	48MP
Tamaño Original de las imágenes	3024 x 4032

Dispositivo	Nikon D5300
Tipo de Cámara	24.1 MP
Lente	18-50

Los dispositivos citados anteriormente fueron seleccionados con la intención de abarcar variadas resoluciones de imágenes, desde un celular hasta una cámara semi-profesional de fotografía para así tener insumos de distintas características para construir el dataset que facilita la prueba de la red neuronal diseñada. Así mismo, se deja a disposición dicho dataset con la intención de dar continuidad al proyecto en fases posteriores.

El dataset creado se compone de aproximadamente 500 imágenes de hojas de plantas de banano, entre las que se encuentran plantas sanas y plantas afectadas con lesiones sospechosas de infección por Foc R4T. Este dataset se encuentra disponible en el siguiente enlace

<https://github.com/jmecifu/HojasDeMusaceaDataset>.

4.6. Criterios de preprocesamiento de las imágenes

Una vez se cuenta con el dataset obtenido en las visitas, se procura mejorar la apariencia de las imágenes que lo componen, o bien, transformarlas de forma tal que se facilite el análisis y el procesamiento de las imágenes mediante la red neuronal.

En primera instancia se procede a eliminar el fondo de la imagen y conservar únicamente la imagen de la hoja de la planta, pasando de la imagen inicial:



Ilustración 19: Hoja de planta musácea, tomada en la Finca San Diego. Por: Jeimy Andrea Cifuentes.

A la imagen:



Ilustración 20: Detalle de la hoja de planta musácea (Ilustración 15) sin fondo.

Las imágenes obtenidas en este paso serán las que conforman el nuevo dataset generado.

4.7. Diseño de la red neuronal convolucional

4.7.1. Requerimientos de alto nivel

Se plantea el desarrollo de una solución que permita el preprocesamiento y análisis de imágenes de plantas de banano y plátano con el fin de encontrar indicios de infección por Foc R4T.

4.7.2. Herramientas y Librerías Existentes

A continuación, se relacionan las Herramientas y Librerías empleadas en el diseño de la red neuronal para la detección de lesiones por Foc R4T en plantas musáceas:

Python

Después de llevar a cabo la debida investigación y lectura de la literatura correspondiente, se prefirió Python sobre otros lenguajes de programación, debido a:

- Su sintaxis simple que facilita el desarrollo de software y la escritura de código.
- La voluminosa disponibilidad de recursos online gratuitos (a saber: tutoriales, librerías, herramientas y contenidos publicados en la Comunidad abierta de desarrolladores).
- Enfocado al desarrollo de redes neuronales, es posible hacer uso de librerías gratuitas que facilitarán el proceso. Como son:
 - TensorFlow: Librería de Google para machine learning.
 - Keras: Librería para deep learning.
- Usabilidad multiplataforma.

Google Colab

Teniendo en cuenta que los procesos asociados a machine learning tienen un altísimo tiempo de procesamiento, aunado a la gran cantidad de datos a procesar durante los mismos, se dificulta la obtención de resultados en un corto periodo de tiempo debido a que los computadores convencionales no resisten dicha carga. Teniendo en cuenta estos hechos, se decide aprovechar las ventajas que nos ofrece la computación en la nube.

Google Colab es un servicio en la nube que se basa en notebooks de Jupyter. Proporciona un tiempo de ejecución totalmente configurado para el aprendizaje profundo y acceso gratuito a una sólida GPU (Carneiro, y otros, 2018).

Teniendo en cuenta los factores anteriormente expuestos, la red neuronal fue desarrollada empleando Google Colab por la facilidad que ofrece la herramienta tanto a nivel de desarrollo como a nivel de ejecución, teniendo en cuenta el nivel de procesamiento requerido durante el proceso de entrenamiento de una red neuronal.

Keras

Librería open-source que permite trabajar con redes neuronales a alto nivel. Fue creada por el ingeniero de Google François Chollet en 2015.

Keras simplifica el trabajo relacionado con el desarrollo y uso de redes neuronales existentes, es muy fácil de usar y posibilita una rápida implementación. No obstante, es importante tener en cuenta que Keras requiere de un backend para funcionar correctamente. Este backend es Tensorflow.

Tensorflow

Plataforma que facilita la creación e implementación de modelos de aprendizaje automático. En conjunto con Keras (gracias a su API de alto nivel), permite crear y entrenar modelos que resuelven problemas complejos del mundo real.

Tensorflow es empleado por Google para potencializar la búsqueda de información en el buscador, en Gmail y encontrar opciones que satisfagan las necesidades de los usuarios al usar el Traductor (Bendersky & Wang, 2021).

4.8. Definición de Casos de Uso

En esta sección se describe la interacción de los diversos actores con la solución

Nombre	Nombre del Proceso
Descripción	Seleccionar Imagen
Actores	Usuario
Precondiciones	
Descripción	El usuario selecciona una imagen que contenga hojas de plantas de banano o plátano.
Evento de activación	El usuario carga la imagen seleccionada.
Flujo normal	La imagen debe ser cargada correctamente y allí el usuario puede seleccionar la opción "Analizar" si desea procesar la imagen.
Flujo alternativo	El usuario cancela la operación.
Postcondiciones	
Comentarios	

Tabla 1: Caso de uso "Seleccionar Imagen"

Nombre	Nombre del Proceso
Descripción	Analizar Imagen
Actores	Usuario
Precondiciones	
Descripción	El usuario pulsa el botón "Analizar Imagen" para ejecutar el análisis de la imagen seleccionada.
Evento de activación	El usuario pulsa el botón "Analizar Imagen".

Flujo normal	La imagen empieza el circuito de análisis y clasificación.
Flujo alternativo	El usuario cancela la operación.
Postcondiciones	
Comentarios	

Tabla 2: Caso de Uso "Analizar Imagen"

Nombre	Nombre del Proceso
Descripción	Clasificar Imagen
Actores	Sistema
Precondiciones	
Descripción	El sistema analiza la imagen y calcula la probabilidad de que esta sea una planta afectada por el Foc R4T.
Evento de activación	El usuario pulsa el botón "Analizar Imagen".
Flujo normal	La imagen empieza el circuito de análisis y clasificación.
Flujo alternativo	El usuario cancela la operación.
Postcondiciones	
Comentarios	

Tabla 3: Caso de Uso: Clasificar Imagen

4.9. Implementación o desarrollo de la red neuronal convolucional

4.9.1. Preprocesamiento de las imágenes

Para el proceso machine learning asociado a visión artificial y clasificación de imágenes es necesario disponer en la capa de entrada la imagen con la mayor cantidad de píxeles disponibles para la correcta identificación/clasificación de las imágenes. No obstante, es necesario realizar un preprocesamiento de las imágenes a emplear, de modo tal que el sistema reciba datos de manera uniforme y el proceso de aprendizaje, así como el proceso de abstracción de las características de las imágenes puedan llevarse a cabo más fácilmente.

Para los datasets seleccionados es imprescindible realizar un proceso de homogeneización de las imágenes, puesto que las imágenes se han capturado bajo condiciones

diversas de luz, con diversos tipos de dispositivos y como resultado tenemos imágenes con distintas características.

Es importante entonces tener en cuenta los aspectos de las imágenes relacionados con el tamaño de estas, la posición de la hoja de planta de banano en la imagen, así como el color, entre otros.

Dentro de los criterios de preprocesamiento de imágenes aplicados al modelo, se seleccionaron los siguientes:

a. Conversión a escala de grises:

Empleando la librería OpenCV para Python, se convirtieron las imágenes en escala de grises así:

```
Cv2.Color_BGR2GRAY
```

b. Se ajustó el tamaño de la imagen:

Para hacer que el procesamiento de la imagen fuese más eficiente, se ajustó el tamaño de las imágenes a un tamaño de 200x200px. Esta operación se lleva a cabo usando la librería OpenCV para Python.

c. Se ecualizó el histograma, para mejorar el contraste de la imagen:

Recibiendo como parámetro la imagen con el nuevo tamaño (paso b), se emplea el método `equalizeHist` de la librería OpenCV para Python.

- d. Empleando desenfoque Gaussiano, se suaviza la imagen con el fin de remover ruido.
Método empleado medianBlur (5) de la librería OpenCV.
- e. Por último, se segmenta la imagen con el fin de detectar los bordes de esta.




Ilustración 21: Imagen de 200x200px, en escala de grises y con detección de bordes.

4.9.2. Arquitectura implementada

```
[ ] Model: "sequential"
```

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 100, 100, 32)	896
max_pooling2d (MaxPooling2D)	(None, 50, 50, 32)	0
conv2d_1 (Conv2D)	(None, 50, 50, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(None, 25, 25, 64)	0
conv2d_2 (Conv2D)	(None, 25, 25, 128)	73856
max_pooling2d_2 (MaxPooling2D)	(None, 12, 12, 128)	0
conv2d_3 (Conv2D)	(None, 12, 12, 256)	295168
max_pooling2d_3 (MaxPooling2D)	(None, 6, 6, 256)	0
flatten (Flatten)	(None, 9216)	0
dense (Dense)	(None, 256)	2359552
dense_1 (Dense)	(None, 128)	32896
dense_2 (Dense)	(None, 3)	387
Total params: 2,781,251		

Ilustración 22: Resumen del modelo para la fase de extracción de características de las imágenes

El modelo secuencial propuesto cuenta con cuatro (4) capas de convolución y cuatro (4) capas de Pooling.

Para las cuatro capas de convolución se empleó la clase Conv2D de Keras. El tamaño del Kernel es de (3,3), empleando función de activación ReLu y padding de tipo same.

Las capas de convolución fueron seguidas por capas de pooling, empleando la clase MaxPooling2D de Keras que cuenta con un tamaño de ventana (pool_size) de (2,2).

Para las capas completamente conectadas, se emplearon funciones de activación ReLu y Softmax. Justo antes de la configuración de las capas completamente conectadas, se adicionó una capa de tipo Flatten que permitiría convertir las salidas de las capas convolucionales en un vector plano, insumo necesario para las capas completamente conectadas.

4.9.3. Especificaciones del Dataset

Nombre de la clase	Cantidad de imágenes
FOC	500
M. Fijiensis	900
Saludables	1100

4.9.4. Proceso de Entrenamiento de la red neuronal

El entrenamiento se llevó a cabo cargando los repositorios de imágenes en google drive como .zip y descomprimiéndolos directamente durante la fase de ejecución del código.

Se aplican los criterios de preprocesamiento de imágenes descritos en la sección 4.9.

Las imágenes son extraídas y procesadas como arreglos y allí inició el proceso de entrenamiento con los parámetros definidos en la sección 4.9.2.

El entrenamiento del modelo consta de 180 épocas y un batch size de 32.

4.9.5. Matriz de Confusión

La matriz de confusión se aplica a los algoritmos de aprendizaje automático con el fin de visualizar el desempeño de los mismos.

Las siguientes opciones conformarían la matriz de confusión asociada al proyecto:

- a. La hoja de planta musácea que es saludable y el sistema clasificó como saludable. Sería un “**Verdadero Saludable**”
- b. La hoja de planta musácea que es saludable y el sistema clasificó como enferma por FOC. Sería un “**Falso FOC Saludable**”. Error tipo I.
- c. La hoja de planta musácea que es saludable y el sistema clasificó como enferma por M. Fijiensis. Sería un “**Falso MFIJ Saludable**”. Error tipo II.
- d. La hoja de planta musácea que tiene lesiones de FOC y el sistema clasificó como enferma por FOC. Sería un “**Verdadero FOC**”.
- e. La hoja de planta musácea que tiene lesiones de FOC y el sistema clasificó como enferma por Saludable. Sería un “**Falso Saludable FOC**”. Error tipo III.
- f. La hoja de planta musácea que tiene lesiones de FOC y el sistema clasificó como enferma por M. Fijiensis. Sería un “**Falso MFIJ FOC**”. Error tipo IV.
- g. La hoja de planta musácea que tiene lesiones de M. Fijiensis y el sistema clasificó como enferma por M. Fijiensis. Sería un “**Verdadero MFIJ**”.
- h. La hoja de planta musácea que tiene lesiones de M. Fijiensis y el sistema clasificó como Saludable. Sería un “**Falso Saludable MFIJ**”. Error tipo V.
- i. La hoja de planta musácea que tiene lesiones de M. Fijiensis y el sistema clasificó como enferma por FOC. Sería un “**Falso FOC MFIJ**”. Error tipo VI.

La matriz asociada a este proyecto tiene tres (3) entradas, por lo que surgen nueve (9) opciones de las cuales tres (3) de ellas son valores reales y seis (6) posibles valores predictivos. Lo que se pretende mediante la matriz de confusión es medir la exactitud y la precisión del modelo, así como la sensibilidad y especificidad.

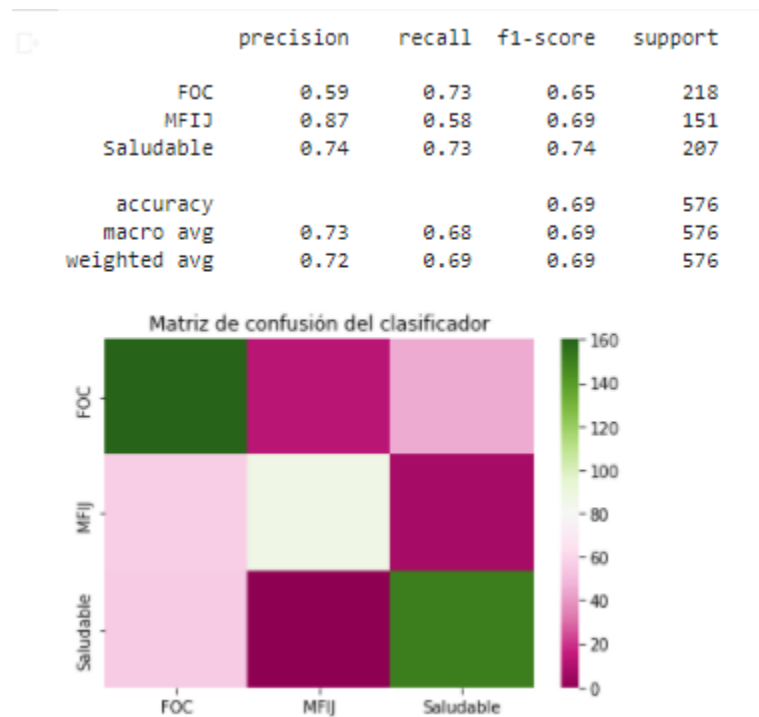


Ilustración 23: Matriz de confusión asociada al proyecto.

4.9.6. Función de pérdida

La función de pérdida en la fase de entrenamiento indica cómo se adapta el modelo al dataset de entrenamiento, mientras que la función de pérdida en la fase de validación indica qué tan bien se adapta el modelo a los datos nuevos




Ilustración 24: Función de pérdida en las fases de entrenamiento y validación

4.9.7. Accuracy o Exactitud del modelo

Mide qué tan exacto es el modelo para encontrar las características esperadas en las imágenes, durante la fase de entrenamiento y validación:

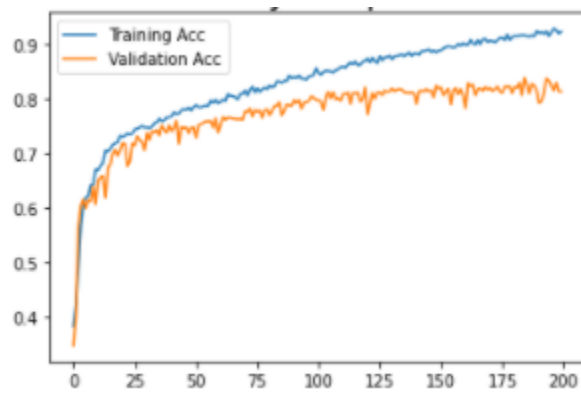


Ilustración 25: Exactitud durante las fases de entrenamiento y validación.

CAPÍTULO V: RESULTADOS OBTENIDOS

5. Resultados

Se diseñó una red neuronal con las características mencionadas en la Sección 4.9.2.

Se obtuvo un porcentaje de detección de la presencia de la enfermedad en un 0.812698

Matriz de confusión.

Se obtuvo un Dataset con aproximadamente 500 imágenes publicado en la URL

<https://github.com/jmecifu/HojasDeMusaceaDataset> , que incluye imágenes de plantas sanas e imágenes de plantas con sospecha de infección por el hongo.

Se desarrolló una charla taller en la Semana TIC del segundo semestre de 2021.

“Taller Tensorflow”, disponible en la siguiente URL: <https://bit.ly/3CnVqTg> –

Cantidad de asistentes: 11

5.1. Entregables

Documento del proyecto.

Repositorio de código en GitHub.

Video del taller: “Taller Tensorflow”.

URL del dataset.

CAPÍTULO VI: CONCLUSIONES

6. Conclusiones

En el marco del presente proyecto se presenta el desarrollo de un sistema automático de detección de lesiones producidas por el hongo *Fusarium Oxysporum* Raza 4 Tropical en imágenes de hojas de plantas musáceas mediante la aplicación de técnicas de aprendizaje automático.

La herramienta de machine learning empleada fue una red neuronal convolucional entrenada con un conjunto de datos de 2200 elementos aproximadamente. Estos elementos eran imágenes preprocesadas de hojas de plantas musáceas sanas, afectadas por Black Sigatoka o bien, con sospecha de lesiones por *Fusarium Oxysporum* raza 4 tropical.

Dentro de las fases de desarrollo del proyecto se evidenciaron los siguientes hallazgos:

- a. La cantidad y la calidad de las imágenes con la cual se pretende entrenar la red neuronal es muy importante. Es importante tener en cuenta las características de las imágenes a Esto con el fin de no sobreentrenar la red al entregarle como insumo imágenes muy similares entre sí y que la red sea capaz de clasificar correctamente las imágenes durante la fase de testeo.
- b. El preprocesamiento que se realice a las imágenes es tan importante como el dataset mismo, debido a que la aplicación de un correcto preprocesamiento de las imágenes acelera el proceso de entrenamiento de la red neuronal y la hace más eficiente.

Siempre es importante entregarle a la red neuronal el dataset tan estandarizado y homogéneo como sea posible.

- c. Un factor importante para tener en cuenta dentro del proceso de desarrollo de redes neuronales convolucionales (y redes neuronales en general) son las limitaciones de hardware de los equipos en los cuales se pretende entrenar el modelo. Es posible que un equipo común de escritorio no supla las necesidades que requiere el procesamiento de las operaciones y allí es recomendable emplear otras alternativas como las que nos ofrece la computación en la nube.
- d. A mayor cantidad de elementos en el dataset, mayor capacidad en disco duro, memoria RAM y procesamiento a nivel de CPU/GPU serán requeridos. Es altamente recomendable procesar el entrenamiento de la red neuronal mediante la GPU, pues este se hará de forma más eficiente.
- e. Se evidenció también que los canales de datos definidos deben tener cantidad similar de imágenes, puesto que cuando se tenían muy pocas imágenes de lesiones en plantas musáceas por Foc R4T (más o menos el 8% de las imágenes en relación con las dispuestas en los demás canales, “Hojas saludables” y “Black Sigatoka”), el sistema clasificaba aleatoriamente las plantas enfermas como afectadas por “Black Sigatoka” y no hacía correctamente la clasificación como plantas con sospecha de lesiones producidas por Foc R4T.

- f. Es importante tener en cuenta que no siempre una gran cantidad de Epoch o ciclos hará que la red neuronal aprenda mejor o que adquiera más características de las imágenes dadas.

Es importante tener en cuenta que siempre existe el riesgo de sobre entrenamiento en el desarrollo de una red neuronal, relacionado en este caso con la poca cantidad de imágenes de hojas de banano con sospecha de infección por Foc R4T, más aún cuando en los demás canales se tenían cerca del 80% de las imágenes totales. Se notó entonces que es importante monitorear el proceso de aprendizaje de la red validando la curva de entrenamiento con relación a la curva de validación para descartar que la red neuronal esté memorizando resultados obtenidos anteriormente, en lugar de aprender a clasificar las imágenes nuevas.

Dentro del proceso de entrenamiento se encontró una precisión del 0.802698, lo cual indica un muy buen nivel de acuerdo entre un clasificador humano que esté analizando las lesiones y la clasificación realizada por la red neuronal.

Debido a que la red ha aprendido a extraer características importantes que representan lesiones por hongos o bacterias en las hojas de las plantas musáceas, considero que la red neuronal podría ser capaz de diagnosticar otros tipos de infecciones en plantas musáceas, tales como el “Moko” o la enfermedad denominada “Pudrición de la corona”, o bien, esta misma red neuronal podría ser extrapolada y con el uso del dataset indicado, aprender a identificar enfermedades y lesiones en otro tipo de plantas (no solamente las plantas musáceas). Es importante tener en cuenta que cualquier nueva característica que se pretenda analizar mediante la red neuronal requerirá una nueva fase de entrenamiento de esta.

No obstante, y aunque durante las visitas de campo realizadas se intentó capturar un dataset de buena calidad para el entrenamiento del modelo, se requiere mayor investigación para emplear algoritmos de este estilo en el diagnóstico de enfermedades directamente en el campo, de modo tal que en primera instancia sea evaluado por los expertos correspondientes y que al final constituya una herramienta de diagnóstico confiable para los trabajadores del campo.

CAPÍTULO VII: TRABAJO FUTURO

7. Trabajo Futuro

En el marco del desarrollo del presente trabajo de grado, se desarrolló una parte del proyecto planteado inicialmente en el semillero SIRT que abarcaba una solución completa en torno a la captura, envío y preprocesamiento de las imágenes, así como su clasificación, almacenamiento y visualización para llevar a cabo análisis posteriores.

Tomando como base la red neuronal construida en este proyecto, es posible seguir investigando acerca de los recursos disponibles para mejorar el aprendizaje de la red, bien sea enfocado en el diagnóstico de la enfermedad producida por el FoC R4T, o bien, diseñar una solución que facilite el diagnóstico de otros tipos de enfermedades en plantas musáceas.

Aún queda por explorar las fases relacionadas con:

- El análisis por parte de expertos en enfermedades de plantas musáceas, con la intención de que ellos analicen el modelo obtenido, teniendo en cuenta la efectividad, la pertinencia, el impacto y el beneficio que este puede tener en relación con las formas convencionales de diagnóstico.

Desde la parte técnica, es posible continuar con las siguientes fases del proyecto:

- La captura automática de imágenes mediante drones u otro tipo de hardware.
- El envío de las imágenes capturadas al repositorio para su análisis y clasificación.
- La disposición de los resultados obtenidos de manera pública ya sea para consulta por parte de los usuarios o de las entidades que así lo requieran.

- Posiblemente, la creación de una aplicación móvil que permita la captura de imágenes y el análisis de estas con base en el modelo diseñado.

El modelo utilizado en este proyecto se encuentra en el repositorio de GitHub, en la siguiente URL: <https://github.com/jmecifu/DiagnosticoPlantasMusaceas>. Así mismo, el dataset resultado de las visitas de campo realizadas durante la duración del proyecto se encuentra en la siguiente URL: <https://github.com/jmecifu/HojasDeMusaceaDataset>.

Referencias y Bibliografía

A Athiraja, P. V. (2021). Banana disease diagnosis using computer vision and machine learning methods. *Journal of Ambient Intelligence and Humanized Computing*, 6537-6556.

Amara, J., Bouaziz, B., & Algergawy, A. (2017). *A Deep Learning-based Approach for Banana Leaf Diseases*. Obtenido de Datenbanksysteme für Business, Technologie und Web (BTW 2017)-Workshopband.: http://btw2017.informatik.uni-stuttgart.de/slidesandpapers/E1-10/paper_web.pdf

Bendersky, M., & Wang, X. (17 de July de 2021). *Google AI Blog*. Obtenido de Advances in TF-Ranking: <https://ai.googleblog.com/search/label/TensorFlow>

Carneiro, T., Medeiros Da Nóbrega, R., Nepomuceno, T., Bian, G.-B., De Albuquerque, V., & Filho, P. (08 de October de 2018). *Performance Analysis of Google Colaboratory as a Tool for Accelerating Deep Learning Applications*. Obtenido de IEEE Xplore: <https://ieeexplore.ieee.org/document/8485684/>

FAO. (s.f.). *FAO*. Obtenido de <https://www.fao.org/3/au910s/au910s.pdf>

Haykin, S. (1994). *Neural Networks, a comprehensive foundation*.

Infaimon. (29 de Enero de 2020). *Historia de la visión artificial*. Obtenido de Infaimon: <https://blog.infaimon.com/historia-vision-artificial/>

Krause, J., Sugita, G., Baek, K., & Lim, L. (June de 2018). *WTPlant (What's That Plant?): A Deep Learning System for Identifying Plants in Natural Images*. Obtenido de ACM Digital Library: <https://dl-acm-org.loginbiblio.poligran.edu.co/doi/10.1145/3206025.3206089>

Liu, L., Li, J., & Sun, Y. (October de 2019). *Research on the Plant Leaf Disease Region Extraction*. Obtenido de ACm Digital Library: <https://dl-acm-org.loginbiblio.poligran.edu.co/doi/10.1145/3369318.3369321>

N. Saranya, L. P. (2020). Detection of Banana Leaf and Fruit Diseases Using Neural Networks. *2020 Second International Conference on Inventive Research in Computing Applications (ICIRCA)*. Combatore, India: IEEE. Obtenido de IEEEExplore.

Senasica. (Agosto de 2019). *Guía de Síntomas y daños de la fusariosis de las musáceas*. Obtenido de SENASICA: [https://prod.senasica.gob.mx/SIRVEF/ContenidoPublico/Guias%20de%20sintomas/Fusariosis%20de%20las%20mus%C3%A1ceas%20\(Fusarium%20oxysporum%20f.%20sp.%20Ocubense%20R4T\).pdf](https://prod.senasica.gob.mx/SIRVEF/ContenidoPublico/Guias%20de%20sintomas/Fusariosis%20de%20las%20mus%C3%A1ceas%20(Fusarium%20oxysporum%20f.%20sp.%20Ocubense%20R4T).pdf)

Simplilearn. (27 de May de 2021). *An overview on multilayer Perceptron (MLP)*. Obtenido de Simplilearn: <https://www.simplilearn.com/tutorials/deep-learning-tutorial/multilayer-perceptron>

Soto, S. A. (15 de Feb de 2021). *Sector Agro fue la actividad económica que más creció en 2020, con variación de 2,8%*. Obtenido de Agronegocios:

<https://www.agronegocios.co/agricultura/sector-agro-fue-la-actividad-economica-que-mas-crecio-en-2020-con-variacion-de-28-3125707>