

Comparación de redes neuronales convolucionales (RNC) para la detección de plagas en el cultivo del durazno en departamento Norte de Santander, Colombia

Comparison of convolutional neural networks (CNN) for pest recognition in peach crops in Norte de Santander, Colombia

Andres Castellano-Corzo¹
Luis David Lara-Rodriguez²
Elizabeth López-Mélendez³

¹Servicio Nacional de Aprendizaje SENA (Colombia). Correo electrónico: acastellanos05@misena.edu.co
orcid: <https://orcid.org/0000-0001-9700-390X>

²Universidad Politécnica de Puebla (México). Correo electrónico: luis.lara406@uppuebla.edu.mx
orcid: <https://orcid.org/0000-0002-1241-3289>

³Universidad Tecnológica de Huejotzingo (México). Correo electrónico: elizabeth.lopez@uth.edu.mx
orcid: <https://orcid.org/0009-0003-6363-0683>

Recibido: 07-08-2023 Aceptado: 01-11-2023

Cómo citar: Castellano-Corzo Andres; Lara-Rodriguez, Luis; López-Mélendez, Elizabeth (2023). Comparación de redes neuronales convolucionales (RNC) para la detección de plagas en el cultivo del durazno en departamento Norte de Santander, Colombia. *Informador Técnico*, 87(2),150-164.
<https://doi.org/10.23850/22565035.5805>

Resumen

La agricultura de precisión, con el propósito de acrecentar los rendimientos de los cultivos y proteger el medio ambiente circundante, emplea productos destinados a su protección. Dicha medida busca prevenir la aparición de plagas y enfermedades que causan pérdidas económicas o complicaciones de naturaleza cuaternaria, lo que tendría un impacto aún más significativo en la comercialización y producción agrícola. Por este motivo, ha surgido la necesidad de desarrollar herramientas tecnológicas para la detección temprana y el control preventivo, que permitan un manejo de las distintas plagas y enfermedades que afectan dichos cultivos. El aprendizaje automático se ha convertido en una herramienta clave, que brinda soluciones analíticas y computacionales para la detección y/o clasificación de plagas. En este estudio se presenta la propuesta de dos diferentes arquitecturas de redes neuronales convolucionales (RNC), con ayuda del aumento de datos, que posibilita — con un 87 % de precisión — la detección de la severidad de las lesiones provocadas por Roya y Torque en la hoja del durazno. El conjunto de imágenes se obtiene con un dispositivo móvil con cámaras fotográficas de alta resolución, en el municipio de Chitagá, al Norte de Santander.

Palabras clave: aprendizaje profundo; durazno; redes neuronales convolucionales; roya; torque.

Abstract

Precision agriculture aimed to increase crop yields while protecting the surrounding environment, uses products for crop protection. This measure seeks to prevent the growth of pests and diseases that cause economic losses or complications of a quaternary nature, which would have an even more significant impact on marketing and agricultural production, which is why the need has arisen to develop technological tools for early detection and preventive control to manage the different pests and diseases that affect these crops. Machine learning has become a key tool to provide analytical and computational solutions for the detection and/or classification of pests. In this study, we present the proposal of two different convolutional neural network (CNN) architectures with the help of data augmentation, allowing us 87 % accuracy in detecting the severity of lesions caused by Peach leaf curl fungus (Torque) and Rust on peach leaves. The set of images is obtained with a mobile device with high-resolution cameras in the municipality of Chitagá in Norte de Santander.

Keywords: convolutional neural network; deep learning; peaches; rust fungus; Peach leaf curl fungus

1. Introducción

El cultivo del durazno (*Prunus pérsica* L.) ha ido ganando terreno gradualmente, hasta el punto en el que su comercialización está saturada (Camargo, 2023). De acuerdo con las cifras registradas por Agronet, la Red de Información y Comunicación del Sector Agropecuario de Colombia, liderada por el Ministerio de Agricultura y Desarrollo Rural, en 2022 la producción de este fruto llegó a las 31.307 toneladas. Así mismo, indica que, aparte de Boyacá, los departamentos con mayor producción de este fruto en el país son Norte de Santander, que cosecha alrededor de 12.544,40 toneladas, que constituyen el 40 % de la producción nacional, seguido de Huila, que logra producir cerca de 977,50 toneladas de duraznos al año, correspondientes al 3 % de la producción nacional, números que muestran el potencial de este producto en diferentes regiones del país, caracterizadas por cambios climáticos continuos (Agronet, 2023).

La Industria 4.0 se caracteriza por fusionar diferentes tecnologías de diversas áreas. Actualmente, el aprendizaje automático forma parte de ello, y se ha aplicado a la agricultura, en donde se recopilan y analizan datos en campo, donde se obtienen los factores necesarios para mejorar la cosecha. Para lograr este propósito, es posible usar diversas tecnologías, como drones, aplicaciones móviles, sensores y actuadores (Apolo-Apolo *et al.*, 2021). Algunas de las técnicas de aprendizaje autónomo utilizadas incluyen clasificación de imágenes, entre ellas, los algoritmos de aprendizaje autónomo que se entrenan utilizando imágenes de duraznos sanos y afectados por plagas o enfermedades, con el propósito de clasificar nuevas imágenes y determinar si hay algún indicio de daño. La detección temprana de plagas y enfermedades en el cultivo de durazno, a través del aprendizaje autónomo, puede contribuir a reducir el uso de pesticidas, optimizar los recursos y mejorar la productividad de los cultivos (Alosaimi *et al.*, 2021; Shruthi *et al.*, 2019; Apolo-Apolo *et al.*, 2019). El aprendizaje autónomo puede ser aplicado para la detección temprana de plagas y enfermedades en calidad de asistente, de esta manera los agricultores pueden tomar medidas rápidas y precisas para prevenir o controlar los problemas anteriormente mencionados.

Los principios de agricultura de precisión se han aplicado en el cultivo de durazno, uno de ellos es el aprendizaje autónomo para buscar que el manejo agronómico sea lo más específico posible, es decir, a nivel de cada lote, realizando el procedimiento de toma de registros de forma manual, tanto para incidencias (plagas y enfermedades) como para severidad (pérdida económica) (Ríos, 2021). De este modo, la inteligencia artificial usa técnicas para estimar las características visuales de diferentes hojas y tallos de las plantas a través del procesamiento de imágenes, donde los resultados demuestran ser de gran ayuda en el manejo de incidencias en diferentes cultivos agrícolas, tomando en cuenta una correcta manipulación y depuración de los datos a utilizar (Gomez *et al.*, 2020). También, se han establecido diferentes variables que intervienen en las enfermedades de

las plantas y cómo han sido tratadas, con técnicas de inteligencia artificial, donde se determinó que el tipo de suelo, clima, temperatura y humedad son algunas de las variables más importantes en el sector agropecuario (Torres-Sánchez *et al.*, 2023; Apolo-Apolo *et al.*, 2020).

De acuerdo con Apolo-Apolo *et al.* (2020) se analizaron características de la Roya Amarilla (plaga) y su influencia en el trigo, con base en imágenes hiperespectrales de barrido multitemporal. Además, se utilizó un modelo de regresión para predecir la severidad de la Roya Amarilla con éxito. Por otro lado, se clasificaron los cítricos usando imágenes hiperespectrales, debido a la importancia de la clasificación de la información y la depuración de esta, que puede ser utilizada a gran escala en procesos de predicción cada vez más acertados. La aplicación de técnicas de procesamiento de imágenes y algoritmos de aprendizaje autónomo en la detección y el reconocimiento de enfermedades y plagas en los cultivos es un área activa de investigación, que muestra un gran potencial de estudio (Camacho *et al.*, 2016). El uso del aprendizaje automático en la detección de plagas y enfermedades del cultivo de durazno representa una revolución en la agricultura de precisión: al aprovechar el poder de los algoritmos de aprendizaje profundo, los agricultores pueden detectar y combatir de manera más efectiva las amenazas que afectan la salud y la productividad de sus cultivos. Esta tecnología promete impulsar la sostenibilidad y la rentabilidad de la industria frutícola, al tiempo que garantiza una mayor seguridad alimentaria para las comunidades en todo el mundo (Solano; Caballero, 2022).

Actualmente, existen varios métodos del aprendizaje automático utilizados para la detección de plagas y enfermedades, entre los que se encuentran los difusos (Sampathkumar; Rajeswari, 2022), agrupación de k-means (Anand *et al.*, 2016; Prakash *et al.*, 2017), árbol de decisión (Mengistu *et al.*, 2018) y redes bayesianas (Pérez-Ariza *et al.*, 2012), visión artificial (García *et al.*, 2020; Negrete, 2018), cadenas de Márkov (Gibson, 1997), sistema de inferencia borrosa (Lozada-Portilla *et al.*, 2021) y red neuronal convolucional profunda (Ahmed; Yadav, 2023; Trivedi *et al.*, 2020; Kaya; Gürsoy, 2023; Zhang *et al.*, 2019).

Un concepto clave para el manejo de pestes es el promovido por la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO, por sus siglas en inglés), que se denomina “manejo integrado de plagas” (IPM, por sus siglas en inglés) (Pernía; Sanabría, 2021). El IPM es un sistema que utiliza diversas técnicas y métodos posibles (control químico, control cultural, regulación biológica o control microbiológico). En este caso, aplicamos el control cultural como base que determina la trazabilidad de un cultivo con miras a futuras decisiones y disminución del daño económico para mantener la población de plagas por debajo de los niveles que puedan causar pérdidas económicas. Existen dos elementos claves para el manejo integrado de pestes: el primero se orienta a la realización de muestreos para monitorear el nivel de diseminación de la plaga, y el segundo se orienta a la definición del umbral de población por encima del cual la productividad del cultivo se afecta de manera sustancial (Martínez *et al.*, 2020).

El objetivo de este trabajo es aplicar principios de agricultura de precisión en el cultivo de durazno, como aprendizaje autónomo, para buscar que el manejo agronómico sea mucho mejor, utilizando (Pernía; Sanabria, 2021) redes neuronales convolucionales para la clasificación de dichas plagas.

2. Marco teórico

2.1. Redes neuronales convolucionales

El aprendizaje profundo permite que los modelos computacionales, que se componen de múltiples capas de procesamiento, aprendan representaciones de datos con múltiples niveles de abstracción. Además, descubre estructuras intrincadas en grandes conjuntos de datos mediante el uso del algoritmo de retropropagación, para indicar cómo una máquina debe cambiar sus parámetros internos que se utilizan para calcular la representación en cada capa a partir de la representación en la capa anterior. Las redes convolucionales profundas han generado avances en el procesamiento de imágenes, video, voz y audio, mientras que las redes recurrentes han arrojado luz sobre datos secuenciales como texto y voz (Bengio, 2009).

Las redes neuronales convolucionales (RNC) son una aplicación proveniente del aprendizaje profundo, la cual nos permite clasificar y extraer características en imágenes, apuntando a mejores resultados que otro tipo de redes neuronales, ya que son muy efectivas porque fueron diseñadas con el fin de imitar la actividad de la corteza visual (parte del cerebro humano que procesa la información visual), por lo que son capaces de extraer y aprender las características de las imágenes de entrada por sí mismas mediante la configuración adecuada de sus capas (Deng; Dong, 2014).

Las RNC son un tipo de red neuronal donde se aplica la convolución en sus capas iniciales. Este tipo de redes tienen diferentes capas, como se observa en la Figura 1, las cuales permiten un aprendizaje automático de las características de las imágenes. La imagen de entrada es convolucionada con una gama de filtros que producen características propias para utilizarse por las capas posteriores de la red e iniciar la etapa de clasificación (Gupta *et al.*, 2022).

El detector de características dentro de una RNC es la entrada a una capa convolucional, cuyos datos aún no han sido procesados, creando una salida que corresponde a un mapa de características que se utilizan como la entrada a la siguiente capa convolucional. La convolución se toma como la aplicación de un filtro en los datos de entrada para un tipo de información específica, esto sirve para examinar la posición de un objeto y las características propias de la imagen, como lo son bordes, texturas y rotaciones (González *et al.*, 2019).

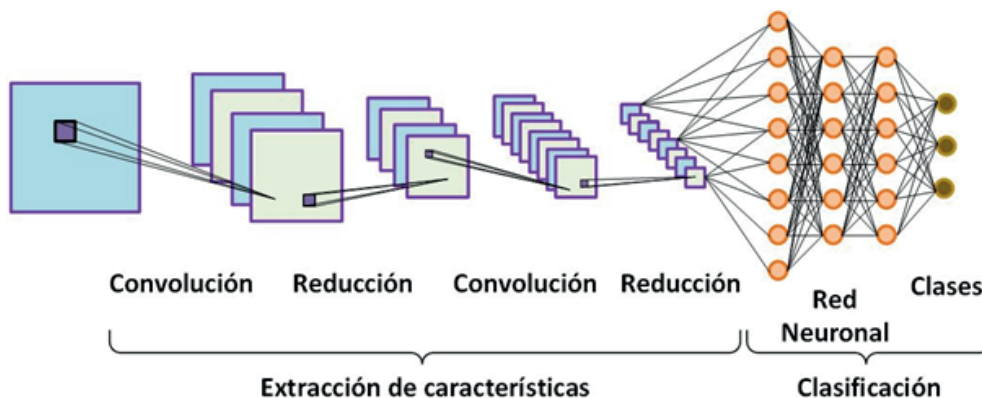


Figura 1. Arquitectura de una RNC
Fuente: elaboración propia.

La convolución discreta en dos dimensiones se define en la Ecuación 1.

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n)K(i - m, j - n) \quad (1)$$

Donde la entrada corresponde a una imagen I , el núcleo de convolución K en cada píxel en la posición (i, j) , y da un mapa de característica de la imagen como salida S .

Se tiene la capa convolucional donde se encuentra la función de activación, la cual ayuda a resaltar los bordes que conformarán las características de cada clase. Estas mismas son las que modifican el valor de salida de las neuronas que conforman las capas de las redes neuronales profundas, estableciendo un valor límite, el cual no debe rebasar antes de propagarse a la siguiente capa. En la Figura 2 se muestran las funciones de activación más comunes, la más utilizada dentro de estas redes es la unidad lineal rectificadora (ReLU), si la entrada está por debajo de 0, la salida es 0 (Ghimire *et al.*, 2022).

Dentro de la fase de extracción de características, se utiliza una capa llamada reducción (*Pooling*), que se ubica entre las capas convolucionales para reducir progresivamente el tamaño espacial de los datos, para controlar el sobreajuste, la operación más utilizada es el *Max pooling*, la cual consiste en agrupar un vecindario y que la salida tome el valor máximo del píxel dentro del vecindario de n vecindad. Otra función de agrupación es el *Average pooling*, donde se incluye un promedio del vecindario anteriormente mencionado.

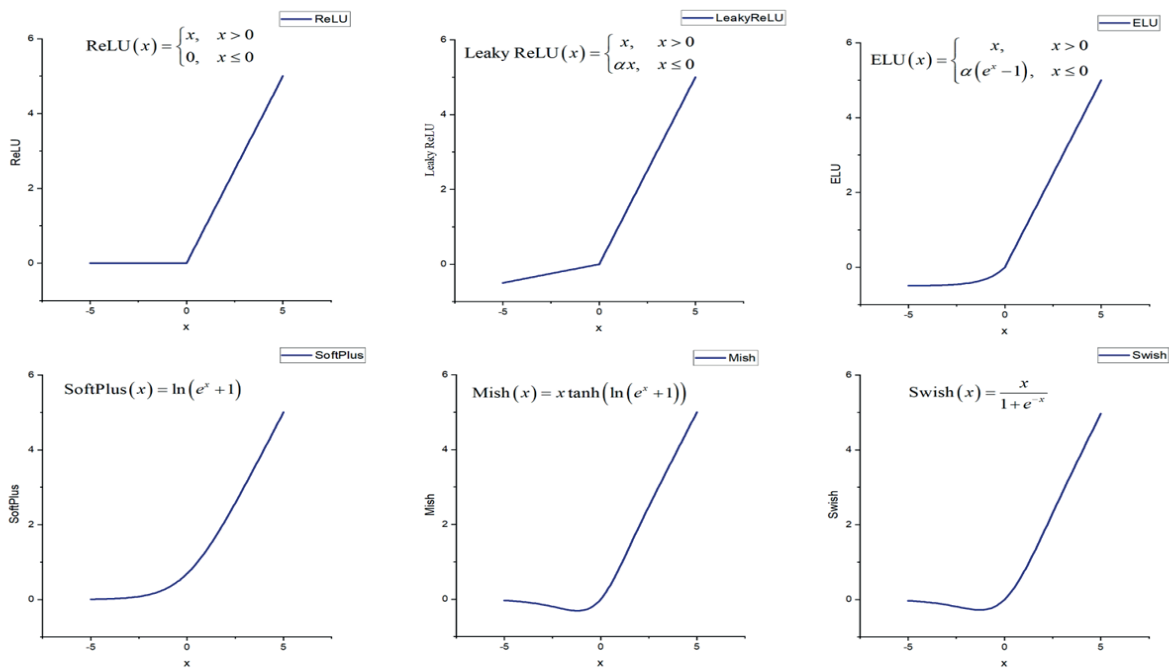


Figura 2. Algunas funciones de activación utilizadas en una red neural profunda
Fuente: elaboración propia.

En la fase de clasificación, las neuronas de la capa están conectadas con cada neurona de la capa anterior, el cálculo se muestra en Ecuación 2:

$$f(x) = \sigma(W * x) \quad (2)$$

Donde F es la salida de las unidades, $W \in \mathfrak{R}$ son los pesos de la red y $\sigma: \mathfrak{R} \rightarrow \mathfrak{R}$ es la función de activación de la red.

Dentro de la capa final se utiliza un algoritmo de retropropagación para aumentar el rendimiento de la red, para esto se utiliza comúnmente la función *Softmax*, la cual se presenta en la Ecuación 3.

$$S(x)_j = \frac{x^{x_i}}{\sum_{i=0}^N e^{x_i}} \quad (3)$$

Donde $S(x): \mathfrak{R} \rightarrow [0,1]$ de cardinalidad N del vector de entrada a la función, recordando que la capa de salida de una RNC tiene un tamaño igual al número de clases.

Estas redes aplican métodos para minimizar la función de pérdida con respecto a los parámetros de la función de predicción, dependiendo del modelo propuesto, algunos de estos métodos son: Adam, gradiente descendiente, propagación de raíz cuadrática media, entre otros. Estas funciones comparan el valor de salida de la red neuronal contra el valor de salida real para determinar la clasificación incorrecta de los datos de entrada, entre ellas tenemos al error cuadrático medio (MSE), pérdida de entropía cruzada, bisagra perdida, entre otras. Esto se logra ajustando los hiperparámetros que mejoran su rendimiento, como número de capas y neuronas, magnitud, regularización (medida contra el sobreajuste), estrategias de inicialización de pesos, definir número de épocas y normalización de datos de entrada (Krizhevsky *et al.*, 2012).

2.2. Aumento de datos

La técnica de aumento de datos (*Data augmentation*), perteneciente al aprendizaje automático, es un procedimiento que aumenta artificialmente los datos basados en la información original, realizando transformaciones geométricas sobre las imágenes originales.

Las transformaciones geométricas en una imagen son operaciones espaciales que modifican la disposición espacial de sus píxeles. Estas transformaciones pueden ser agrandar o reducir la imagen, dependiendo de lo que se busque realizar, y consisten en dos operaciones básicas: transformación espacial de coordenadas (Ecuación 4) y la interpolación de intensidad, que asigna un valor de intensidad a los píxeles transformados espacialmente (Woods; Gonzalez, 2018).

$$\begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = T \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ 0 & 0 & 1 \end{bmatrix} \quad (4)$$

Las transformaciones de rotación, reflexión, escalamiento y traslación dependerán de los valores que se escogen para la matriz T. Para poder calcular diversas transformaciones en la misma imagen, simplemente las matrices se multiplican en el orden asignado. En la Tabla 1 se presenta la matriz T, correspondiente a la operación designada.

Tabla 1. Matrices de transformaciones geométricas espaciales

T	T	T
Escala/Reflexión, $= \begin{bmatrix} c_x & 0 & 0 \\ 0 & c_y & 0 \\ 0 & 0 & 1 \end{bmatrix}$	Rotación, $= \begin{bmatrix} \cos \theta & -\sin \theta & 0 \\ \sin \theta & \cos \theta & 0 \\ 0 & 0 & 1 \end{bmatrix}$	Traslación, $= \begin{bmatrix} 1 & 0 & t_x \\ 0 & 1 & t_y \\ 0 & 0 & 1 \end{bmatrix}$

Fuente: Woods y Gonzalez (2018).

En la Figura 3 se muestran las transformaciones geométricas espaciales más comunes sobre una imagen con diferentes ángulos, desplazamientos y reflexiones, correspondientes a las matrices presentadas en la Tabla 1.



Figura 3. Transformaciones geométricas espaciales en una imagen

Nota. a) Original, b) rotación, c) reflexión horizontal, d) reflexión vertical, e) escalamiento, f) desplazamiento vertical, g) desplazamiento horizontal y h) múltiples operaciones espaciales.

Fuente: Mosaico elaboración propia.

3. Metodología

La recolección de las imágenes de durazno se realizó en las fincas La Fabiola, El Veranito, La Dorada, La Esperanza, La Esmeralda de las Veredas Carrillo y Llano Grande del municipio de Chitagá, Norte de Santander, en cultivos que corresponden a un terreno que se encuentra situado en la cordillera oriental sobre gigantescas arrugas, con terreno quebrado. Se considera que Chitagá tiene un suelo excepcional, ya que es rico en minerales. Además, el comportamiento de la temperatura durante el año es heterogéneo, debido a las variaciones altitudinales del municipio, el cual cuenta con áreas en los tres pisos térmicos (páramo, frío, templado). En sectores muy pequeños, en el piso térmico cálido, la humedad relativa en la zona varía de 75 % a 85 % durante el año, lo que puede ser beneficioso o perjudicial, dependiendo de los cultivos (Villamizar, 2014).

Dichas imágenes se obtuvieron en el espectro visible con modelo de color RGB, con cámaras de dispositivos móviles de alta resolución (4 cámaras principales: 108 MP, $f/1,9$, angular: 8 MP, $f/2,2$, 112 °, profundidad: 2 MP, $f/2,4$, macro: 2 MP, $f/2,4$), con dos tomas por cultivo en jornadas de 8 horas; esta actividad se realizó en varias sesiones, y cabe resaltar que las condiciones climáticas en la zona no afectaron la toma de imágenes, debido a que la luminosidad que se presenta no causa desenfoque, ni sombras o saturaciones, además de que las condiciones de las capturas fueran las mismas para todas las imágenes sin enfoque selectivo o profundidad de campo. Las imágenes tienen una resolución (2340 x 1080 píxeles), capturadas con la ayuda de tripié, que facilitó la toma.

La severidad de la afección se obtuvo dividiendo la hoja de durazno en cuatro secciones y, con ayuda de un agrónomo, se determinó la superficie de cubrimiento de la lesión, adquiriendo de 55 a 70 imágenes por categoría de severidad con las plagas Torque (*Taphrina deformans*) y Roya (*Puccinia graminis*). Cada afección se dividió en 4 categorías, cuyos rangos de porcentaje oscilaron entre: 0-25 %, 26-50 %, 51-75 % y 76-100 %. Estos porcentajes fueron similares a los cuartiles de los diagramas de caja.

Una vez las imágenes fueron obtenidas con ayuda de la técnica de aumento de datos, se buscó balancear las clases, lo cual se logró con la técnica alcanzar 150 imágenes por categoría, para un total de 1.200 imágenes entre todas las categorías. La técnica aplicada de aumento de datos requiere, en su primera etapa, definir intervalos para ciertas operaciones geométricas espaciales aplicadas al conjunto original de imágenes. De esta manera, se dividieron los rangos de cada variable de respuesta de la siguiente manera: rotación de 0 a 45°, escalamiento de 0,95 a 1,05, además de aplicar reflexiones horizontales y verticales. La segunda y última etapa de este método requiere generar, con base en una distribución uniforme, un valor r contenido de los rangos mencionados para las operaciones geométricas espaciales que así lo necesitan y una aleatoriedad binomial en las operaciones de reflexión.

De la resolución original de las imágenes que se han tomado con ayuda del tripié, que permite estabilizar la toma, se ha hecho un recorte a un cuarto (585 x 270 píxeles), centrada en la hoja del plantío. Además, se han descartado todas las imágenes que se han movido por diversas razones, o en las que se presentaron condiciones de luminosidad no favorables. En ambas arquitecturas de las imágenes de entrada, se hace uso de la interpolación bicúbica para reescalarlas a un tamaño de 300 píxeles, el cual es ligeramente superior a la media de la resolución para este tipo de modelos.

Las arquitecturas secuenciales propuestas de los modelos de RNC, aplicadas al conjunto de imágenes de entrenamiento y validación, se ilustra en las Figuras 4 y 5, en donde se observan las etapas de extracción de características y clasificación

En la primera arquitectura, la etapa de extracción de características está conformada por dos filtros de convolución bidimensionales de 32 y 64 filtros con función de activación ReLU, una etapa de reducción a la mitad de su tamaño, aplicando la técnica de *Max pooling*, finalizando con una capa de convolución de 2D con 128

filtros, y una de reducción con características iguales a las anteriores. En la segunda arquitectura, denominada etapa de clasificación, se encuentra una red neuronal artificial (RNA) perceptrón multicapa, con un par de capas en serie de 250 neuronas con activación ReLU y una capa de categorización de salida tipo *Softmax*.

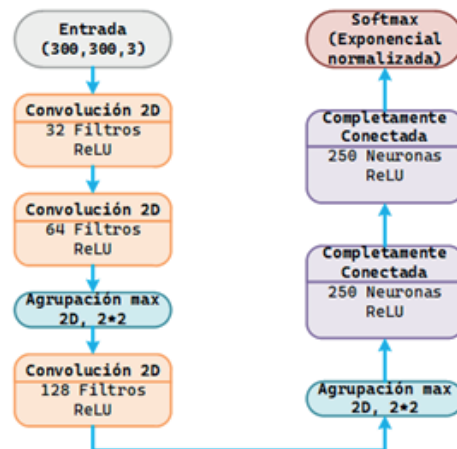


Figura 4. Arquitectura de la RNC del primer modelo
Fuente: elaboración propia.

Para mejorar la extracción de características en la segunda arquitectura, se utilizaron dos filtros de convolución bidimensionales de 512 filtros con función de activación ReLU. Para la reducción, se utilizaron las técnicas de *Max pooling* y *Average pooling* entre capas, finalizando esta etapa con una capa de convolución de 2D con 512 filtros y la reducción mencionada anteriormente. La etapa de clasificación, de igual manera que la anterior, es una RNA perceptrón multicapa. Sin embargo, esta cuenta con tres capas en serie de 4.096 y 2.048 neuronas con activación ReLU, respectivamente, además de una capa de categorización de salida tipo *Softmax*. Para evitar el sobreajuste y mejorar el entrenamiento de ambas redes en sus capas ocultas, se hace uso del mecanismo conocido como *Dropout*, que impulsa la desactivación aleatoria de neuronas con sinapsis débiles que no contribuyen en el aprendizaje (Poernomo; Kang, 2018). Se hizo uso del método adaptativo de aprendizaje *Adagrad*, que se caracteriza por ajustar la tasa de aprendizaje a los hiperparámetros de la red (Saad; Adnan, 2021; Fang *et al.*, 2020).

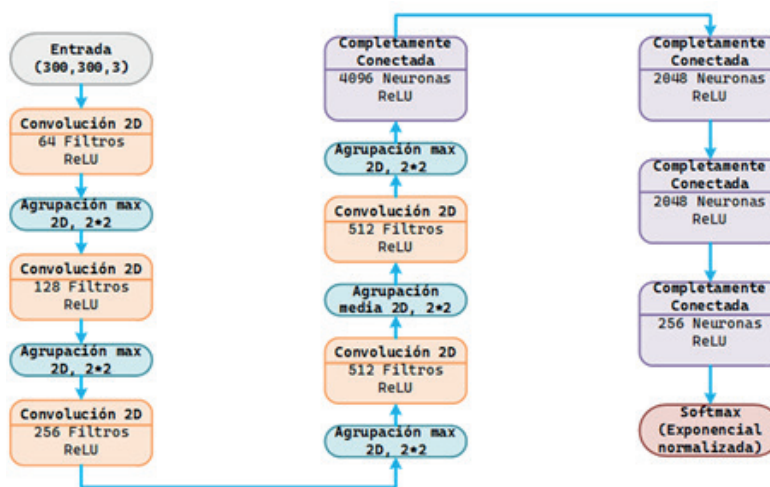


Figura 5. Arquitectura de la RNC del segundo modelo
Fuente: elaboración propia.

Al tener las categorías balanceadas, estas se dividieron en dos subconjuntos de entrenamiento (80 %) y validación (20 %) para alimentar al par de arquitecturas de RNC propuestas en esta investigación. Dado que las arquitecturas de las RNC propuestas tienden a ajustar una cuantiosa cantidad de parámetros con la resolución original del conjunto de imágenes categorizadas, se reescalaron estas últimas a 300 píxeles de lado, para que se ajusten en el proceso de entrenamiento aproximadamente una centena de millón de parámetros, y se puedan calcular con GPU en unas cuantas horas. Las características de cada imagen son captadas de forma similar a las células de la corteza visual. Este conjunto de características extraídas funge como entrada a la etapa constituida por la red neuronal profunda para que sean categorizadas.

Con el propósito de conocer el desempeño de estas arquitecturas, se realizaron pruebas de porcentaje de precisión en el conjunto de validación, aunado con gráficas de aprendizaje y una matriz de confusión en cada modelo.

4. Resultados y discusión

En la Figura 6 se observa una muestra de cada una de las 8 categorías conformadas por las afecciones de Roya y Torque con diferente cuartil de severidad. Las arquitecturas secuenciales propuestas de los modelos de RNC se implementaron utilizando *TensorFlow*, la cual es una librería de aprendizaje automático de código abierto, desarrollada por Google, que permite la construcción y entrenamiento de redes neuronales para la detección de patrones similares al razonamiento humano (Abadi *et al.*, 2016).




Figura 6. Enfermedades de roya y torque por grado de severidad en la hoja de durazno.

Nota. a) Roya 0-25 %, b) Roya 26-50 %, c) Roya 51-75 %, d) Roya 76-100 %, e) Torque 0-25 %, f) Torque 26-50 %, g) Torque 51-75 % y h) Torque 76-100 %

Fuente: elaboración propia.

La primera arquitectura alcanzó un 78 % de precisión en los datos de validación, constituida en dos etapas combinadas entre filtros de convolución bidimensionales y agrupación máxima, que permiten al modelo obtener sus características de las imágenes de entrada, seguidas de dos capas densas de 250 neuronas, cada una para su aprendizaje. Tras el resultado de precisión alcanzado por el primer modelo, se hace una evolución de este al aumentar las etapas combinadas entre los filtros de convolución y las reducciones de dimensionalidad que, al realizarse en cada etapa, en potencia de dos, permite el aumento en la cardinalidad de los filtros convolucionales en mismo factor, con el propósito de una mejor extracción de características en las imágenes. Con el aumento de características se propone una red neuronal profunda de mayor complejidad con el doble de capas y un aumento significativo en el número de neuronas de cada capa que el modelo original, lo que resulta en una mejora del 9 % en la precisión del segundo modelo con respecto al primero.

En la Figura 7 se presentan las curvas de precisión y pérdidas de los modelos, se nota que la primera arquitectura alcanza la mejor tasa de aprendizaje alrededor de las 150 épocas, posteriormente no presenta

un decaimiento de su aprendizaje, pero deja aprender, esto es observable en la intersección entre las curvas de entrenamiento y validación. Subsiguiente a las 150 épocas, la curva de validación permanece constante y la de entrenamiento sigue monótonamente creciente, esto mismo se ve reflejado en la curva de pérdida, en cuyo valor cercano a las 150 épocas, la curva de entrenamiento es monótonamente decreciente y la curva de validación presenta un aumento de pérdida de forma lineal. En las curvas de aprendizaje y pérdida de la segunda arquitectura se observa una mejora en la tasa de aprendizaje (87 %) con respecto a la primera y un desplazamiento en la inflexión de aprendizaje y pérdida posterior a las 220 épocas.

La precisión alcanzada por el segundo modelo del 87 % de ambos padecimientos con diferentes severidades en las hojas de duraznos es consistente con el 84 % que reportan Esgario *et al.* (2020), quienes realizan una clasificación de cinco enfermedades que atacan a la hoja del café; el 85 % obtenido por Dawod y Dobre (2022) para la roya en la hoja de girasol, e igual porcentaje de precisión de nuestro segundo modelo con Agarwal *et al.* (2020) en la hoja de tomate.

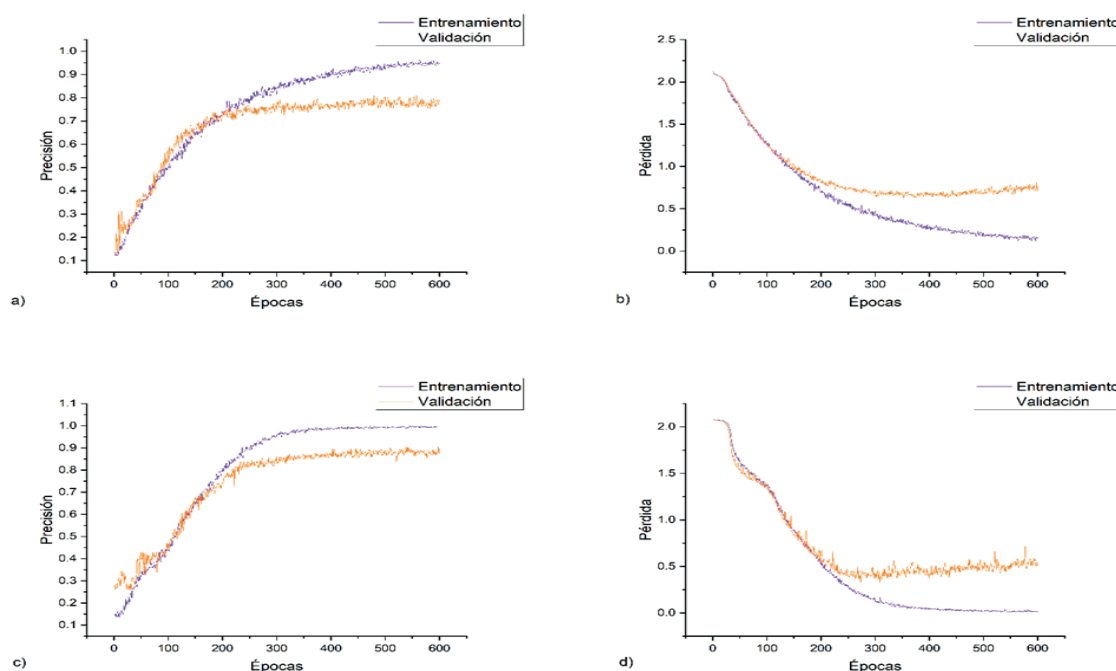


Figura 7. Curvas de entrenamiento y validación del modelo

Nota. a) Primera arquitectura precisión, b) primera arquitectura pérdida, c) segunda arquitectura precisión, y d) segunda arquitectura pérdida.

Fuente: elaboración propia.

La matriz de confusión (matriz de aciertos) es una herramienta novedosa y sencilla de visualización del desempeño de un algoritmo de supervisado (Pereira *et al.*, 2018), donde cada renglón de la matriz representa a las instancias en la clase real (experta), y las columnas el número de predicciones de cada clase (Hardin; Shumway, 1997).

En la Figura 8 se presentan las matrices de confusión obtenidas de ambos modelos. En el primero se observa que 5 categorías están por arriba de la precisión que el modelo arroja, pues se observa que la Roya oscila entre 0-25 y 26-50, y el Torque entre 26 y 50, es decir, que presentan un peor desempeño en autoidentificación y confusión con otras clases. Esto se mejora con el segundo modelo, en el cual el autoidentificarse está por encima en todas las categorías del rendimiento del anterior modelo. La variabilidad entre categorías se concentra en las clases del Torque 0-25 con el de 51-75, al mismo tiempo que la Roya 0-25, que presenta ligeras confusiones con Roya 26-50 y 51-75.

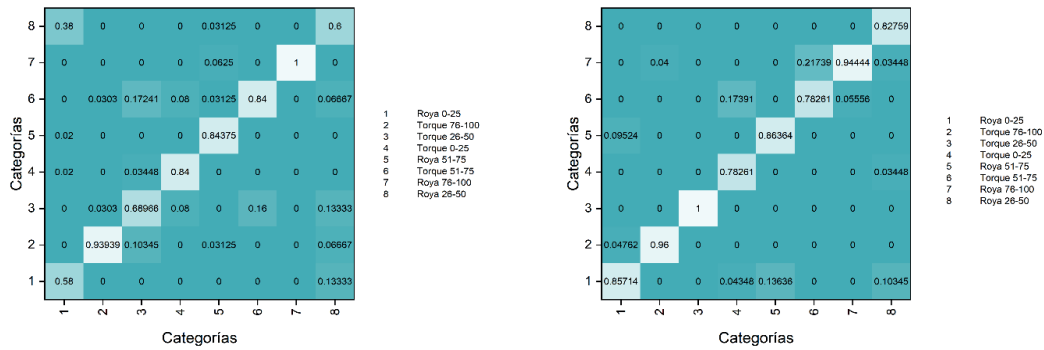


Figura 8. Matrices de confusión
 Nota. Derecha: primer modelo, izquierda: segundo modelo.
 Fuente: elaboración propia.

5. Conclusiones

La detección de plagas y enfermedades en etapas tempranas aumenta la productividad agrícola y sus ganancias operativas, debido a que se combate anticipadamente su crecimiento y floración defectuosa del plantío, lo que trae beneficios económicos al agricultor, al preservar sus recursos naturales y evitar el uso innecesario de fertilizantes. La detección que se logra con el segundo modelo propuesto de Torque y Roya en el cultivo del durazno representa un avance significativo en este campo, nuestra propuesta busca la categorización de ambas enfermedades presentes en la hoja de durazno, con un grado de severidad en ellas.

Los resultados en el primer modelo tienen un nivel de precisión en detección de enfermedades en el cultivo del durazno con un 78 % de validación, y el segundo con un 87 % de precisión de validación. Estos porcentajes de precisión son alcanzados con ayuda de la técnica de aumento de datos y el balanceo de cardinalidad entre clases. Es claro que la mejora en precisión del segundo modelo al primer modelo reside en las etapas de extracción de características y clasificación de más que posee el segundo modelo, a diferencia del primero, ya que le concede mayor robustez.

El siguiente paso en nuestra investigación es aplicar la técnica de transferencia de conocimiento o aprendizaje, que es especialmente útil cuando se tiene un conjunto de datos pequeños y se desea mejorar su rendimiento en precisión en la detección de enfermedades en la hoja de durazno.

Referencias

Abadi, Martín; Agarwal, Ashish; Barham, Paul; Brevdo, Eugene; Chen, Zhifeng; Citro, Craig; Corrado, Greg; David, Andy; Dean, Jeffrey; Devin, Matthieu; Ghemawat, Sanjay; Goodfellow, Ian; Harp, Andrew; Irving, Geoffrey; Isard, Michael; Jia, Yangqing; Jozefowicz, Rafal; Kiser, Lukasz; Kudlur, Manjunath; ... Zheng, Xiaoqiang (2016). *Tensorflow: Large-scale machine learning on heterogeneous distributed systems*. *arXiv preprint arXiv:1603.04467* [Librería de código].
<https://doi.org/10.48550/arXiv.1603.04467>

Agarwal, Mohit; Singh, Abhishek; Arjaria, Siddhartha; Sinha, Amit; Gupta, Suneet (2020). ToLeD: Tomato Leaf Disease Detection using Convolution Neural Network. *Procedia Computer Science*, 167, 293-301.
<https://doi.org/10.1016/j.procs.2020.03.225>

- Agronet (2023). Conozca cómo funciona el negocio del durazno en el mercado colombiano. <https://www.agronet.gov.co/estadistica/Paginas/home.aspx?cod=1>
- Ahmed, Imtiaz; Yadav, Pramod (2023). Plant disease detection using machine learning approaches. *Expert Systems*, 40(5), e13136. <https://doi.org/10.1111/exsy.13136>
- Alosaimi, Wael; Alyami, Hashem; Uddin, Irfan (2021). PeachNet: Peach Diseases Detection for Automatic Harvesting. *Computers, Materials & Continua*, 67(2), 1665-1677. <https://doi.org/10.32604/cmc.2021.014950>
- Anand, Raju; Veni, Shanmugham; Aravinth, Jagatheesan (2016). An application of image processing techniques for detection of diseases on brinjal leaves using k-means clustering method. En *International conference on recent trends in information technology (ICRTIT)* (pp. 1-6). Instituto de Ingenieros Eléctricos y Electrónicos. <https://doi.org/10.1109/ICRTIT.2016.7569531>
- Apolo-Apolo, Orly; Andújar, Dionisio; Reiser, David; Pérez-Ruiz, Manuel; Martínez, Jorge (2021). Deep-learning-based detection of in-field tomatoes using a terrestrial mobile platform. En Stafford, John (Ed.), *Precision agriculture '21* (pp. 319-329). Alianza de Energía y Clima de las Américas. <https://doi.org/10.3920/978-90-8686-916-9>
- Apolo-Apolo, Orly; Martínez-Guanter, Jorge; Egea, Gregorio; Raja, Purushothaman; Pérez-Ruiz, Manuel (2020). Deep learning techniques for estimation of the yield and size of citrus fruits using a UAV. *European Journal of Agronomy*, 115, 126030. <https://doi.org/10.1016/j.eja.2020.126030>
- Apolo-Apolo, Orly; Pérez-Ruiz, Manuel; Martínez-Guanter, Jorge; Egea, Gregorio (2019). Estimación de parámetros biofísicos de interés para la mejora de trigo usando inteligencia artificial. En García, Francisco; Ramos, Pablo (Eds.), *Memorias del X Congreso Ibérico de Agroingeniería* (pp. 959-966). Universidad de Sevilla. <https://dialnet.unirioja.es/servlet/articulo?codigo=8145362>
- Bengio, Yoshua (2009). Learning Deep Architectures for AI. *Foundations and Trends in Machine Learning*, 2(1), 1-127. <https://doi.org/10.1561/2200000006>
- Camacho, Alfonso; Vargas, César; Arguello, Henry (2016). Un estudio comparativo de algoritmos de detección de objetivos en imágenes hiperespectrales aplicados a cultivos agrícolas en Colombia. *Revista Tecnura*, 20(49), 86-99. <http://doi.org/10.14483/udistrital.jour.tecnura.2016.3.a06>
- Camargo, Yeison (2023). *Manejo técnico del cultivo de durazno (Prunus pérsica) variedad Gran Jarillo y el cultivo de higo (Ficus carica) ubicados en el municipio de Silos* [Tesis de pregrado]. Universidad de La Salle. https://ciencia.lasalle.edu.co/ingenieria_agronomica/323
- Dawod, Rodica; Dobre, Ciprian (2022). Automatic segmentation and classification system for foliar diseases in sunflower. *Sustainability*, 14(18), 11312. <https://doi.org/10.3390/su141811312>

- Deng, Li; Dong, Yu (2014). Deep Learning: Methods and Applications. *Foundations and Trends in Signal Processing*, 7(3-4), 197-387.
<https://doi.org/10.1561/20000000039>
- Esgario, José; Krohling, Renato; Ventura, José (2020). Deep learning for classification and severity estimation of coffee leaf biotic stress. *Computers and Electronics in Agriculture*, 169, 105162.
<https://doi.org/10.1016/j.compag.2019.105162>
- Fang, Jen-Kuang; Fong, Cher-Min; Yang, Peng; Hung, Chao-Kai; Lu, Wen-Long; Chang, Chien-Wei (2020). AdaGrad Gradient Descent Method for AI Image Management. En *Memorias de la 2020 IEEE International Conference on Consumer Electronics* (pp. 1-2). Instituto de Ingenieros Eléctricos y Electrónicos.
<https://doi.org/10.1109/ICCE-Taiwan49838.2020.9258085>
- García, Ernesto; Cervantes, Jair; Espejel, Josué; Ruíz, José; García, Farid; (2020). Identification of diseases and pests in tomato plants through artificial vision. En *Proceedings of Intelligent Computing Methodologies: 16th International Conference* (Parte III, pp. 98-109). International Conference on Intelligent Computing.
https://doi.org/10.1007/978-3-030-60796-8_9
- Ghimire, Deepak; Dayoung, Kil; Kim, Seong-heum (2022). A Survey on Efficient Convolutional Neural Networks and Hardware Acceleration. *Electronics*, 11(6), 945
<https://doi.org/10.3390/electronics11060945>
- Gibson, Gavin (1997). Markov chain Monte Carlo methods for fitting spatiotemporal stochastic models in plant epidemiology. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 46(2), 215-233.
<https://doi.org/10.1111/1467-9876.00061>
- Gomez, Michael; Vergara, Alejandro; Montenegro, Frank; Alonso, Henry; Safari, Nancy; Raymaekers, Dries; Ocimati, Walter; Ntamwira, Jules; Tits, Laurent; Omondi, Aman; Blomme, Guy (2020). Detection of banana plants and their major diseases through aerial images and machine learning methods: A case study in DR Congo and Republic of Benin. *ISPRS Journal of Photogrammetry and Remote Sensing*, 169, 110-124.
<https://doi.org/10.1016/j.isprsjprs.2020.08.025>
- González, Ángel; Guerrero, Carlos; Olvera, Carlos; López, Francisco; López, Daniela; Gutiérrez, Valeria; Villagarana, Santiago (2019). Estudio y comparativa de algoritmos de detección de objetos con redes neuronales artificiales convolucionales para la detección de enfermedades en hojas. *Ciencias de la Ingeniería*, 1-6.
<https://doi.org/https://doi.org/10.48779/p41k-fx69>
- Gupta, Jaya; Pathak, Sunil; Kumar, Gireesh (2022). Deep Learning (CNN) and Transfer Learning: A Review. *Journal of Physics: Conference Series*, 2273, 012029.
<https://doi.org/10.1088/1742-6596/2273/1/012029>
- Hardin, Perry; Shumway, Matthew (1997). Statistical significance and normalized confusion matrices. *Photogrammetric Engineering and Remote Sensing*, 63(6), 735-739.
- Kaya, Yasin; Gürsoy, Ercan (2023). A novel multi-head CNN design to identify plant diseases using the fusion of RGB images. *Ecological Informatics*, 75, 101998.
<https://doi.org/10.1016/j.ecoinf.2023.101998>

- Krizhevsky, Alex; Sutskever, Ilya; Hinton, Geoffrey (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, 25, 1097-1105.
- Lozada-Portilla, William; Suárez-Barón, Marco; Avendaño-Fernández, Eduardo (2021). Aplicación de redes neuronales convolucionales para la detección del tizón tardío *Phytophthora infestans* en papa *Solanum tuberosum*. *Revista U. D. C. A Actualidad & Divulgación Científica*, 24(2).
<https://doi.org/10.31910/rudca.v24.n2.2021.1917>
- Martínez, Juliana; Fajardo, Alba; Esquivel, Jhoan; González, Dubán; Prieto, Ángela; Rincón, Daniela (2020). Manejo integrado del cultivo de mango *Mangifera indica* L. *Ciencias Agropecuarias*, 6(1), 51-78.
<https://doi.org/10.36436/24223484.267>
- Mengistu, Abrham; Mengistu, Seffi; Melesew, Dagnachew (2018). An automatic coffee plant diseases identification using hybrid approaches of image processing and decision tree. *Indonesian Journal of Electrical Engineering and Computer Science*, 9(3), 806-811.
<http://doi.org/10.11591/ijeecs.v9.i3.pp806-811>
- Negrete, Jaime (2018). Artificial vision in mexican agriculture for identification of diseases, pests and invasive plants. *Journal of Advancements in Plant Science*, 1(3).
- Pereira, Rafael; Plastino, Alexander; Zadrozny, Bianca; Merschmann, Luiz (2018). Correlation analysis of performance measures for multi-label classification. *Information Processing & Management*, 54(3), 359-369.
<https://doi.org/10.1016/j.ipm.2018.01.002>
- Pérez-Ariza, Cora; Nicholson, Ann; Flores, Julia (2012). Prediction of coffee rust disease using *Bayesian networks*. *Proceedings of the Sixth European Workshop on Probabilistic Graphical Models*, 6, 259-266.
- Pernía, Juan; Sanabria, María (2021). El manejo integral de plagas y enfermedades en cultivos como una alternativa de compromiso para el cumplimiento de la Responsabilidad Social Ambiental en la agricultura. *Dissertare, Revista de Investigación en Ciencias Sociales*, 6(1), 1-21.
- Poernomo, Alvin; Kang, Dae-Ki (2018). Biased dropout and crossmap dropout: learning towards effective dropout regularization in convolutional neural network. *Neural Networks*, 104, 60-67.
<https://doi.org/10.1016/j.neunet.2018.03.016>
- Prakash, M.; Saraswathy, G.; Ramalakshmi, G.; Mangaleswari, K.; Kaviya, T. (2017). Detection of leaf diseases and classification using digital image processing. En *International conference on innovations in information, embedded and communication systems (ICIIECS)* (pp. 1-4). Instituto de Ingenieros Eléctricos y Electrónicos.
- Ríos, Rodolfo (2021). La Agricultura de Precisión. Una necesidad actual. *Ingeniería Agrícola*, 11(1), 67-74.
- Saad, Haji; Adnan, Mohsin (2021). Comparison of optimization techniques based on gradient descent algorithm: a review. *PalArch's Journal of Archaeology of Egypt/Egyptology*, 18(4), 2715-2743.
<https://archives.palarch.nl/index.php/jae/article/view/6705>
- Sampathkumar, Shanmugam; Rajeswari, Ramachandran (2022). An automated crop and plant disease identification scheme using cognitive fuzzy c-means algorithm. *IETE Journal of Research*, 68(5), 3786-3797.
<https://doi.org/10.1080/03772063.2020.1780163>

- Shruthi, U.; Nagaveni, V.; Raghavendra, B. (2019). A review on machine learning classification techniques for plant disease detection. En *5th International conference on advanced computing & communication systems (ICACCS)* (pp. 281-284). Instituto de Ingenieros Eléctricos y Electrónicos.
<https://doi.org/10.1109/ICACCS.2019.8728415>
- Solano, César; Caballero, Ivonne (2022). *Modelo de predicción de plagas en el cultivo de palto utilizando metodología de aprendizaje automático supervisado*. Virú S. A. [Tesis de pregrado]. Universidad Privada Antenor Orrego.
<http://purl.org/pe-repo/ocde/ford#2.02.04>
- Torres-Sánchez, Jorge; Escolà, Alexandre; Castro, Ana; López-Granados, Francisca; Rosell, Joan; Jiménez-Brenes, Francisco; Sanz, Ricardo; López, Eduard; Peña-Barragán, José (2023). UAV photogrammetry vs mobile terrestrial laser scanning for woody crops characterization. En Stafford, John (Ed.), *Precision agriculture '23* (pp. 1019-1026). Alianza de Energía y Clima de las Américas.
<https://doi.org/https://doi.org/10.3920/978-90-8686-947-3>
- Trivedi, Jay; Shamnani, Yash; Gajjar, Ruchi (2020). Plant leaf disease detection using machine learning. En Gupta, Shilpi; Sarvaiya, Jignesh (Eds.), *Emerging Technology Trends in Electronics, Communication and Networking. ET2ECN 2020. Communications in Computer and Information Science* (vol. 1214, pp. 267-276). Springer.
https://doi.org/10.1007/978-981-15-7219-7_23
- Villamizar, César (2014). *Ruta del Durazno*. Universidad de Pamplona.
https://www.unipamplona.edu.co/unipamplona/portalIG/home_174/recursos/chitaga/26042015/diagnostico_economico.jsp
- Woods, Richard; Gonzalez, Rafael (2018). *Digital Image Processing* (4ª ed.). Pearson.
- Zhang, Keke; Xu, Zheyuan; Dong, Shoukun; Cen, Canjian; Wu, Qiufeng (2019). Identification of peach leaf disease infected by *Xanthomonas campestris* with deep learning. *Engineering in Agriculture, Environment and Food*, 12(4), 338-396.
<https://doi.org/10.1016/j.eaef.2019.05.001>