

UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ

Colegio de Ciencias e Ingenierías

Detección temprana de Oídio sp. en el cultivo de rosas con el uso de inteligencia artificial.

Leslier Gabriela Díaz López

Ingeniería en Ciencias de la Computación

Trabajo de fin de carrera presentado como requisito
para la obtención del título de
Ingeniera en Ciencias de la Computación

Quito, 19 de mayo de 2023

UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ

Colegio de Ciencias e Ingenierías

**HOJA DE CALIFICACIÓN
DE TRABAJO DE FIN DE CARRERA**

**Detección temprana de Oídio sp. en el cultivo de rosas con el
uso de inteligencia artificial.**

Leslier Gabriela Díaz López

Nombre del profesor, Título académico

Daniel Fellig Goldvechmiedt, MSc.

Quito, 19 de mayo de 2023

© DERECHOS DE AUTOR

Por medio del presente documento certifico que he leído todas las Políticas y Manuales de la Universidad San Francisco de Quito USFQ, incluyendo la Política de Propiedad Intelectual USFQ, y estoy de acuerdo con su contenido, por lo que los derechos de propiedad intelectual del presente trabajo quedan sujetos a lo dispuesto en esas Políticas.

Asimismo, autorizo a la USFQ para que realice la digitalización y publicación de este trabajo en el repositorio virtual, de conformidad a lo dispuesto en la Ley Orgánica de Educación Superior del Ecuador.

Nombres y apellidos: Leslier Gabriela Díaz López

Código: 00205238

Cédula de identidad: 1727572172

Lugar y fecha: Quito, 19 de mayo de 2023

ACLARACIÓN PARA PUBLICACIÓN

Nota: El presente trabajo, en su totalidad o cualquiera de sus partes, no debe ser considerado como una publicación, incluso a pesar de estar disponible sin restricciones a través de un repositorio institucional. Esta declaración se alinea con las prácticas y recomendaciones presentadas por el Committee on Publication Ethics COPE descritas por Barbour et al. (2017) Discussion document on best practice for issues around theses publishing, disponible en <http://bit.ly/COPETheses>.

UNPUBLISHED DOCUMENT

Note: The following capstone project is available through Universidad San Francisco de Quito USFQ institutional repository. Nonetheless, this project – in whole or in part – should not be considered a publication. This statement follows the recommendations presented by the Committee on Publication Ethics COPE described by Barbour et al. (2017) Discussion document on best practice for issues around theses publishing available on <http://bit.ly/COPETheses>.

RESUMEN

El cultivo de rosas en el Ecuador presenta uno de los mayores aportes económicos en nuestro país, debido a su exportación en gran medida. Debido a esto, es necesario cumplir con un estándar de alta calidad, es crucial abordar el problema de las enfermedades que afectan a las rosas, siendo el Oídio sp la enfermedad más común para las hojas, lo cual afecta negativamente al proceso de fotosíntesis causando que se marchiten. Una posible solución para los agricultores es la detección temprana de la enfermedad, a través del uso del aprendizaje automático.

El elemento esencial del aprendizaje automático es la implementación de redes neuronales, las cuales generan un modelo de análisis de entrenamiento a través de un conjunto de datos. Para este trabajo en específico se implementaron las redes neuronales convolucionales, utilizando los modelos VGG19 y VGG16. Dichos modelos, fueron empleados con diferentes dataset y parámetros; obteniendo múltiples resultados presentes en la gráfica “épocas vs loss”; y los valores relacionados al comportamiento del entrenamiento como son: “accuracy”, “precisión”, “recall”, “F1 score”.

Se utilizó el método StratifiedKFold para generar un modelo con una distribución equilibrada de los datos, lo cual ayudó a controlar el sobreajuste “overfitting” y mejoró las métricas. Gracias a la creación de este modelo de aprendizaje, es posible detectar tempranamente la enfermedad y evitar su propagación.

Palabras clave: aprendizaje automático, Oídio, Redes Neuronales convolucionales, rosas

ABSTRACT

The cultivation of roses in Ecuador is one of the main sources of economic income for the country, as they are exported to a large extent. To maintain a high quality standard, it is crucial to address the problem of diseases affecting roses, with powdery mildew being the most common leaf disease, which negatively affects photosynthesis and causes wilting. A viable solution for growers is early detection of this disease through machine learning.

The fundamental component of machine learning is the implementation of neural networks, which generate analysis models using data sets. In this case, convolutional neural networks were employed using the VGG19 and VGG16 models. These models were used with different datasets and parameters, which produced multiple results that were represented in a graph of "epochs vs. loss" and values related to training performance, such as "accuracy", "precision", "recall" and "F1 score".

The StratifiedKFold method was used to generate a model with a balanced distribution of the data, which helped control overfitting and improved the metrics. Thanks to the creation of this learning model, it is possible to detect the disease early and prevent its spread.

Keywords: machine learning, powdery mildew, convolutional neural networks, rose

ÍNDICE

RESUMEN	5
ABSTRACT	6
Capítulo 1	10
Introducción	10
1.2 Justificación del Tema	11
1.3 Objetivos	12
Capítulo 2	13
Estado de arte	13
2.1 Oídio en rosas	13
2.2 Variables Incidencia y Severidad	13
2.3 Aprendizaje automático	14
2.4 Redes Neuronales	16
2.5 Deep Learning	17
CAPÍTULO 3	20
Metodología de desarrollo	20
CAPÍTULO 4	33
CONCLUSIONES	36
Recomendaciones y trabajos futuros	38
Bibliografía.....	40

Índice de Figuras

Figura 1: Arquitectura VGG19.....	22
Figura 2: Gráfica de Loss vs Épocas	23
Figura 3: Gráfica de Loss vs Épocas	24
Figura 4: VGG16 Arquitectura.....	25
Figura 5: Gráfica de Loss vs Épocas	27
Figura 6: Figura 7: Gráfica de Loss vs Épocas.....	28
Figura 8: Gráfica de Loss vs Épocas	29
Figura 9: Gráfica de Épocas vs Accuracy	30
Figura 10: Gráfica de Loss vs Épocas	31
Figura 11: Gráfica de Épocas vs Accuracy	31

Índice de Tablas

Tabla 1: Cálculo de métricas	24
Tabla 2: Cálculo de métricas	24
Tabla 3: Cálculo de métricas	27
Tabla 4: Cálculo de métricas	28
Tabla 5: Cálculo de métricas	29
Tabla 6: Matriz de confusión.....	29
Tabla 7: Cálculo de métricas	31
Tabla 8: Matriz de confusión.....	31

CAPÍTULO 1

Introducción

En la actualidad, el cultivo de rosas en Ecuador desempeña un papel importante en la economía del país. Este producto ha ganado reconocimiento en diversos mercados internacionales debido a su excelente calidad y belleza. Sin embargo, mantener los estándares necesarios para la exportación enfrenta varias dificultades, principalmente debido a la presencia de plagas que causan grandes pérdidas económicas y de tiempo. Entre las enfermedades más comunes se encuentran el Velloso, Botrytis y el Oídio s.p., causado por el hongo “*Sphaerotheca Pannosa*”. Estos afectan tanto a las hojas como los capullos de las rosas, manifestándose como un polvo de color ceniza. Para tratar esta enfermedad, se emplea un procedimiento que implica la eliminación manual de las rosas afectadas y el uso de pesticidas (Vera, 2019). Es necesario, contar con personal especializado en agricultura que realice muestreos de las plantaciones, los cuales se envían posteriormente al laboratorio para su análisis y tratamiento. Todo este proceso requiere un tiempo considerable de ejecución.

Por otro lado, las enfermedades presentadas en las rosas evitan que tengan un crecimiento y desarrollo adecuado, llegando incluso a provocar la pérdida total de las plantaciones. El Oídio, con su distintiva capa de polvo, impide que las rosas realicen fotosíntesis, lo que ocasiona que las rosas se marchiten. Esta enfermedad se propaga con facilidad por la plantación, debido al viento. Dado a su textura puede ser difícil de reconocer, los agricultores inexpertos no identifican fácilmente los síntomas de la enfermedad. Es por esto, que las técnicas de “Machine Learning” pueden ayudar a que este proceso de detección del Oídio sea más fácil.

El primer paso consiste en recopilar datos representativos que se utilizarán para entrenar una red neuronal específica para detectar la enfermedad en las hojas. Asimismo, los algoritmos de "Machine Learning" se emplean para mejorar el reconocimiento, la confiabilidad y la detección de enfermedades en las plantas [2].

1.2 Justificación del Tema

Desde los años 90, la industria florícola de Ecuador ha experimentado un desarrollo en los cultivos de rosas para exportación. Este sector se ha convertido en uno de los principales impulsores del comercio exterior y ha contribuido significativamente a la economía del país [3]. Ecuador es reconocido como uno de los países con mayor diversidad de rosas y ha logrado destacarse como un exportador en el mercado de flores no tradicionales [4]. En el año 2020, se registró un crecimiento positivo del 7,43%, lo que generó importantes ingresos y contribuyó a la Balanza Comercial Agropecuaria, consolidando así la posición competitiva del producto [5].

Sin embargo, la producción de rosas se ve afectada por enfermedades que impiden alcanzar la calidad necesaria para su comercialización. Estas enfermedades causan síntomas que provocan grandes pérdidas económicas para los agricultores. Para detectar tempranamente las plagas y enfermedades, es necesario llevar a cabo una supervisión constante de los cultivos para evitar posibles amenazas. En este sentido, el uso del aprendizaje automático permite mejorar la supervisión habitual mediante la implementación de un sistema automatizado, lo que garantiza una mayor precisión en el control del Oídio s.p. en los cultivos.

1.3 Objetivos

I. Generales.

Desarrollar un modelo de aprendizaje que permita la detección temprana del Oídio sp en el cultivo de rosas mediante el uso de inteligencia artificial.

II. Específicos.

- Emplear un “dataset” de imágenes de rosas para la identificación de la enfermedad más frecuente.
- Establecer la metodología adecuada para determinar la presencia de Oídio sp.
- Desarrollar y entrenar un modelo neuronal capaz de predecir el Oídio sp en las rosas.

CAPÍTULO 2

Estado de arte

2.1 Oídio en rosas

Alrededor del mundo, la agricultura presenta una pérdida del 35% de la producción, siendo el 14% atribuido a enfermedades o plagas (Anvarionovich, Zafarovich, 2021). En el Ecuador, el 71% de rosas cultivadas se destinan a la exportación, convirtiendo este producto en el principal representante dentro de la categoría de flores de nuestro país (Espín, 2021). Los principales síntomas del Oídio presentado en las rosas se manifiestan en las hojas, evidenciándose como un polvo de tono cenizo que, con el tiempo, puede tornarse blanco o incluso café, causando deformaciones y la caída de las hojas. Esta enfermedad también puede afectar los tallos y los botones florales. El Oídio se propaga a través del viento y se deposita en las hojas de las rosas, donde germina y desarrolla pequeñas raíces que absorben los nutrientes de la planta, afectándola directamente. Debido a su impacto en la estética, el Oídio es considerado la enfermedad más perjudicial para las rosas, lo cual repercute directamente en su valor comercial (Espín, 2021).

2.2 Variables Incidencia y Severidad

La incidencia se detecta a base de un proceso de observación, que se realiza individualmente con cada hoja para revisar si tienen o no presencia de una enfermedad. Esto se calcula a través de una fórmula (Guamán, 2023). Sabiendo que los folios es una sola hoja del conjunto de hojas, se presenta la siguiente ecuación:

$$\text{Incidencia}(\%) = \frac{\text{Nro. de foliolos afectados}}{\text{Nro. total de foliolos (enfermos + sanos)}} \times 100$$

La severidad es un proceso que permite conocer el porcentaje de enfermedad que tiene la hoja. Esto se calcula a través de una fórmula. Sabiendo que el área foliar es todo el conjunto de varias hojas, se presenta la siguiente ecuación:

$$\text{Severidad} = \left(\frac{\text{Área afectada}}{\text{Área foliar}} \right) \times 100$$

2.3 Aprendizaje automático

La Inteligencia Artificial (IA), se encarga del auto aprendizaje de algoritmos, derivando conocimientos de datos para realizar predicciones. Un sistema de aprendizaje automático es la agrupación de algoritmos que toman decisiones, para resolver problemas basándose en la experiencia acumulada (Espín, 2021). Además, al resolver problemas, el sistema puede trabajar en entornos reales, lo que permite tener una alternativa más eficiente para la obtención de conocimiento de datos. El aprendizaje automático se puede encontrar en el uso de spam de correos electrónicos, reconocimiento de voz y texto, autos autónomos y software de reconocimiento.

Por otro lado, un subcampo de la inteligencia artificial es el “Machine Learning”, que permite crear sistemas que aprenden automáticamente (Calderón, 2019). Se encarga de identificar patrones para crear un modelo o algoritmo que genere un aprendizaje de predicción de muestra de datos. El aprendizaje supervisado es la enseñanza a través de

datos que están etiquetados de entrada y salida, que permiten realizar predicciones; es decir, es un conjunto de datos etiquetados y clasificados que se conoce a que grupo pertenecen. Además, el sistema se encarga de aprender a distinguir dos o más clases. Por ejemplo, el entrenamiento se puede encontrar en la clasificación de correos no deseados, específicamente en grupos de correos etiquetados como spam y no spam.

De igual forma, la regresión es la predicción de datos continuos, denominado análisis de regresión. En una ecuación que tiene la relación lineal con dos variables, donde realiza una estimación del valor de la variable dependiente y un valor a la variable independiente (Espín, 2021). Este sistema permite predecir un resultado con la variable que tenga una respuesta continua y encontrar una relación entre las variables.

El sistema de aprendizaje automático no supervisado presenta los datos que no tienen etiquetas y tienen una estructura desconocida, que permite tener una exploración en los datos para la extracción de información relevante. La agrupación en clústeres (búsqueda de patrones) permite explorar el análisis de los datos, con un conjunto de información o subgrupos que tengan similitud de características. Este método es utilizado en marketing para descubrir grupos de clientes que tengan igualdad de intereses o preferencias. Este sistema es implementado en la visualización de datos a través de histogramas o diagramas de dispersiones con características unidimensionales, bidimensionales o tridimensionales.

Por otro lado, está el sistema de aprendizaje de reforzamiento, que se encarga de desarrollar un agente que mejore el desempeño de las interacciones con el entorno; este se denomina sistema de retroalimentación, el cual se ejecuta mediante una función de recompensa, con prueba y error. Las máquinas de vectores de soporte (SVM), realizan

tareas de clasificación y regresión. Se puede ver su aplicación en el procesamiento de lenguaje natural, reconocimiento de imágenes y la visión artificial (Nagaveni, Raghavendra, 2019).

2.4 Redes Neuronales

Son modelos de aprendizaje donde la computadora aprende a realizar una acción mediante el análisis de entrenamiento; se inspira en la estructura funcional del cerebro. Este sistema genera una conexión de las neuronas entre sí, es decir, una neurona de entrada está conectada con una de salida, donde se realizan varias réplicas de sus conexiones. Las redes neuronales actualmente se emplean en el monitoreo médico, robótica y reconocimiento de imágenes (Erazo, Uema, 2020). Se distribuyen por capas, que reciben datos de la capa inferior, y en la capa superior se determina el error usado para modificar los pesos de las conexiones entre neuronas para ir decreciendo el error. El proceso es continuo hasta lograr un trabajo óptimo. Esto implica que puede generalizar la red apropiadamente evitando el fenómeno de sobreajuste “overfitting”.

En un sistema de aprendizaje automático, los nodos asignan pesos a los datos de entrada. Durante el entrenamiento, estos pesos se ajustan para que la red se acerque a las etiquetas deseadas. El objetivo es encontrar un equilibrio en el ajuste de pesos para evitar el sobreajuste, donde la red se adapta demasiado a los datos de entrenamiento. Se busca lograr que la red se acerque a las etiquetas de entrenamiento sin perder su capacidad de generalización en nuevos datos.

Las redes neuronales convolucionales son utilizadas para datos con topología de malla, debido a que se encargan de localizar patrones en imágenes, escenas y objetos. Es decir,

se encargan de la clasificación de imágenes, sin utilizar la extracción manual de características que se busca. Tienen neuronas con tres dimensiones: ancho, alto y profundidad. Además, utilizan redes ya existentes para realizar nuevas tareas (Calderón, 2019).

2.5 Deep Learning

El “Deep Learning” es considerado un aprendizaje profundo, un subcampo del “Machine Learning”. Utiliza el aprendizaje a través de capas sucesivas de representaciones significativas (Valenzuela, 2021). Tiene una capa de entrada que es la que recibe los datos y los transmite a la capa oculta, donde se realizan modificaciones para buscar la similitud con la variable objeto (donde se asignan los datos), para finalmente pasar a la capa de salida donde devuelve los datos de predicción. Este proceso lo realiza con nodos que representan un porcentaje de la imagen original; donde al final, cuando todos los nodos se juntan forman la imagen completa.

El “Deep Learning” es aplicado actualmente por Facebook, para la identificación de rostros en fotos, donde el software desarrollado es capaz de reconocer a los diferentes usuarios. Además, “Deep Learning” se presenta en el reconocimiento de voz para poder escribir un mensaje en el celular.

2.4 Trabajos Relacionados

En el estudio presentado en (Espín, 2021), se detalla cómo se llevaron a cabo la construcción y preprocesamiento de los datos obtenidos mediante un dron que sobrevoló una plantación de rosas. Si bien el dispositivo permitía enviar imágenes en tiempo real,

se encontraron dificultades debido a la necesidad de una red de internet para transmitir los datos. Para el desarrollo de clasificación de datos, se optó por un proceso manual de preprocesamiento, en el cual se revisaron y descartaron aquellas imágenes que presentaban ruido. Posteriormente, se llevaron a cabo el etiquetado de las imágenes para identificar la presencia del Oídio, utilizando la herramienta “LabelImg”, la cual permitió una anotación gráfica de las imágenes y tuvo un proceso exitoso. Para el uso del aprendizaje automático, se empleó una metodología de redes neuronales convolucionales (CNN) y el “Framework YOLO” para el etiquetado y la predicción de las imágenes. Los resultados obtenidos fueron satisfactorios, con un área sobre la curva de 79% y una precisión de 73%.

En el estudio presentado (Muñoz, 2019), se utilizaron un conjunto de datos compuesto únicamente por imágenes de rosas de color rojo, en las cuales se identificaron características específicas relacionadas con el tallo y el tamaño del botón (ancho y alto). El enfoque se centró en la detección de la enfermedad del veloso. Para la clasificación de imágenes, se empleó el software “Classification Learner” de Matlab, logrando porcentajes altos. Sin embargo, las imágenes tenían un fondo complejo, lo cual dificultó el proceso de análisis. Además, se implementó el método “Bag of Features” para la detección de enfermedades y especificaciones de calidad, pero no resultó eficiente debido a la limitación de datos y la falta de diversidad en el conjunto de imágenes. Sin embargo, obtuvo un alcance de 75% en “accuracy”. Por otro lado, para la precisión de clasificación obtuvo 74,4% SVM Linear y SVM quadratic.

En el estudio (Valenzuela, 2021), se utilizó el conjunto de datos de “PlantVillage” para identificar cuatro enfermedades que afectan a las hojas de tomate. Para llevar a cabo la

detección de imágenes, se empleó la red neuronal “Faster R-CNN” y el “Framework Mask R-CNN” de “Matterport”, específicamente el modelo `mask_rcnn_coco.h5`. Además, el etiquetado de las imágenes se realizó manualmente con una clase de Python. El entrenamiento de la red neuronal se llevó a cabo utilizando el modelo VGG16, lo que permitió obtener resultado de 84% de “accuracy” y 0,42 de “val los”.

En el artículo (Erazo, Uema, 2020), se emplean un modelo RGB para obtener patrones de colimetría, que luego se traducen a un código y se utilizan en una red neuronal capaz de reconocer dos enfermedades. Sin embargo, el “dataset” estaba compuesto por múltiples enfermedades. Para el entrenamiento de la red neuronal se enfocaron en utilizar el lenguaje Python, donde no se encuentra mucho detalle al respecto. Por otro lado, recomiendan utilizar un conjunto de datos que incluya enfermedades más comunes en las plantas de tomate y utilizar una red neuronal que pueda detectar síntomas más complejos. Es importante seleccionar cuidadosamente las características y la arquitectura de la red neuronal para lograr una detección precisa y eficaz de las enfermedades.

CAPÍTULO 3

Metodología de desarrollo

Para el desarrollo de este proyecto se empleó “Team Data Science Process” (TDSP), que es una metodología de la minería de datos que consiste en cinco fases:

- Descripción del proyecto.
- Adquisición y comprensión de los datos.
- Modelo.
- Implementación.
- Aceptación.

La primera fase se describe como la preparación del proyecto, durante la cual se investigaron temas relevantes; como las enfermedades de las rosas, redes neuronales y construcción del “dataset”. Enfocándose en la identificación de la enfermedad más frecuente; que afecta a las rosas. Todas estas investigaciones permiten un conocimiento claro para el desarrollo del proyecto.

Para el segundo paso, se enfocó en recopilar los datos. Se realizó una búsqueda de una plantación de rosas que presenten síntomas de la enfermedad Oídio s.p. Con la ayuda de la Ingeniera Agrónoma Elizabeth Urbano PHD., se identificó las hojas que se encontraban enfermas y sanas, para luego fotografiarlas. Cabe destacar que el Oídio sp se propaga con facilidad causando grandes pérdidas del producto, por lo que existe un gran control semanal mediante el uso de pesticidas, para evitar su propagación. Lo que limita a obtener una gran cantidad de datos.

Una vez que se tomaron las fotos de las hojas, estas se clasificaron en dos grupos: "Sanas" y "Enfermas". Luego, se seleccionaron las imágenes que presentaban ruido, como mala calidad, borrosas o con demasiado brillo, con el objetivo de evitar posibles interferencias durante el entrenamiento de la red neuronal.

Para la fase del modelado, se implementó las redes neuronales convolucionales (CNN), las cuales presentan una facilidad en el procesamiento de datos cuadrículados, como las imágenes empleadas en este proyecto. Tomando en consideración investigaciones previas relacionadas con este estudio, se empleó las librerías “Keras y TensorFlow”; debido a su alto desempeño en redes neuronales.

Se utilizó el modelo pre-entrenado VGG19 para el aprendizaje del sistema. VGG19 es una red neuronal convolucional compuesta por 19 capas, lo que facilita su implementación y uso. Este modelo es ampliamente reconocido en el campo de la clasificación de imágenes y se destaca por su alta precisión y rendimiento. Ha sido entrenado previamente en el conjunto de datos ImageNet, que abarca una amplia variedad de imágenes. Gracias a este entrenamiento exhaustivo, VGG19 ha adquirido un profundo conocimiento de las características y patrones visuales presentes en las imágenes, lo que lo convierte en una herramienta invaluable para la clasificación precisa de imágenes.




Figura 1: Arquitectura VGG19

La arquitectura del modelo VGG19 se compone de un total de 19 capas, que se dividen en 16 capas de convolución y 3 capas completamente conectadas. Las capas convolucionales, ubicadas en la parte inicial del modelo, son responsables de analizar y extraer las características relevantes de las imágenes. Están interconectadas, lo que les permite capturar patrones más complejos a medida que la información fluye a través de ellas. Además, se incorporan capas de “max-pooling” que desempeñan un papel importante en la prevención del sobreajuste al reducir la dimensionalidad de las características extraídas. Finalmente, se encuentra la capa de salida, donde se obtiene la clasificación final de la imagen (Nguyen, 2022).

Para cargar los datos, se utilizó la biblioteca “ImageDataGenerator” de “Keras”, que permite generar conjuntos de imágenes de entrenamiento, prueba y validación. Esta herramienta proporciona flexibilidad al aplicar transformaciones aleatorias como cambios de escala, rotación y zoom. En el primer entrenamiento, se utilizó un conjunto de 125 imágenes, dividiéndolas en un 80% para entrenamiento y un 20% para validación. Se aplicaron técnicas de aumento de datos como el volteo vertical y horizontal, así como zoom, rotación y rango para enriquecer la diversidad de los datos.

Para el primer entrenamiento de prueba se realizó con el modelo VGG19 con 50 épocas, obteniendo los siguientes resultados:




Figura 2: Gráfica de Loss vs Épocas

La gráfica que muestra las curvas de "train" y "test" revela una leve brecha entre ellas, lo cual indica la presencia de un fenómeno conocido como "overfitting" o sobreajuste. Esto sucede cuando el modelo ha aprendido de manera excesiva los datos de entrenamiento, incluyendo el ruido presente en ellos, en lugar de captar patrones más generales de forma adecuada. Este fenómeno provoca un error generalizado en el entrenamiento, lo que impide que el modelo tenga una buena capacidad de predicción.

Además, se calculan varias métricas para evaluar el rendimiento del modelo. El "accuracy" se utiliza para medir la proporción de predicciones correctas en general. La precisión, por su parte, indica la cantidad de predicciones positivas verdaderas realizadas por el modelo. El "recall", en cambio, mide la capacidad de detectar correctamente los resultados positivos verdaderos. Por último, el "F1 score" es una métrica que combina tanto la precisión como el "recall" en una única medida de rendimiento.

Accuracy	0.541
Precision	0.655
Recall	0.655
F1 Score	0.655

Tabla 1: Cálculo de métricas

Posteriormente, con el modelo VGG19 se aumentó la cantidad de épocas a 500 para conseguir una mejora en el entrenamiento y resultado de las métricas. Obteniendo lo siguiente:




Figura 3: Gráfica de Loss vs Épocas

Accuracy	0.572
Precision	0.678
Recall	0.679
F1 Score	0.678

Tabla 2: Cálculo de métricas

Tras realizar 500 épocas de entrenamiento, se evidenció una mejora significativa en las métricas de evaluación, lo que se reflejó en una reducción del error en las predicciones.

Sin embargo, al analizar la gráfica, se pudo observar que persistía el fenómeno de sobreajuste “overfitting”.

Tomando en consideración los resultados, se realizó una investigación de cómo solucionar el fenómeno de “overfitting”. Teniendo como opciones: aumentar la cantidad de datos, usar un modelo con menor profundidad o utilizar una función de EarlyStopping; la cual se utiliza para prevenir el “overfitting”. Esta evita que el modelo tenga un aprendizaje del ruido, interrumpiendo el entrenamiento cuando no genera mejoras.

Tras las investigaciones anteriores, se utilizó VGG16 que es un modelo con menor cantidad de capas y parámetros, y con estudios previos a tenido buenos resultados en predicción de imágenes.




Figura 4: VGG16 Arquitectura

La arquitectura del modelo VGG16 está compuesta por 13 capas convolucionales, encargadas de extraer características de las imágenes. También se incluyen capas de “max-pooling” para disminuir la resolución y capas conectadas para la clasificación. La capa de salida utiliza la función “softmax”, mientras que todas las capas, excepto la de salida, emplean la función “ReLU”. Esta configuración permite al modelo analizar de manera efectiva las imágenes y realizar predicciones precisas (Bobadilla, 2021).

Para el proceso de entrenamiento, se aumentó los datos a un conjunto de 250 imágenes. Además, se utilizó la técnica de aumento de datos, la cual consiste en generar nuevas imágenes a partir de las existentes mediante transformaciones como cambios de escala, rotación y zoom. El objetivo de este aumento de datos es proporcionar al modelo una mayor variedad de ejemplos para entrenar, lo que puede mejorar su capacidad de generalización y prevenir el sobreajuste. El conjunto de imágenes se dividió en dos conjuntos: el 80% se destinó al entrenamiento “train” y el 20% restante se utilizó para la validación (test) del modelo. Se llevó a cabo el entrenamiento utilizando el modelo VGG16 durante 500 épocas, y se obtuvieron los siguientes resultados:




Figura 5: Gráfica de Loss vs Épocas

Accuracy	0.521
Precision	0.52
Recall	0.504
F1 Score	0.512

Tabla 3: Cálculo de métricas

Tras analizar los resultados de la implementación del nuevo modelo con 500 épocas, se pudo observar que las métricas de evaluación no experimentaron mejoras significativas. Además, en la gráfica de rendimiento se evidenció nuevamente la presencia del fenómeno de sobreajuste (overfitting). Tras una investigación exhaustiva para identificar posibles causas, se llegó a la conclusión de que la cantidad de datos utilizados podría ser un factor determinante en este resultado. Se llegó al hallazgo de que el número de épocas de entrenamiento debe aproximarse al número de datos disponibles para obtener un mejor

rendimiento. En consecuencia, se realizó una prueba adicional utilizando el modelo VGG16 con 100 épocas, obteniendo los siguientes resultados:




Figura 6: Figura 7: Gráfica de Loss vs Épocas

Accuracy	0.525
Precision	0.523
Recall	0.536
F1 Score	0.529

Tabla 4: Cálculo de métricas

Considerando los resultados de la implementación de 100 épocas, se observó una pequeña mejora en las métricas de evaluación, lo que se tradujo en un menor porcentaje de error en la predicción. No obstante, en la gráfica se aprecia una disminución del fenómeno de sobreajuste (overfitting), el cual sigue afectando al modelo.

Posteriormente, se aumentó el dataset a 1096 imágenes resultantes, dividiéndolas en un 70% para entrenamiento, un 25% para validación. Asimismo, se aplicó el aumento de datos y se utilizó la función de "earlystop". En cuanto a las métricas, se amplió el uso de la matriz de confusión y se realizó una evaluación del modelo en busca de mejoras en

los resultados. Obteniendo los siguientes resultados, con el modelo VGG16 que presentó mejoras, con 100 épocas:




Figura 8: Gráfica de Loss vs Épocas

Accuracy	0.543
Precision	0.53
Recall	0.512
F1 Score	0.521

Tabla 5: Cálculo de métricas

71	53
57	60

Tabla 6: Matriz de confusión

Además, se aumentaron gráficas para observar el rendimiento de la red neuronal. Se implementó la gráfica de “accuracy” vs épocas, obteniendo los siguientes resultados:




Figura 9: Gráfica de Épocas vs Accuracy

Al aumentar la cantidad de datos utilizados, se pudo apreciar una disminución en la incidencia de sobreajuste en las figuras 8 y 9. Además, los valores de las métricas se mantuvieron estables sin experimentar cambios significativos.

Por otro lado, se utilizó un conjunto de datos compuesto por 634 imágenes, las cuales se dividieron en un 70% para entrenamiento, un 10% para prueba y un 10% para validación. Además, se aplicó un aumento de datos en la función de prueba y se evaluó el modelo para observar su progreso y mejora a lo largo del entrenamiento. Obteniendo los siguientes resultados, con el modelo VGG19 con 20 épocas:




Figura 10: Gráfica de Loss vs Épocas




Figura 11: Gráfica de Épocas vs Accuracy

Accuracy	0.539
Precision	0.525
Recall	0.796
F1 Score	0.633

Tabla 7: Cálculo de métricas

18	46
13	51

Tabla 8: Matriz de confusión

Es importante destacar que en este entrenamiento se realizaron 20 épocas, las cuales se ejecutaron varias veces. Se utilizó la función de "earlystop", la cual detuvo el entrenamiento en la época 5 debido a la falta de mejoras significativas.

En cuanto a la evaluación del modelo, se obtuvo una precisión (accuracy) del 66,41%, lo cual, se acerca a los valores de investigaciones previas realizadas. Sin embargo, al analizar los gráficos, se puede observar la presencia de overfitting, ya que en la figura

10 se aprecia una tendencia ascendente y en la figura 11 se observa una tendencia descendente.

Repositorio de la investigación de este trabajo:

<https://github.com/LeslierDiaz/DeteccionImages.git>

CAPÍTULO 4

Después de llevar a cabo diversas pruebas de análisis de los resultados de las métricas y gráficos obtenidos, se determinó que el modelo VGG19 fue el que mostró los mejores resultados en cuanto valores de las métricas de “accuracy”, “recall”, “precisión”, “f1 score”. Esto se debe a que, al contar con una mayor cantidad de parámetros y una mayor profundidad en su estructura; fue capaz de identificar y capturar de manera más precisa las características específicas de los datos.

Como primera comparación entre todas las pruebas realizadas, tomando en cuenta la división del “dataset” en entrenamiento y validación, se puede afirmar que el mejor escenario se obtuvo con 500 épocas de entrenamiento. En este caso, se observó una reducida incidencia del fenómeno de sobreajuste en las gráficas. Al utilizar 125 imágenes en el entrenamiento, se obtuvo un rango de métricas entre el 57% y el 67%.

Por otro lado, tomando en cuenta el aumento del “dataset” y la separación conjunta entre 80% entrenamiento, 10% prueba y 10% validación, con el modelo de VGG19 y 20 épocas presentó un valor de precisión del modelo de 66,41%; y los resultados de la métrica en un rango de 53% a 79%

Sin embargo, en las gráficas presentes se puede denotar un aumento de “overfitting”, debido a que la gráfica presenta un comportamiento ascendente de “train” y de “test”.

Por otro lado, es importante mencionar que se realizó una prueba con el uso de “StratifiedKFold”, teniendo como objetivo obtener una proporción equilibrada de los datos; debido a que evita las predicciones incorrectas y presenta una evaluación de mayor precisión de rendimiento del modelo. El entrenamiento fue realizado con un total de 1018

imágenes, las cuales fueron divididas por la técnica de “StratifiedKFold” en 691 “train”, 240 “test” y 143 “validation” y un splits de cinco. Obteniendo estos resultados:




Figura 12: Gráficos Épocas vs Loss

En los cinco gráficos se observan comportamientos distintos en cuanto a “train” y “validation”. que lo común en las líneas son un incremento hacia abajo. Además, podemos observar la presencia de overfitting en media cantidad.

En cuanto a las métricas se obtuvo:

Accuracy	0.5274
Precision	0.5354
Recall	0.5196
F1 Score	0.5274

Tabla 9: Métricas de evaluación

Al analizar los resultados de las métricas, se observa que, a pesar de haber utilizado la función “StratifiedKFold” para lograr un equilibrio en la distribución de las imágenes, no se obtuvo un aumento en los valores. Sin embargo, esta estrategia puede contribuir a reducir el margen de error en las predicciones, mejorando así la precisión de los resultados.

CONCLUSIONES

- A lo largo del desarrollo de este proyecto e investigación de varios trabajos relacionados, se puede afirmar que para detección temprana del Oídio sp; se puede aplicar el uso de redes neuronales convolucionales como el modelo VGG19, debido a su preentrenamiento en imágenes, lo que permite tener una mayor precisión en la detección de objetos.
- A través de técnicas de aprendizaje automático y procesamiento de imágenes, el uso de un dataset ha demostrado ser una estrategia efectiva, debido a su extracción de características de las imágenes, las cuales son empleados en un entrenamiento del modelo, el cual es capaz de detectar la enfermedad.
- Es importante destacar que el tamaño del dataset, la adecuada división en conjuntos de entrenamiento y validación, y el uso de técnicas de aumento de datos son aspectos fundamentales para obtener resultados óptimos. La limitación en la disponibilidad de datos se debe a varios factores. En primer lugar, los daños ocasionados por el Oídio en la producción de rosas pueden ser devastadores, lo que conduce a la pérdida total de las plantaciones. Esto dificulta la obtención de un gran número de imágenes para el entrenamiento de modelos de detección de la enfermedad.
- Dadas estas limitaciones, es importante realizar esfuerzos para recopilar y aumentar la cantidad de datos disponibles. Esto puede involucrar la colaboración entre investigadores, productores y entidades relacionadas para obtener imágenes de calidad que representen diferentes casos de Oídio en las rosas. Además, el uso de técnicas de aumento de datos puede ser útil para ampliar el tamaño del conjunto de datos y mejorar la capacidad de generalización de los modelos.

- Para la metodología de este trabajo, se implementó “Team DataScienceProcess” para tener una guía de los procesos adecuados a realizarse en este proyecto.
- Después de realizar las pruebas en este proyecto, se seleccionó el modelo que presentó el mayor valor de predicción y mostró una menor presencia de sobreajuste (overfitting). Esto se hizo con el objetivo de minimizar el porcentaje de error en las predicciones y aumentar la confiabilidad del modelo. Al elegir el modelo con mejores resultados, se busca asegurar una mayor precisión y reducir los posibles errores en las predicciones.
- Mediante la realización de entrenamientos y la adición de datos, se obtuvo como resultado el alcance a la métrica de un 0.66 siendo un valor aceptable considerando las investigaciones previas en las cuales los valores de las métricas alcanzaron un total 0.70.

RECOMENDACIONES Y TRABAJOS FUTUROS

- Es importante destacar que, para obtener mejores resultados en términos de métricas de precisión, se recomienda contar con un dataset que contenga más de 1000 imágenes. Cuantas más imágenes se tengan disponibles para el entrenamiento, es más probable que se logren métricas de precisión más altas.
- Por otro lado, es recomendable utilizar la técnica de “data argumentation” (aumento de datos) para generar un mayor número de muestras sin la necesidad de adquirir nuevas imágenes. Esto permite enriquecer el conjunto de datos y mejorar la capacidad del modelo para generalizar y reconocer patrones en nuevas imágenes.
- Es importante utilizar varias métricas de predicción para observar el comportamiento general de la red neuronal. Además, se sugiere emplear diferentes gráficas, como la curva ROC (Receiver Operating Characteristic) y la precisión o pérdida (accuracy or loss), para evaluar el rendimiento del modelo desde diferentes perspectivas.
- Por lo tanto, para investigaciones futuras, se propone aumentar la cantidad de datos, que tenga mayor calidad en cuanto a diversidad en distintos ambientes. A medida que se incrementa la cantidad de datos, es posible mejorar aún más las métricas del modelo, acercándolas lo más posible al valor óptimo.

- Otro punto para mencionar sería importante realizar investigación y diversas pruebas en la metodología de “shallow learning” para de esta manera ver si existe una mejora las métricas de evaluación.

BIBLIOGRAFÍA

- Anavarionovich,Z., Zafarovich, M. (2021). *Common oidium or un-dew disease in vineyards and measures to combat it.*
- Bobadilla, J. (2021). *Machince Learning y Deep Learning usando Python, Scikit y keras.*
- Calderón., Guerra, V., Gallegos, M., Beltrán, L. (2021). *Competitividad del sector floricultor mediante la estrategia liderazgo en costos.*
- Calderón, A., Hurtado, H. (2021). *Competitividad del sector floricultor mediante la estrategia liderazgo en costos.*
- Cedillo, C., Gonzáles, C., Salcedo,V., Sotomayor, J. (2021). *El sector florícola del Ecuador y su aporte a la Balanza Comercial Agropecuaria: período 2009 – 2020.*
- Espín, L. (2021). *Sistema inteligente de aprendizaje automático mediante el uso de un vehículo aéreo no tripulado(UVA) para el monitoreo de Oidium(sphaerotheca pannosa) en el cultivo de rosas de exportacion en el Ecuador.*
- Guamán, A. (2023). *Evaluación de tres combinaciones de cuatro tipos de fungicidas para el control de Podosphaera pannosa en la variedad de rosa STAR 2000.*
- Nagaveni, Raghavendra. (2019). *A Review on Machine Learning Classification Techniques for Plant Disease Detection," 5th International Conference on Advanced Computing & Communication Systems (ICACCS), Coimbatore, India, pp. 281-284.*

- Nguyen, T. (2022). *A VGG-19 Model with Transfer Learning and Image Segmentation for Classification of Tomato Leaf Disease.* .
- Saldañas, M., Vera, K. (2019). *Diagnóstico de plagas y enfermedades presentes en las plantas de la zona urbana de la ciudad de Cuenca.* .
- Valenzuela, S. (2021). *Detección y Clasificación de Enfermedades en el Tomate Mediante Deep Learning y Computer Visión.* .