

Desarrollar un modelo de machine learning basado en redes neuronales para la identificación y clasificación de enfermedades en cultivos de arroz mediante el análisis de imágenes

Elaborado por:

Andersson Yesid Jiménez Ramírez

Jhon Jairo Romero Sutachan

Juan Sebastián Gutiérrez Zorro

Programa de Estudio:

Especialización en Machine Learning

Universidad EAN

Seminario de Investigación Especialización

Bogotá

01/09/2024

RESUMEN

Colombia se destaca por su producción agraria, caracterizada por la distribución de la producción en diferentes pisos térmicos de la geografía nacional. Uno de los cultivos de mayor desarrollo a nivel nacional es el cultivo de arroz, los principales departamentos productores son el departamento de Casanare, Tolima y Meta. Las prácticas agrarias actuales asociadas a estos cultivos, relacionados con la aspersión de agroquímicos, carecen no solo de eficiencia productiva sino también afección al medio ambiente y a la salud de los trabajadores. Por ello, empezar a involucrar inteligencia artificial en estos procesos traen ventajas comparativas en todos los aspectos de la producción. El objetivo del presente trabajo es realizar un algoritmo de machine learning que mediante la clasificación de imágenes ayude a la detección temprana de plagas y enfermedades.

Palabras clave: Agroquímicos, Agricultura de precisión, Casanare, Cultivo de Arroz, Machine Learning, Producción.

Descripción del Problema

Los agricultores en Colombia siempre han tenido dificultades a la hora de sembrar y cosechar sus cultivos, los altos costos asociados a compra de semillas y agroquímicos, el difícil acceso a créditos bancarios, problemas en transporte, el abuso en la compra de sus productos de algunos intermediarios y el bajo precio de estos han sido los inconvenientes a los que se han enfrentado y los causales de convertir a esa labor en un oficio casi que inviable.

La falta de planificación y la no estandarización a la hora de iniciar todos los procesos que conllevan los cultivos, juega un papel fundamental en la productividad, lo que, asociado a los inconvenientes y en ocasiones a las condiciones del clima, genera una baja en los ingresos ocasionando pérdidas y por consiguiente quiebras a muchos en el gremio.

El agro, en especial el cultivo de arroz es uno de los principales sectores que mueven la economía en el departamento de Casanare, sus agricultores no están exentos de toda la problemática nombrada anteriormente, siendo los altos costos el mayor dolor de cabeza. Uno de los más altos por los que padecen los agricultores está asociado a la protección al cultivo, esto incluye la compra de herbicidas, insecticidas y fungicidas para el control de plagas, malezas y enfermedades; y el costo por hectárea de su aplicación. Según cifras de la Federación Nacional de Arroceros (FEDEARROZ) estos costos equivalen aproximadamente del 15% al 19% del total de sembrar y cosechar una hectárea de arroz a lo largo del año y en los dos tipos de siembra (secano y riego).

A causa de los bajos rendimientos que se han presentado en los últimos años y en miras a contrarrestar esta reducción, el agricultor ha optado por aumentar el número de aplicaciones

y dosis de insumos como fertilizantes, herbicidas e insecticidas (Acosta-Buitrago, 2011), lo que no precisa una mejora en la productividad sino por el contrario un daño al cultivo, un alza en los costos y una mayor contaminación.

Pregunta general de investigación

¿Cómo pueden los modelos de Machine Learning aplicados al procesamiento de imágenes detectar de manera temprana enfermedades en los cultivos de arroz, con el objetivo de reducir el uso de agroquímicos y disminuir los costos de producción?

Objetivo General

Desarrollar un modelo de machine learning basado en redes neuronales para la identificación y clasificación de enfermedades en cultivos de arroz a través del análisis de imágenes, dirigido al departamento de Casanare.

Objetivos Específicos

- Recolectar imágenes de cultivos de arroz afectadas por enfermedades en diferentes datasets, que asegure una base de datos robusta y que pueda ser utilizada en el entrenamiento del modelo.
- Evaluar las métricas de precisión, sensibilidad y especificidad del modelo seleccionado, que permita estimar el desempeño del modelo.
- Testear el modelo en un escenario real que permita su puesta en marcha.
- Desarrollar un MVP, mediante la cual se pueda realizar la visualización de los resultados obtenidos por el modelo, en la cual el agricultor pueda visualizar las coordenadas referentes a la imagen de la sección del cultivo que presenta la enfermedad, la foto, y el respectivo nombre de la enfermedad asociada.

JUSTIFICACIÓN

En el departamento de Casanare se cultivan aproximadamente 150,000 hectáreas de arroz, lo que representa el 29% del total nacional. Esto supone un riesgo significativo si no se aplican los manejos agronómicos adecuados, especialmente en lo relacionado con la aspersión aérea, ya que puede aumentar la probabilidad de que la cosecha no se recoja debido a los problemas generados por la fumigación.

Diversos estudios han comprobado que los métodos convencionales de fumigación no son los más eficientes para proteger los cultivos. Además, estos métodos impactan negativamente las áreas circundantes, causando daños a otros cultivos, a la flora y fauna, y a las personas que habitan cerca al lugar.

Debido a lo anterior se busca evitar el uso desmesurado de agroquímicos que permita así mejorar la rentabilidad del agricultor, disminuir los efectos nocivos para el medio ambiente y sobre la salud de los trabajadores y operarios.

MARCO TEORICO

El arroz es una de las fuentes principales de ingesta de calorías para alrededor de la mitad de la población mundial y un punto de apoyo para las poblaciones rurales y pilar de la seguridad alimentaria en muchos países de bajos ingresos. Lo cultivan principalmente los campesinos en parcelas de menos de una hectárea. El arroz juega también un papel importante como producto "salarial" para quienes trabajan en los sectores agrícolas comerciales o no agrícolas. (FAO, s.f.).

El origen del cultivo del arroz se remonta a hace miles de años entre China y la India. Dos países que, hoy en día, son los mayores productores de arroz del mundo, así como sus principales consumidores. Por su parte, el comercio exterior de este cereal está también protagonizado por ambos Estados. Mientras que China es el país con mayor cantidad de arroz importado, la India lidera la exportación mundial de arroz. (Statista, s.f.).

Colombia como país agrícola no se queda atrás, se ubicó como el país número 22 productor de arroz paddy seco en el mundo, con una producción promedio de 2.71 millones de toneladas, y número 33 en productividad, con unos rendimientos cercanos a 5.09 toneladas por hectárea de arroz paddy seco, según datos de la Organización de la Naciones Unidas para la Alimentación y la Agricultura (FAO).

Según cifras del Departamento Administrativo Nacional de Estadística (DANE) junto con el gremio de arroz la Federación Nacional de Arroceros (Fedearroz), en Colombia para el año 2023 se sembraron alrededor de 590.000 hectáreas en donde la zona de los llanos se establece como el mayor productor con un total de 316.000 hectáreas sembradas.

Existen muchos factores por los cuales la competitividad del sector arrocero en Colombia es baja. Sin embargo, entre ellas sobresalen dos en particular: el rendimiento (producción por hectárea) y los costos de producción. En Colombia el rendimiento promedio del cultivo mecanizado es de 4,7 toneladas por hectárea, mientras que en Estados Unidos es de 8,1 toneladas por hectárea. Por otro lado, en Colombia los costos de producción de arroz mecanizado pueden llegar a ser 50% más altos que en Estados Unidos.

El mercado nacional del arroz paddy verde (materia prima de la industria arrocera nacional) se caracteriza por estar en una estructura oligopsónica (SIC, 2012). La producción de los agricultores (grandes, medianos y pequeños) es absorbida en su totalidad por la industria molinera que se encarga de hacer una transformación industrial para el consumo final. Esta última cuenta con poder de negociación para definir precios y cantidades demandadas. Esto significa que factores tales como el poder de los compradores y la elasticidad de oferta y demanda, juegan un papel fundamental en el desarrollo del mercado.

El arroz es un cultivo clave para la seguridad alimentaria mundial, pero las enfermedades como *leaf blast*, *false smut* y *brown spot* afectan negativamente la productividad y calidad del cultivo. Un diagnóstico rápido y preciso es esencial para tomar medidas de control oportunas (Deng et al., 2021, p. 2)(fpls-12-701038).

Actualmente, el diagnóstico se realiza principalmente mediante observación visual por expertos, lo cual es limitado por la disponibilidad de personal capacitado y puede dar lugar a errores de juicio. Además, muchos métodos modernos requieren equipos costosos o sofisticados, lo que dificulta su implementación en el campo (Deng et al., 2021, p. 3)(fpls-12-701038).

La agricultura de precisión (AP) busca optimizar los recursos mediante el uso de tecnologías avanzadas como el GPS, sensores remotos, drones y sistemas de soporte a decisiones (DSS). Esto permite un manejo espacial y temporal del cultivo, mejorando la rentabilidad y reduciendo el impacto ambiental (Orozco, O. A., & Llano Ramírez, G. (2016)). Además, la AP integra la gestión de datos agroclimáticos con mapas de productividad para tomar decisiones más informadas en cada fase del ciclo del cultivo (Orozco, O. A., & Llano Ramírez, G. (2016)).

Investigaciones recientes han demostrado que las redes neuronales convolucionales pueden ser eficaces para el reconocimiento de enfermedades en cultivos. Este enfoque permite evitar la extracción manual de características y mejorar la precisión de diagnóstico mediante modelos como DenseNet-121 y SE-ResNet-50 (Deng et al., 2021, p. 6)(fpls-12-701038).

Rajesh Yakkundimath., *et al.* (2022),. Presenta un estudio en el cual se implementan modelos avanzados de aprendizaje profundo (deep learning) basados en el enfoque de transfer learning para la clasificación de diversos síntomas de enfermedades en imágenes de plantas de arroz. Dichos modelos hacen uso de un set de 12.000 imágenes etiquetadas de tres enfermedades con 24 síntomas distintos, la evaluación de dichos modelos se realizó mediante el método de validación cruzada obteniendo un promedio de clasificación de 92.24%.

Teniendo en cuenta lo descrito anteriormente se puede evidenciar que la aplicación de modelos de machine learning en un entorno experimental arroja resultados positivos, lo cual puede proporcionar información fiable a los cultivadores de arroz, con el fin de poder tomar decisiones a partir de información veraz, y haciendo la aplicación de una agricultura

de precisión (AP) lo cual puede contribuir con la disminución de costos respecto a la detección precisa de enfermedades en los cultivos.

De igual manera de acuerdo a la investigación realizada se observa que los modelos de machine learning aplicados a esta problemática se fundamentan principalmente en el uso del deep learning, haciendo uso de los algoritmos de clasificación ya creados.

De acuerdo con Srdjan Sladojevic, Marko Arsenovic, Andras Anderla (2016), el método utilizado para la aplicación de los modelos de deep learning se fundamenta en las siguientes etapas:

- Adquisición de datos
- Preprocesamiento de imágenes
- Diseño de arquitectura DNN
- Entrenamiento arquitectura DNN
- Evaluación de arquitectura DNN

Respecto al modelo planteado por el autor como métricas de medición del modelo de hace uso de las métricas de precisión, F1 Score y Recall, apoyándose de igual manera en el uso de las respectivas matrices de confusión con el fin de tener un elemento visual para poder ver los resultados obtenidos por el modelo.

Tomando como tanto el modelo planteado por Rajesh Yakkundimath., *et al.* (2022) en su artículo “Classification of Rice Diseases using Convolutional Neural Network Models” y el propuesto por Srdjan Sladojevic, Marko Arsenovic, Andras Anderla (2016) en su artículo “Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image

Classification”, pudimos evidenciar que si bien la metodología de aplicación sigue los mismos

pasos, las redes neuronales utilizadas son distintas ya que para el primer modelo propuesto se hace uso de redes neuronales convolucionales (CNN) y para el segundo modelo propuesto se hace uso de redes neuronales profundas (DNN).

Teniendo en cuenta lo descrito, de acuerdo con el artículo publicado por Pragya Shukla(2024) “CNN vs DNN for visual understanding of images” las redes neuronales convolucionales (CNN) son particularmente poderosas en la comprensión visual dentro del procesamiento de imágenes, mientras que las redes neuronales profundas (DNN) disponen de una estructura mucho más general por lo cual las DNN se pueden aplicar a tareas de procesamiento de imágenes, pero las CNN están especialmente diseñadas para la comprensión visual de las imágenes.

Para este artículo el autor realiza un ejercicio de comparación de rendimientos entre los dos diferentes tipos de redes convolucionales haciendo uso de un DataSet de imágenes, obteniendo un resultado favorable de reconocimiento de imágenes haciendo uso de CNN sobre las DNN, por lo cual las CNN presentan resultados más favorables en cuanto a:

- Reconocimiento de imágenes
- Detección de objetos
- Clasificación de imágenes

Mientras que los escenarios en los cuales las DNN son más efectivas se encuentran en tareas de procesamiento de lenguaje natural (PLN), o en el análisis de datos estructurados.

Teniendo en cuenta la investigación realizada, para el desarrollo de nuestro modelo se hará uso de las redes neuronales convolucionales (CNN) utilizando principalmente las arquitecturas de clasificación de imágenes LeNet, AlexNet, y ResNet, las cuales han sido

utilizadas en modelos previamente entrenados y han presentado una alta precisión en los conjuntos de datos suministrados.

De acuerdo a lo descrito anteriormente vale la pena precisar que el desarrollo del modelo presentando sustenta su entrenamiento en la obtención y etiquetado de imágenes de los cultivos del arroz, por consiguiente surge un concepto importante y desde el cual inicia la obtención de las imágenes a analizar, y es el concepto de Agricultura de Precisión, el cual nace como una necesidad de controlar cultivos extensivos en los cuales se hace difícil el acceso a todos y cada uno de los metros cuadrados de terreno que deben ser vigilados constantemente para el control de plagas, infestaciones de malezas, etc. (Naji, 2019).

Vale la pena precisar que los cultivos extensivos a nivel mundial están relacionados con la siembra de cereales, algodón, caucho entre otros. De acuerdo a esto el arroz como el maíz posee la mayor extensión de tierra cultivada y el mayor número de personas dedicadas a su producción, el consumo per cápita mundial para el 2011, estuvo alrededor de los 65 kilogramos (Mohanty, 2013).

Teniendo en cuenta lo mencionado se hace necesario la implementación de tecnologías que apoyen la agricultura de precisión ya que la producción a nivel mundial de arroz se genera en 113 países, que según Bernardi(2017) para el caso de América la mayor producción la tiene Brasil con 13 millones de toneladas; sigue Estados Unidos con 10 millones de toneladas y en tercer lugar se encuentra Perú y Colombia con 3 millones de toneladas respectivamente.

METODOLOGIA


Descripción metodológica

El enfoque metodológico de este trabajo será principalmente cuantitativo, ya que se desarrollará un modelo de Machine Learning para la identificación y clasificación de enfermedades en cultivos de arroz a partir de imágenes. A través de la recolección de datos visuales, se utilizarán métricas como precisión, sensibilidad y especificidad para evaluar el desempeño del modelo. Además, se adoptará un enfoque descriptivo, donde se detallarán los procesos de recolección de datos, entrenamiento del modelo y la plataforma de visualización, con el fin de proporcionar un análisis claro sobre el funcionamiento del sistema. El componente cualitativo se incluirá en la fase de pruebas, donde se recogerá la retroalimentación de los agricultores sobre la efectividad y usabilidad del modelo, permitiendo hacer ajustes basados en sus comentarios.

El estudio tendrá también un enfoque transversal, ya que se llevará a cabo en un periodo específico, centrado en la recolección de datos durante una temporada de cultivo en el departamento de Casanare, sin seguimiento a largo plazo. Finalmente, se empleará un enfoque analítico para evaluar cómo el modelo responde a diferentes tipos de enfermedades y cómo se pueden mejorar sus predicciones, además de analizar la efectividad del modelo en condiciones reales a partir de la interacción con los agricultores. De esta forma, se busca desarrollar una solución práctica y eficaz que no solo sea precisa en su diagnóstico, sino también útil para los usuarios finales en el contexto agrícola.

Diseño metológico

Matriz de tareas



Objetivos específicos	Actividades	Resultado esperado	Responsable	Fecha/Cumplimiento
1 Recolectar imágenes de cultivos de arroz afectadas por enfermedades en diferentes datasets, que asegure una base de datos robusta y que pueda ser utilizada en el entrenamiento del modelo.	<ul style="list-style-type: none"> Consultar diferentes datasets. Validar la calidad de la información investigada Etiquetar las imágenes encontradas Reunirse con agricultor experto 	<ul style="list-style-type: none"> Tener establecido el dataset con el que se entrenará el modelo 	<ul style="list-style-type: none"> Juan Sebastian Gutierrez Zorro 	1/10
2 Evaluar las métricas de precisión, sensibilidad y especificidad del modelo seleccionado, que permita estimar el desempeño del modelo.	<ul style="list-style-type: none"> Diseñar la red neuronal a usar. Investigar tipos de redes ya existentes con el que el modelo puede funcionar. Entrenar el modelo y reentrenar para buscar la optimalidad del mismo. 	<ul style="list-style-type: none"> Realizar diferentes modelos con el fin de comparar los desempeños 	<ul style="list-style-type: none"> Juan Sebastian Gutierrez Zorro Jhon Jairo Romero 	20/10
3 Testear el modelo es un escenario real que permita su puesta en marcha.	<ul style="list-style-type: none"> Testear el modelo con el fin evaluar su funcionalidad en un escenario real. Buscar mejoras del modelo en caso de ser necesario. Desplegarlo en un entorno óptimo 	<ul style="list-style-type: none"> Tener un modelo idoneo con el fin de resolver la problemática expuesta al inicio del trabajo 	<ul style="list-style-type: none"> Jhon Jairo Romero Anderson Yesid Jiménez 	10/11
4 Desarrollar un MVP, mediante la cual se pueda realizar la visualización de los resultados obtenidos por el modelo, en la cual el agricultor pueda visualizar las coordenadas referentes a la imagen de la sección del cultivo que presenta la enfermedad, la foto, y el respectivo nombre de la enfermedad asociada	<ul style="list-style-type: none"> Desarrollar una plataforma en donde se puedan visualizar ciertos indicadores tales como: Datos del cultivo, enfermedades encontradas a partir del modelo creado 	<ul style="list-style-type: none"> Tener una plataforma (MVP) que permita visualizar algunos indicadores del cultivo junto con la información generada por el modelo. 	<ul style="list-style-type: none"> Anderson Yesid Jiménez 	13/11

Imagen propia

Fase de recolección de datos. En esta etapa, se recopilaron imágenes correspondientes a diversas enfermedades que afectan a los cultivos de arroz, provenientes de diferentes datasets. Este ejercicio fue necesario debido a la alta complejidad y el elevado costo de generar o crear esta información de manera propia. Para llevar a cabo esta tarea, se realizó una investigación detallada sobre las distintas enfermedades que impactan los cultivos de arroz. Seguidamente se investigó en varias fuentes tales como, Kaggle, RoboFlow o de algunos repositorios de ciencia como Natural Science Foundation of China, National Institute of Health, IEEE Data Port. Una vez obtenido el conjunto de datos, se validó con un agricultor experto en el tema, con el fin de asegurar la calidad de la información. El objetivo de este proceso es construir un conjunto de datos robusto, representativo y veraz, que sirva para el entrenamiento del modelo. En total se recopilaron 3736 imágenes de la


cuales se tenían 5 tipos de enfermedades y 1 clase llamada Healthy. Se tenía 587 Brown spot , eran 487 Leaf Blight, eran 540 Leaf Scald, eran 651 Leaf blast, 657 Narrow brown spot, 758 healthy.

Fase de preprocesamiento de datos. El conjunto de datos armado se organizó en una carpeta principal, dentro de la cual se crearon tres subconjuntos denominados Train, Test y Validation, destinados al entrenamiento, prueba y validación del modelo, respectivamente. Se asignó aproximadamente el 72% de las imágenes al subconjunto Train, el 21% al subconjunto Validation y el 7% al subconjunto Test.

En cuanto al preprocesamiento, las imágenes se redimensionaron a 224 x 224 píxeles para estandarizar su tamaño y facilitar la normalización, mejorando así la eficacia del entrenamiento del modelo. Además, se configuró un tamaño de lote (batch size) de 16 imágenes por iteración durante el aprendizaje de la red neuronal.

A continuación se muestran algunas de las imágenes usadas:

Bacterial leaf blight



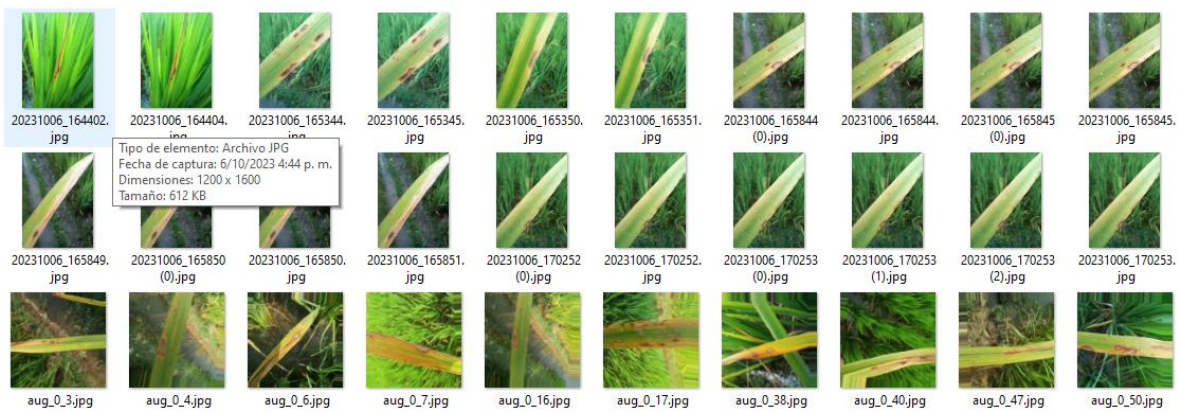
Brown spot




Healthy



Leaf Blast



Leaf Smut



Sheath Blight



Fase de diseño del modelo: La estructura de la red neuronal convolucional desempeña un papel fundamental en el rendimiento del modelo final. Para evaluar su efectividad en el diagnóstico de enfermedades del arroz, se comparó el desempeño de diferentes arquitecturas. Se incluyeron redes neuronales diseñadas por el autor de este trabajo, así como dos arquitecturas ampliamente reconocidas: ResNet y DenseNet.

Para las arquitecturas ResNet y DenseNet fueron ajustados utilizando el método de aprendizaje por transferencia con el fin de disminuir el tiempo de entrenamiento. El aprendizaje por transferencia significa aplicar el conocimiento aprendido de un conjunto de

datos a otro, lo cual ha demostrado ser efectivo para el reconocimiento de enfermedades en plantas (Kaya et al., 2019; Chen et al., 2020).

A continuación, se presentan los parámetros específicos de cada red

Modelo	Parámetros
Propio	424,006
ResNet	23,850,758
DenseNet	7,301,446

Tabla Parámetros. Propia

Fase de entrenamiento del modelo. En esta fase, se entrenaron los distintos modelos y se calcularon diversas métricas clave, como la precisión, la sensibilidad, la especificidad y el F1-score, para evaluar de manera integral su desempeño. Durante el proceso de entrenamiento, se identificaron áreas de mejora en los modelos, lo que llevó a la realización de reentrenamientos estratégicos.

Estos reentrenamientos incluyeron la implementación de regularizadores para evitar el sobreajuste, el uso de técnicas de *dropout* para mejorar la generalización, y la modificación de hiperparámetros como la tasa de aprendizaje, el número de capas y neuronas, y el tamaño del lote. Asimismo, se probaron diferentes configuraciones de optimizadores y

funciones de pérdida con el fin de encontrar la combinación óptima que maximizara el rendimiento del modelo.

El objetivo final fue garantizar que el modelo seleccionado no solo obtuviera altos puntajes en las métricas de evaluación, sino también que pudiera generalizar adecuadamente en datos no vistos, asegurando así su aplicabilidad en escenarios reales.

Fase de evaluación: El rendimiento de los modelos se comparó con el fin de seleccionar el mejor. Para cada modelo, los resultados de la predicción fueron, Verdaderos positivos (TP): predicciones correctas del tipo de enfermedad; Falso positivos (FP): otro tipo de enfermedad que fueron predichos como esta enfermedad; Verdaderos Negativos (TN): predicciones correctas de que la enfermedad no pertenece a otros tipos; Falsos Negativos (FN): La enfermedad fue predicha como otro tipo de enfermedad. Estos resultados se usaron para determinar el desempeño de: exactitud (accuracy), precisión (precision), tasa de recuperación (recall rate), puntaje F1 (F1 score).

$$A = \frac{\sum_{i=1}^6 TP_i}{N}$$

$$P_i = \frac{TP_i}{TP_i + FP_i}$$

$$R_i = \frac{TP_i}{TP_i + FN_i}$$

$$F1_i = \frac{2 * P_i * R_i}{P_i + R_i}$$

Donde **N** es el número total de imágenes de prueba, **A** es la exactitud, **P** es la precisión, **R** es la tasa de recuperación, **F1** es el puntaje F1, **i** representa el i-ésimo tipo de enfermedad, y

T_{Pi}, **F_{Pi}** y **F_{Ni}** son el número de verdaderos positivos, falsos positivos y falsos negativos, respectivamente, para el i-ésimo tipo de enfermedad.

Implementación del modelo. El modelo en conjunto se implementó en una plataforma que consistió en una arquitectura de software y una interfaz de usuario. El sistema de software tenía dos partes: el usuario y el servidor. El usuario debe realizar las peticiones al servidor mediante un navegador web. Para el desarrollo del aplicativo se utilizó el lenguaje php y una base de datos relacional de tipo SQL. Este aplicativo cumplirá la función de repositorio de imágenes e información asociados al cultivo estudiado.

Se propone utilizar drones especializados para obtener imágenes de los cultivos de arroz de manera eficiente y precisa. Estos drones cuentan con tecnología avanzada que les permite delimitar de forma automática el área que será sobrevolada, asegurando una cobertura completa y uniforme del terreno. Durante el vuelo, los drones capturan videos de alta calidad que posteriormente se procesan para convertirlos en imágenes estáticas de gran resolución.

Además, los drones registran las coordenadas geográficas exactas de cada punto donde se toman las imágenes, lo que permite asociar cada fotografía con su ubicación específica en el terreno. Toda esta información, incluyendo las imágenes y las coordenadas, se envía directamente a la plataforma de procesamiento de datos. Esto facilita el análisis visual y geoespacial, ayudando a detectar posibles enfermedades, deficiencias nutricionales u otras irregularidades en los cultivos de manera temprana y eficiente.

Una vez recopilada la información, el usuario podrá ingresar a la plataforma mediante sus credenciales para visualizar las imágenes capturadas y los posibles tipos de enfermedades identificadas en los cultivos. Además, tendrá acceso a información complementaria, como las propiedades del suelo, el tipo de semilla empleada, datos meteorológicos y pronósticos específicos según las coordenadas de la ubicación, entre otros. Esta funcionalidad permitirá realizar un seguimiento detallado de los cultivos, facilitando análisis comparativos a lo largo del tiempo y fomentando la implementación de mejoras continuas en su manejo y productividad usando otras técnicas del machine learning.

A continuación se muestra el Minimum viable product (MVP) o mínimo producto viable:

La siguiente imagen muestra el inicio de sesión para acceder a la plataforma.

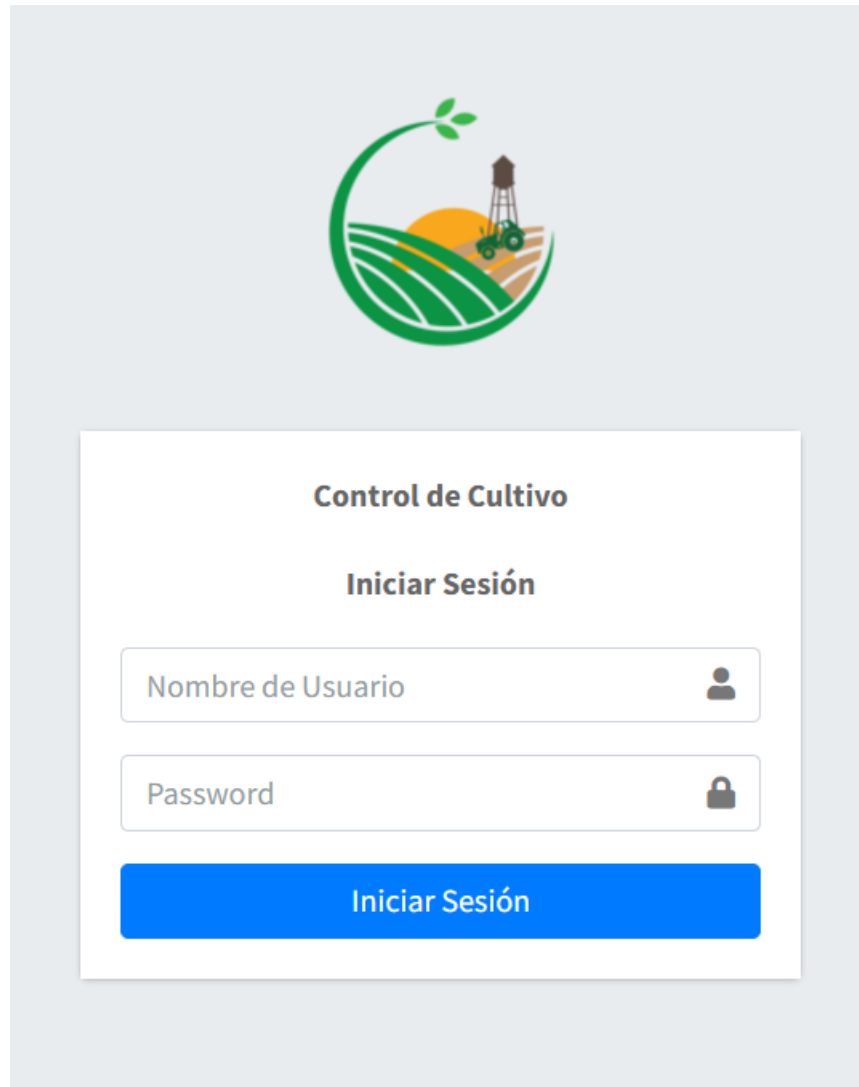


Imagen inicio sesión plataforma web

La siguiente imagen muestra la información asociada al cultivo.

AgriCoApp

Inicio Contacto

Admon Administrador

Gestión de Cultivos

Gestión de cultivo

Cerrar Sesión

Usuario: Admon

Administrar Cultivo

+ Registrar Cultivo

Copy CSV Excel PDF Print Column visibility Search:

idCultivo	areaSembrada	fechaEstimadaSiembra	fechaEstimadaCosecha	SemillaUtilizada	Operaciones
1	1	2024-11-01	2025-01-31	Comun	
2	8	2024-09-04	2024-11-24	Común 2	

Showing 1 to 2 of 2 entries

Previous 1 Next

Copyright © Todos los derechos reservados. Version 1.1.0

Vista general de la plataforma

La siguiente imagen muestra la vista general de la plataforma.

AgriCoApp

Inicio Contacto

Admon Administrador

Gestión de Cultivos

Gestión de cultivo

Cerrar Sesión

Módulo Inicial Admon

Tablero de control

2

Usuarios registrados

9Ha

Total de área sembrada

2

Total de imagenes recopiladas

Copyright © Todos los derechos reservados. Version 1.1.0

Vista general de la plataforma

DEFINICIÓN DE VARIABLE

Respecto a las variables principales asociadas al cultivo se cuenta con las siguientes:

VARIABLE	DEFINICIÓN CONCEPTUAL	DEFINICIÓN OPERACIONAL
Presencia de Enfermedad	Estado de salud del cultivo de acuerdo con la presencia de enfermedades	Medición binaria (0 – si equivale a ausente, 1- si equivale a presente) resultado obtenido de acuerdo al análisis de las imágenes recopiladas
Tipo de enfermedad	Clasificación de las enfermedades comunes en el cultivo de arroz	Identificación categoría de la enfermedad, haciendo uso del modelo de machine learning utilizado
Humedad del suelo	Cantidad de agua contenida en el suelo donde se encuentra el cultivo	Medición porcentual, de acuerdo con las condiciones físicas del cultivo
Nivel de Luz	Cantidad de luz que recibe el cultivo durante el periodo de crecimiento	Datos obtenidos de dispositivo de medición instalado en el cultivo
Edad de la planta	Tiempo transcurrido desde la germinación de la planta hasta la recolección de los datos	Medición en días desde la germinación de la planta
Temperatura ambiental	Historico de temperatura registrada en el desarrollo del cultivo	Medición en grados centígrados de acuerdo con lo registrado en el desarrollo del cultivo
Frecuencia de riego	Cantidad de veces que el cultivo es regado	Conteo de riegos en cada uno de los sectores del cultivo
Tiempo de exposición a plaguicidas	Cantidad de tiempo desde la última aplicación de plaguicidas al cultivo	Registro de fechas de fumigación

Respecto a la variables que se pretenden analizar en el desarrollo del modelo de machine learnign se encuentran las siguientes:

VARIABLE	DEFINICIÓN CONCEPTUAL
Etiqueta de imagen	Nombre de la enfermedad asociada a cada imagen
Imagen de planta de arroz	Imagen de la planta de arroz afectada por la enfermedad
Accuracy	Mide la proporción de predicciones correctas sobre el total de predicciones
Sensibilidad	Mide cuantos de los casos positivos reales fueron identificados correctamente
F1 Score	Es la media entre precisión y recall proporcionando una metrica balanceada, cuando las clases del modelo se encuentran desbalanceadas
Matriz de confusión	Proporciona de manera grafica las predicciones del modelo mostrando la cantidad de Verdaderos Positivos, Falsos Positivos, Verdaderos Negativos, Falsos Negativos, representa ayuda para modelos de clasificación
Curva ROC	Indica la capacidad del modelo para clasificar clases positivas y negativas en el desarrollo de cada una de las iteraciones de entrenamiento

POBLACIÓN Y MUESTRA

DESCRIPCIÓN DE LA POBLACIÓN

La población objeto de estudio se compone de los cultivos de arroz ubicados en el departamento del Casanare Colombia. Estos cultivos principalmente se componen del tipo de arroz **Oryza Sativa**, los cuales son conocidos como arroz común. Los cultivos a analizar ya se encuentran en la etapa de plantula a maduración, con un estado de salud visible, lo cual permita la recolección de imagenes de cultivos con el fin de poder utilizar dichas imagenes en la prueba del modelo de machine learning desarrollado.

Inicialmente se espera realizar la recolección de imagenes del cultivos ubicados en el departamento del Casanare, en donde se tomaran imagenes de manera aleatoria de cada uno

de los sectores del cultivo, con el fin de utilizarlas en las pruebas del modelo realizado, y evaluar la precisión respecto a la clasificación de las enfermedades, y las plantas que se encuentran en un estado saludable.

SELECCIÓN DE METODOS E INSTRUMENTOS

Recolección de datos: Inicialmente se realizará el uso de la técnica de fotografía manual, con el fin de obtener imágenes más cercanas, y que permitan la captura del mayor detalle posible de cada una de las plantas, puesto que el detalle de las imágenes en una de las principales restricciones con las que cuenta el modelo de machine learning, ya que su rendimiento en la clasificación depende de la calidad de las imágenes.

Metodos de analisis de datos: Respecto al analisis de los datos, en el desarrollo del modelo se aplicaran las tecnicas de vision computacional para poder procesar y analizar las imagenes con las cuales se realizará la validación del modelo.

En el desarrollo de dicha prueba se hará el uso de modelos preentrenados respecto a la clasificación de imágenes, haciendo uso de la arquitectura Res-Net50, arquitectura perteneciente a la familia de redes residuales, modelos los cuales están diseñados para el entrenamiento de redes neuronales profundas, con el fin de realizar labores de clasificación de imágenes.

Posteriormente respecto a las métricas del modelo, dichas se analizarán de manera estadística evaluando la cantidad de aciertos obtenidos respecto a las imágenes probadas, de igual forma tomando como base las métricas de precisión, sensibilidad y la matriz de confusión obtenida en el entrenamiento del modelo.

Producto del análisis de dichos datos, se evaluará la necesidad de hacer un reentrenamiento de dicho modelo, evaluando la posibilidad de ajustar los hiperparámetros que componen la red neuronal, o la cantidad de iteraciones realizadas en el proceso de entrenamiento.

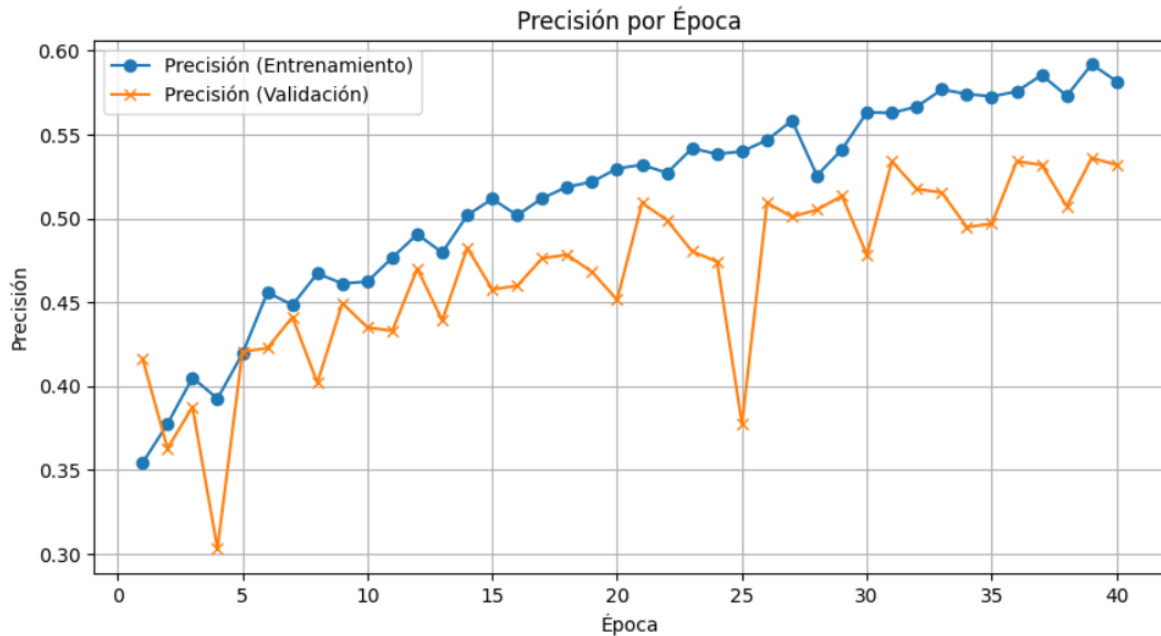
Teniendo en cuenta que el modelo no puede ser sobreentrenado, ya que se corre el riesgo de un overfitting lo cual conllevaría al sobre ajuste del modelo, lo cual equivale a la degradación del mismo, ya que no realizaría la clasificación de las imágenes de manera óptima.

De igual forma respecto a las variables físicas que componen el cultivo se desarrollará una plataforma web mediante la cual se realizará la captura de los datos necesarios, esto con el fin de poder contar con una información más robusta.

RESULTADOS OBTENIDOS

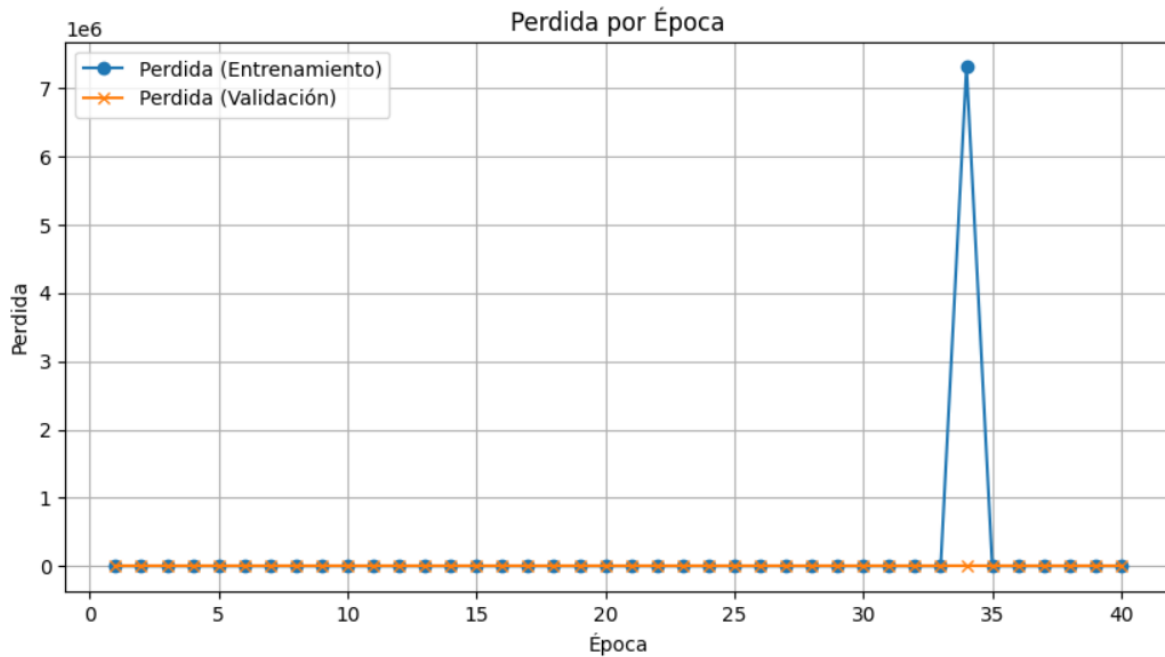
Después de realizar los entrenamientos de las diferentes redes evaluadas ResNet, DenseNet y Propia, a continuación se procede a mostrar los diferentes resultados que se obtuvieron de accuracy de entrenamiento, accuracy de validación, pérdida y matriz de confusión.

Para Resnet se obtuvo un accuracy de entrenamiento cercano al 57%, adicional un accuracy de validación cercano al 54%. Estos resultados sugieren que, aunque la técnica de *transfer learning* permitió cierto nivel de adaptación al nuevo dominio, el desempeño alcanzado no es suficiente para satisfacer los requerimientos del problema planteado. Adicional cabe mencionar que esta red al ser la de mayor parámetros requiere un costo computacional más elevado.

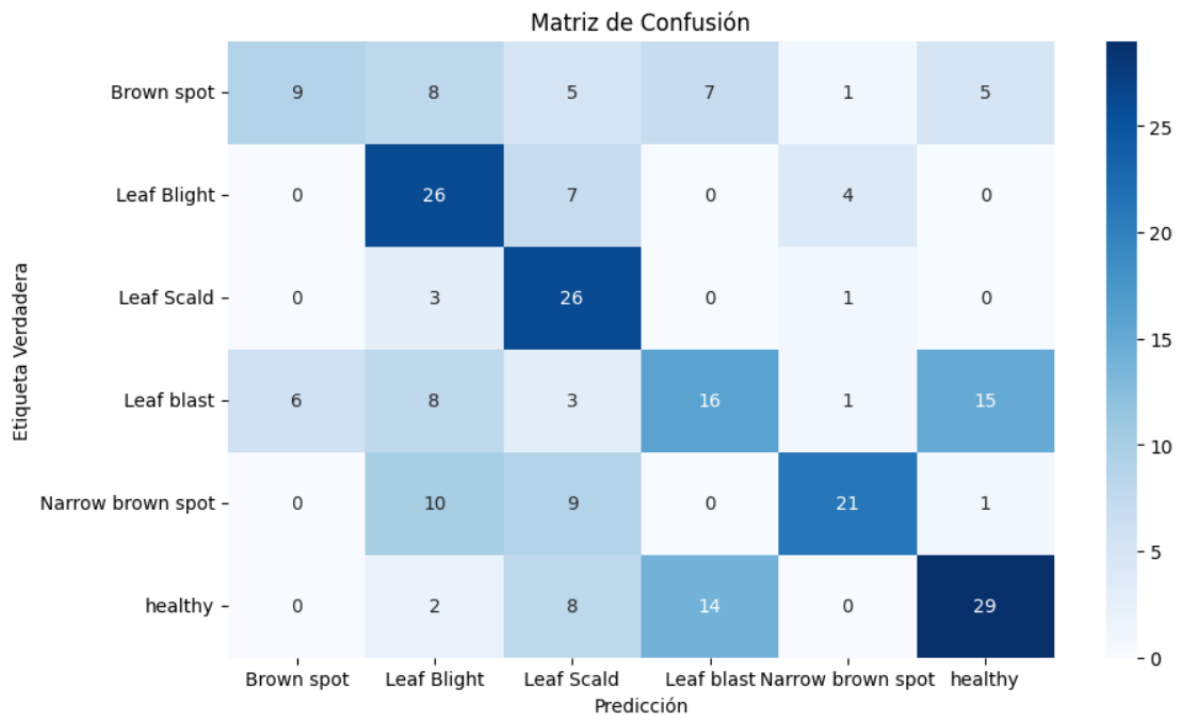


El análisis de la función de pérdida Al inicio del entrenamiento, la pérdida en el conjunto de entrenamiento era de 1.7122, lo que indicaba una discrepancia significativa entre las predicciones y las etiquetas reales. Sin embargo, con el avance del entrenamiento, la pérdida se redujo paulatinamente, alcanzando un valor de 1.1356 en la última época. Este descenso en la pérdida es indicativo de que el modelo ha ido aprendiendo a realizar predicciones más precisas y ajustadas a las etiquetas correctas.

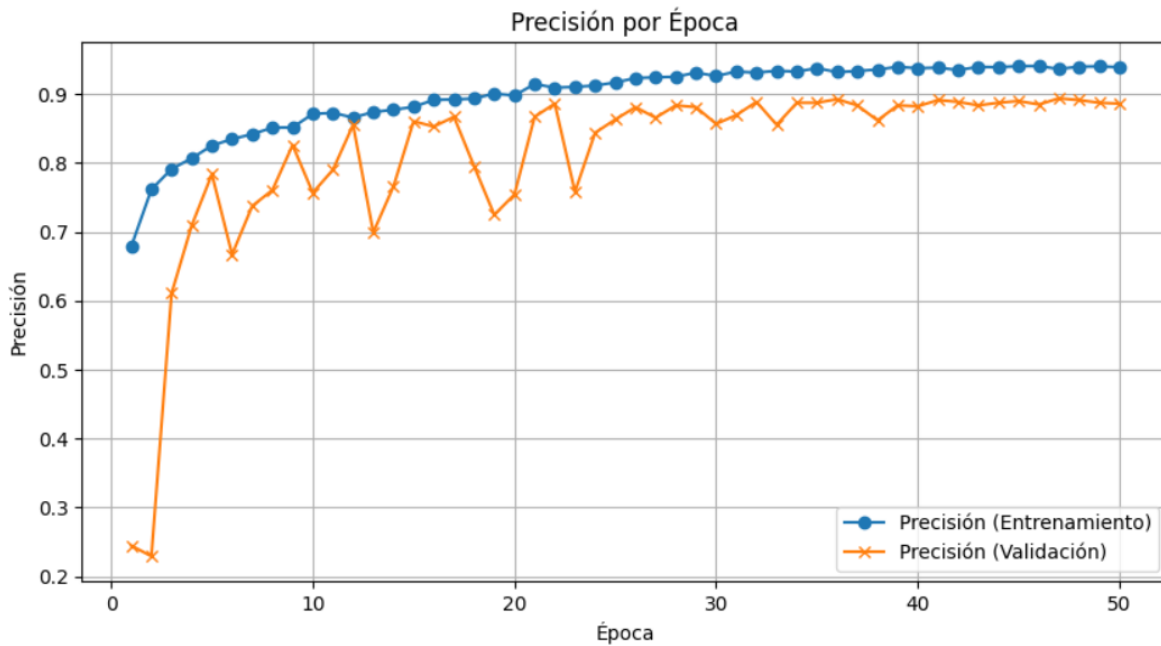
Es relevante notar que, a pesar de la disminución constante de la pérdida, en algunas épocas, como la época 34, se observa un valor atípico en el conjunto de entrenamiento (con una pérdida extremadamente alta de 16,583,193), lo que podría sugerir algún problema o anomalía en el proceso de entrenamiento o en los datos de entrada en esa iteración específica. Este tipo de fluctuaciones podría reflejar la presencia de ruido o datos no representativos en el conjunto de entrenamiento.



El modelo tiene un buen desempeño general, pero muestra confusión entre algunas clases, especialmente entre las clases 0, 1, y 3. Específicamente, algunas clases (como la clase 1 y clase 2) tienen menos confusión y están siendo clasificadas correctamente en la mayoría de los casos.




En la arquitectura propia se evidencia un incremento sostenido en la precisión del conjunto de entrenamiento, superando un valor del 90% después de la época 30. Sin embargo, la precisión en el conjunto de validación, aunque también muestra una mejora significativa durante las primeras épocas, fluctúa considerablemente y se estabiliza alrededor del 88%. Estas fluctuaciones en el conjunto de validación podrían atribuirse a la variabilidad intrínseca de los datos utilizados o a una posible sensibilidad del modelo a ciertas características específicas. La diferencia entre ambas curvas sugiere un ligero sobreajuste, a pesar de esto, el alto nivel de precisión alcanzado demuestra que el modelo logra un desempeño efectivo en la tarea de detección de enfermedades en los cultivos de arroz y puede llegar a generar beneficios.




Se observa que la pérdida en el conjunto de entrenamiento disminuye progresivamente de manera constante, comenzando en valores superiores a 1.5 y estabilizándose en torno a 0.5 al final del entrenamiento. Por otro lado, la pérdida en el conjunto de validación muestra una tendencia general a la baja, aunque con mayor variabilidad, empezando con valores alrededor de 2.25 y estabilizándose aproximadamente en 0.75 después de la época 30. Las fluctuaciones en la pérdida de validación podrían ser indicativas de diferencias entre los conjuntos de datos de entrenamiento y validación, o de un modelo que presenta ligeras dificultades para generalizar en ciertos casos. Sin embargo, el comportamiento convergente de ambas curvas hacia el final del entrenamiento sugiere que el modelo ha logrado

minimizar eficazmente su error, lo que respalda la efectividad del proceso de aprendizaje.

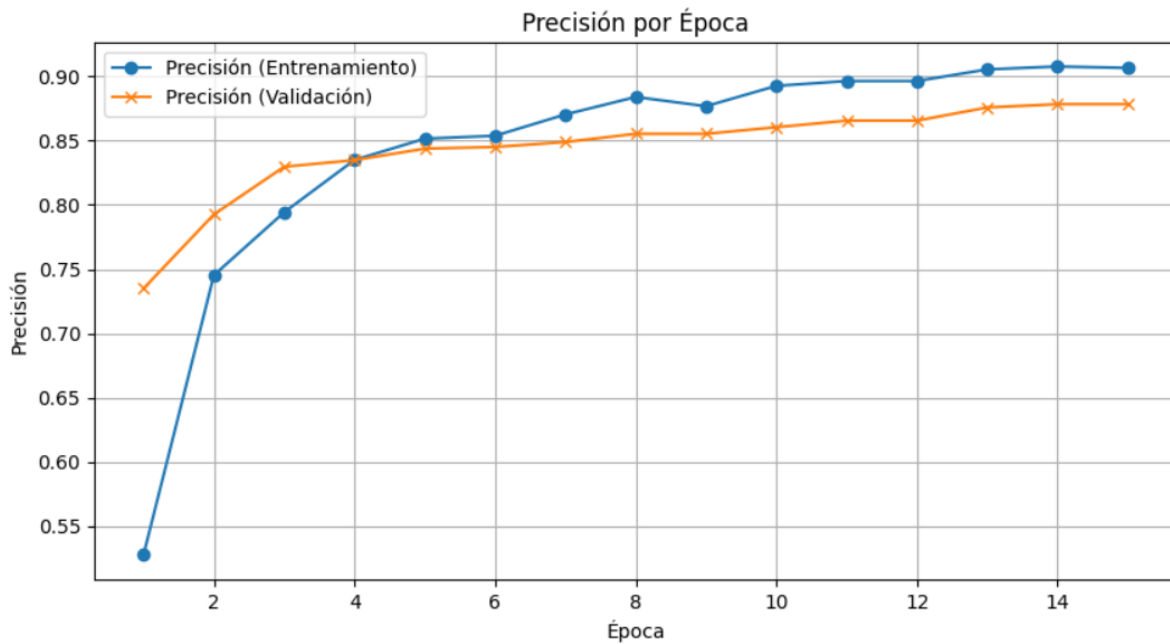


La matriz obtenida muestra un rendimiento bastante sólido en general, con la mayoría de las clases bien identificadas. En particular, la clase leaf blast presenta la mayor cantidad de verdaderos positivos (39), mientras que la clase leaf blight muestra un rendimiento igualmente alto con 34 verdaderos positivos. Sin embargo, se observan algunos errores de clasificación en las clases Narrow brown spot y Healthy, donde se presentan confusiones con otras clases, como se evidencia en las casillas correspondientes a falsos positivos y falsos negativos. En términos generales, la matriz indica que el modelo tiene un desempeño robusto, pero existen áreas que pueden beneficiarse de una mayor optimización, particularmente en las clases menos representadas.

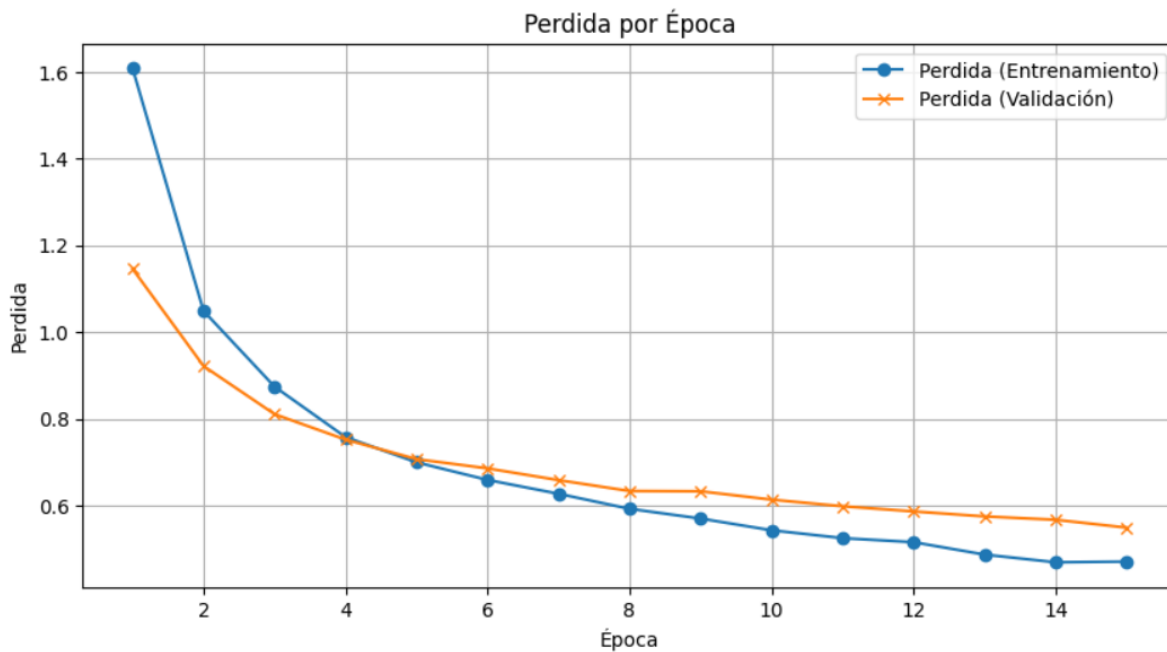


Para DenseNet en la primera época, el modelo alcanzó una precisión de 39.36% en el conjunto de entrenamiento y 73.50% en el conjunto de validación, lo que refleja una capacidad inicial de generalización moderada. A lo largo de las épocas, el modelo continuó mejorando su rendimiento, alcanzando una precisión de 90.93% en el conjunto de entrenamiento al final de la última época. En el conjunto de validación, la precisión llegó al 87.84%, lo que indica una excelente capacidad de generalización y una adecuada capacidad del modelo para clasificar correctamente las imágenes de enfermedades en los cultivos de

arroz.

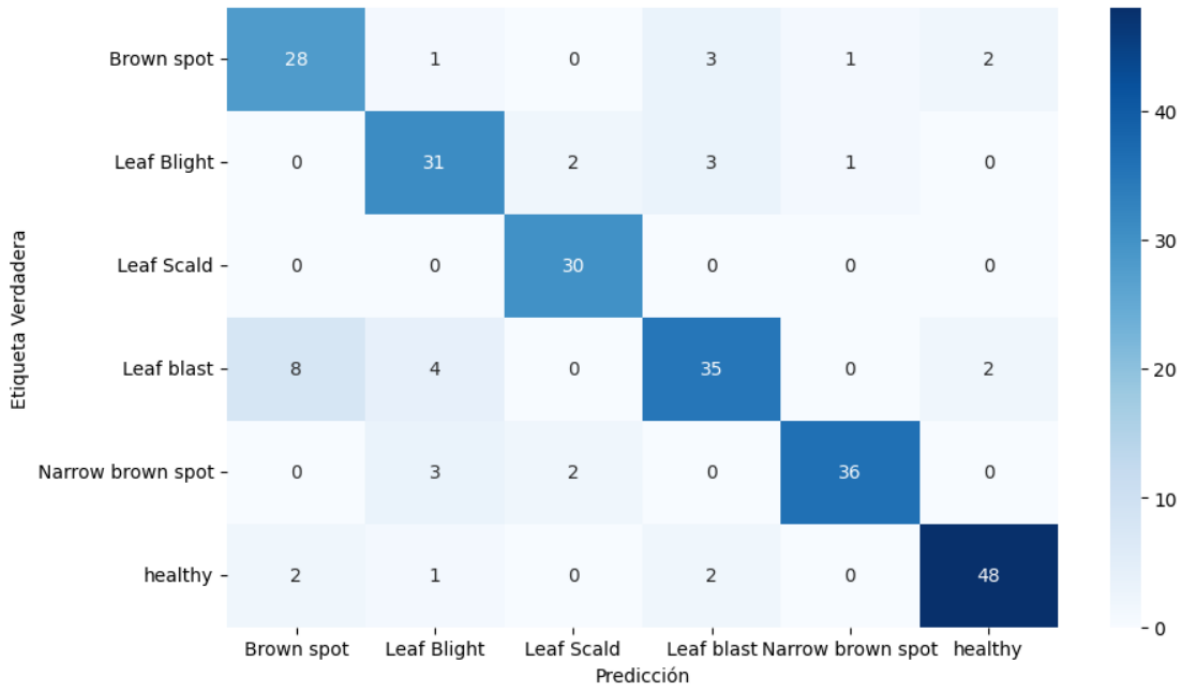


El modelo mostró una disminución constante a lo largo de las 15 épocas de entrenamiento, lo que indica un proceso de optimización efectivo. En la primera época, la pérdida en el conjunto de entrenamiento fue de 1.96, mientras que en el conjunto de validación fue de 1.14, lo que refleja una diferencia significativa que puede ser atribuida a la falta de generalización en la fase inicial. Sin embargo, con el transcurso de las épocas, la pérdida en el conjunto de entrenamiento disminuyó de manera sostenida, alcanzando un valor de 0.46 en la última época. De manera similar, la pérdida en el conjunto de validación también mejoró, llegando a 0.54 al final del entrenamiento. Estos resultados sugieren que el modelo ha logrado un buen equilibrio entre la capacidad de aprendizaje y la generalización, minimizando los errores tanto en los datos de entrenamiento como en los de validación, lo cual es crucial para su desempeño en la clasificación de enfermedades en los cultivos de arroz.



La evaluación del modelo también se realizó a través de la matriz de confusión, que permite observar el desempeño del modelo en cada clase. Los resultados mostraron una clasificación bastante precisa, con una mayor cantidad de verdaderos positivos en varias clases. En particular, la clase 3 alcanzó 35 verdaderos positivos, y la clase 6 obtuvo 48, lo que indica un buen desempeño en la identificación de estas clases. Sin embargo, también se observaron algunos errores de clasificación, especialmente en las clases 1, 4 y 5, donde se produjeron ciertos falsos positivos y falsos negativos. Por ejemplo, la clase 1 presentó 8 falsos positivos, y la clase 4 tuvo 2 falsos negativos. Estos resultados sugieren que, aunque el modelo muestra un rendimiento global fuerte, hay áreas en las que se podrían realizar mejoras, especialmente en las clases con una mayor confusión entre categorías.

Matriz de Confusión



Conclusion

En conclusión, el modelo de Machine Learning basado en redes neuronales para la identificación y clasificación temprana de enfermedades en los cultivos de arroz ha demostrado que puede ser una herramienta eficaz para abordar uno de los desafíos más críticos en la agricultura moderna: la reducción del uso de agroquímicos y la disminución de los costos de producción. A través de la recolección de una base de datos robusta de imágenes de cultivos afectados por diversas enfermedades, el modelo ha sido entrenado para detectar patrones específicos que permiten una intervención temprana y precisa. Las evaluaciones de las métricas de precisión, sensibilidad y especificidad han mostrado un desempeño notable del modelo, lo que respalda su capacidad de generalizar en escenarios reales. Además, el desarrollo de un MVP con una interfaz amigable para el agricultor proporciona una solución práctica y accesible para la visualización de resultados en tiempo real, facilitando la toma de decisiones informadas y mejorando la eficiencia en el manejo de los cultivos. Este enfoque innovador no solo optimiza los procesos agrícolas, sino que también contribuye a un manejo más sostenible y económico de los cultivos de arroz en el departamento de Casanare, abriendo la puerta a futuras aplicaciones de inteligencia artificial en la agricultura.

REFERENCIAS

ACOSTA, J. Evaluación del sistema intensivo de cultivo arrozero (Sica) en el municipio de Purificación, Tolima. Bogotá D.C. 2011. (Tesis de pregrado). Universidad de Cundinamarca.

Fedearroz. (s.f.). Estadísticas arroceras. <https://fedearroz.com.co/es/fondo-nacional-del-arroz/investigaciones-economicas/estadisticas-arroceras/>

Revista: “ *Deep Learning for Plant Identification in Natural Environment*” (Yu Sun, Yuan Liu, Guan Wang, Haiyan Zhang) 22 May 2017.

Statista. (s.f.). Principales países a nivel mundial según el consumo de arroz. Statista. <https://es.statista.com/estadisticas/598940/principales-paises-a-nivel-mundial-segun-el-consumo-de-arroz/>

FAO. (s.f.). *El arroz: Fuente clave para la seguridad alimentaria y las economías rurales.* Organización de las Naciones Unidas para la Agricultura y la Alimentación.

<https://www.fao.org/economic/est/publicaciones/publicaciones-sobre-el-arroz/es/>

Organización de las Naciones Unidas para la Alimentación y la Agricultura - FAO. (2021).

FAOSTAT statistical database [Base de datos]. Roma. Disponible en:

<http://www.fao.org/faostat/en/>

Orozco, O. A., & Llano Ramírez, G. (2016). Sistemas de información enfocados en tecnologías de agricultura de precisión y aplicables a la caña de azúcar, una revisión.

Revista Ingenierías Universidad de Medellín, 15(28), 103-124. Recuperado de

<http://www.redalyc.org/articulo.oa?id=75047635007>

Revista: ***“Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification”*** (Srdjan Sladojevic, Marko Arsenovic, Andras Anderla) 22 June 2016.

Brayan Andrés Ortiz González, Emanuel Hernández medina universidad pontificia bolivariana escuela de ingenierías y arquitectura facultad de ingeniería electrónica montería 2022, trabajo de grado **“análisis de imágenes multiespectrales obtenidas en cultivos de arroz para la determinación de anomalías”**

Yakkundimath, R., Saunshi, G., Anami, B., & Palaiyah, S. (2022). Classification of rice diseases using convolutional neural network models. *Journal of The Institution of Engineers (India): Series B*, 103(4), 1047–1059. <https://doi.org/10.1007/s40031-021-00704-4>

Deng, R., Tao, M., Xing, H., Yang, X., Liu, C., Liao, K., & Qi, L. (2021). Automatic diagnosis of rice diseases using deep learning. *Frontiers in Plant Science*, 12, 701038.

Morera Torres, S, Velásquez Zabaleta, M y Viveros Barrera, J. (2018). El impacto del Programa Colombia Siembra sobre la producción primaria del arroz : ¿a quién benefició más?. Uniandes. Disponible en: <http://hdl.handle.net/1992/35049>.