

DETECCIÓN DE ESTRÉS EN PLANTAS DE CHILE HABANERO EMPLEANDO ALGORITMOS DE APRENDIZAJE PROFUNDO

STRESS DETERMINATION IN HABANERO CHILE PLANTS USING DEEP LEARNING ALGORITHMS

M. J. Matuz Cruz¹
J. M. Guzmán Albores²
E. López Carrasco³
M. S. Peralta González⁴

RESUMEN

El chile habanero es conocido por su intenso picor y sabor distintivo, su producción se destina al mercado nacional, internacional y a la industria de alimentos procesados. Uno de los principales desafíos en los cultivos es la detección temprana del estrés biótico y abiótico. Por lo tanto, se implementó un modelo de visión artificial para la detección de estrés en plantas de chile habanero a partir del entrenamiento de una Red Neuronal Convolutiva (CNN), el entrenamiento se llevó a cabo con la herramienta de Google colab utilizando un dataset con imágenes capturadas mediante dispositivos móviles y etiquetadas con herramientas de software especializadas. Diversas investigaciones presentan un enfoque al uso de redes neuronales convolucionales (CNN) para identificar enfermedades y plagas en cultivos, sin embargo, debido a las variaciones en parámetros y procesamiento de imágenes, aún existe un campo de estudio a mejorar. Se realizaron experimentos con los modelos de CNN YOLO v8, Detectron2 y MobileNetv2 obteniendo con este último un porcentaje del 90% en la precisión del estrés, estos avances en visión artificial abren nuevas oportunidades para transformar el manejo del estrés en el chile habanero y el manejo agrícola. Se obtuvo también la formación de recurso humano con seis residentes y dos estudiantes de posgrado.

ABSTRACT

Habanero peppers are known for their intense spiciness and distinctive flavor, and their production is destined for the domestic and international markets and the processed food industry. One of the main challenges in crops is the early detection of biotic and abiotic stress. Therefore, a computer vision model was implemented for stress detection in habanero chili plants by training a Convolutional Neural Network (CNN). The training was carried out with the Google colab tool using a proprietary dataset with images captured by devices and labeled with specialized software tools. Several researches present an approach to the use of convolutional neural networks (CNN) to identify diseases and pests in crops, however, due to variations in parameters and image processing there is still a field of study to be improved. Experiments were conducted with CNN models YOLO v8, Detectron2 and MobileNetv2, obtaining with the latter a percentage of 90% in stress accuracy. These advances in artificial vision open new opportunities to transform stress management in habanero peppers and agricultural management. Human resources training was also obtained with six residents and two postgraduate students.

ANTECEDENTES

El chile habanero es una especie conocida por su intenso picor y sabor distintivo, con producción concentrada en Yucatán y destinada tanto al mercado nacional como internacional. Las propiedades organolépticas del chile habanero dependen de diversos factores ambientales como el tipo de suelo y las condiciones osmóticas y nutricionales (González, 2024). Sin embargo, este cultivo enfrenta amenazas significativas debido a

¹ Profesor de Tiempo Completo del Instituto Tecnológico de Tapachula. mjmatuz@tapachula.tecnm.mx

² Profesor de Tiempo Completo del Instituto Tecnológico de Tapachula. yuek@hotmail.com

³ Profesor de Tiempo Completo del Instituto Tecnológico de Tapachula. eli.lopez@tapachula.tecnm.mx

⁴ Profesor de Tiempo Completo del Instituto Tecnológico de Tapachula. msperaltagonzalez@gmail.com

factores ambientales y biológicos que afectan su crecimiento y rendimiento, lo que compromete tanto la calidad como la cantidad de la producción.

Entre los factores que impactan el desarrollo y productividad del chile habanero, destacan dos tipos principales de estrés: el estrés abiótico y el estrés biótico. El estrés abiótico es provocado por factores no biológicos, como la sequía, la salinidad del suelo, las altas temperaturas y la radiación. Estos elementos afectan negativamente la capacidad de las plantas para realizar la fotosíntesis, lo que limita su crecimiento y productividad (Reyna, 2019). Por otro lado, el estrés biótico resulta de la interacción de la planta con organismos vivos, como patógenos, herbívoros o competidores, y puede afectar su desarrollo y resistencia a enfermedades. En otras palabras, el estrés biótico proviene de ataques de plagas o enfermedades al cultivo (Fagro, 2023).

Tradicionalmente, el diagnóstico de enfermedades en los cultivos ha sido realizado mediante inspección visual, lo cual resulta en una metodología limitada y sujeta a la experiencia y habilidad del observador (Krizhevsk, 2012). Este proceso no solo es lento y requiere de expertos capacitados, sino que es ineficaz en grandes plantaciones, lo que aumenta el riesgo de detección tardía de problemas de salud en las plantas. Consecuentemente, esta demora puede derivar en el uso excesivo de pesticidas y productos químicos, incrementando los costos de producción y generando un impacto ambiental negativo.

En respuesta a estos desafíos, la implementación de este proyecto emplea un modelo basado en inteligencia artificial para la detección temprana de estrés en plantas de chile habanero. Utilizando redes neuronales convolucionales (CNN), la metodología se enfoca a la detección y clasificación automática permitiendo un monitoreo eficiente y en tiempo real de la salud de los cultivos. La adopción de esta tecnología optimiza la precisión del diagnóstico y facilita la gestión sostenible del cultivo, promoviendo prácticas agrícolas responsables y rentables.

Tipos de estrés

Estrés: Es el estado, en el cual, la planta no realiza sus funciones fisiológicas de manera normal lo cual detiene su crecimiento y desarrollo, limitando la productividad de los cultivos (Valle, 2013).

Estrés abiótico: Es causado por factores abióticos. Esto significa factores "no vivos", como por ejemplo el viento, demasiada luz y un contenido demasiado alto de sales en el suelo (Pravia, 2025).

Dentro de la categoría de estrés abiótico existen diversos tipos de estrés como lo son:

- **Estrés por temperatura:** Las altas temperaturas causan daños fisiológicos y metabólicos, con las bajas de temperatura las plantas dejan de crecer o se congelan y terminan muriendo.
- **Estrés por falta o exceso de luz:** La luz es la fuente de energía para la fotosíntesis, que está relacionada con la producción de carbohidratos y oxígeno, la falta o el exceso de estos influyen en su crecimiento y desarrollo.

- Estrés por la ausencia o exceso de nutrientes: La ausencia de nutrientes afecta al crecimiento de la planta y a su fruto, pero el exceso también tiene efectos negativos, como en los casos del nitrógeno y del fósforo.

Estrés biótico: Es causado por organismos vivos. Varios patógenos como los hongos, las bacterias y los virus juegan un papel en esto (Valle, 2013).

Herramientas

Apowersoft: es un proveedor de soluciones multimedia y de negocios en línea gratuitas, que ayuda a los usuarios a grabar, enriquecer, convertir y entregar contenido multimedia, la transferencia y gestión de móviles, la conversión de PDF, la eliminación del fondo de imágenes, la recuperación de datos en su vida y obras diarias (Apowersoft, 2024).

Roboflow: Una herramienta de inteligencia artificial que le da a tu aplicación la capacidad de procesar imágenes. Simplifica el proceso al proporcionarte herramientas y algoritmos de aprendizaje automático, permitiendo desarrollar rápidamente aplicaciones prácticas que pueden reconocer objetos, rostros y realizar diversas tareas visuales (Roboflow, 2024).

Supervisely: Es una herramienta que ayuda a trabajar con imágenes y videos para proyectos de inteligencia artificial. Con ella, puedes marcar y etiquetar fácilmente diferentes partes de las imágenes (como objetos o áreas específicas), organizar todo tu trabajo en proyectos, y entrenar modelos de IA para que reconozcan patrones en imágenes.

PhotoRoom: Es una aplicación para la edición de imágenes que cuenta con múltiples características como, eliminación de fondos, edición avanzada y exportación fácil (Photoroom, 2024).

Google Colab: es un servicio alojado de Jupyter Notebook que no requiere configuración y que ofrece acceso gratuito a recursos de computación, como GPUs y TPUs. Colab es una solución especialmente adecuada para el aprendizaje automático, la ciencia de datos y la educación (Google-colab, 2024).

Métricas

- Precisión (Accuracy): La precisión es una métrica que indica la proporción de predicciones correctas realizadas por el modelo en comparación con el número total de predicciones.
- Precisión: Esta métrica mide la proporción de verdaderos positivos correctamente clasificados sobre el número total de muestras clasificadas como positivas.
- Recall: Esta métrica evalúa la proporción de verdaderos positivos en relación con el total de instancias positivas en el conjunto de datos.
- Score: Es una medida que combina la precisión y el recall, ofreciendo una medida equilibrada del rendimiento del modelo.
- Matriz de confusión: Es una tabla que describe el rendimiento de un modelo supervisado de Machine Learning en los datos de prueba, donde se desconocen los verdaderos valores. Se llama “matriz de confusión” porque hace que sea fácil detectar dónde el sistema está confundiendo dos o más clases tal como se muestra en la Tabla 1.

Tabla 1. *Matriz de confusión.*

Casos	Clasificación	
	Positivo	Negativo
Clase real	Positivo	Negativo
Positivos	VP	FN
Negativos	FP	VN

Donde:

Verdaderos Positivos (VP)= Número de muestras predichas como positivas.

Verdaderos Negativos (VN)= Número de muestras predichas erróneamente como positivas.

Falsos Positivos (FP)= Número de muestras predichas correctamente como negativas.

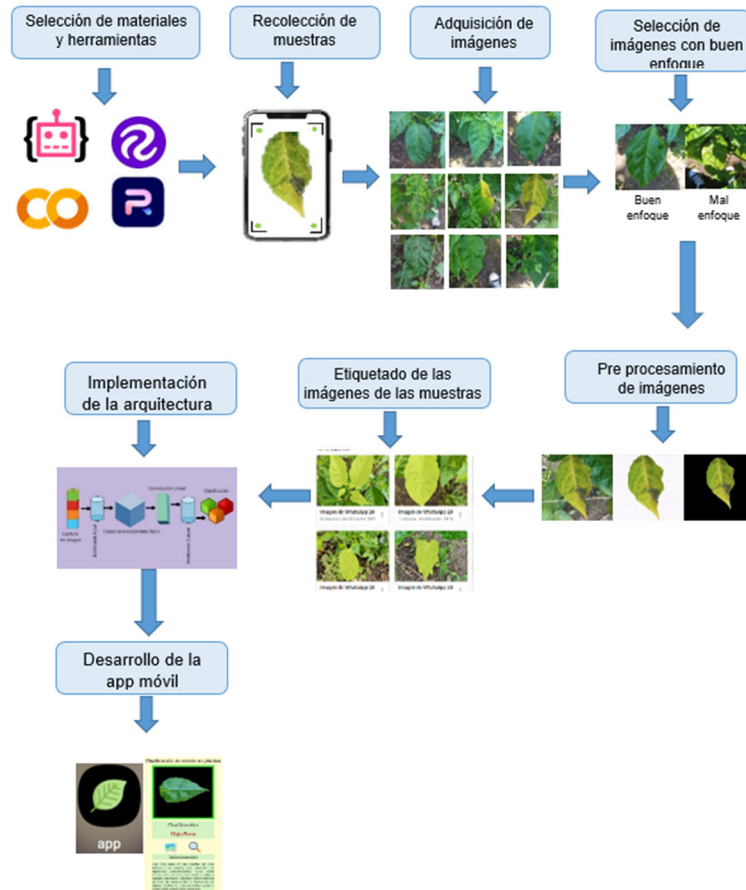
Falsos Negativos (FN)= Número de muestras predichas erróneamente como negativas.

En este trabajo, se ha seleccionado la arquitectura MobileNetV2, conocida por su alta precisión en el reconocimiento de enfermedades en plantas y su eficiencia computacional. Las Redes Neuronales Convolucionales se destacan como una de las técnicas más efectivas para tareas de detección de objetos en imágenes, ofreciendo precisión y rapidez (Krizhevsk, 2012). El proyecto se enfoca en el desarrollo de un modelo basado en MobileNetV2 para la detección de síntomas de estrés abiótico, estrés biótico y el reconocimiento de plantas sanas en cultivos de chile habanero. La implementación del sistema permitirá optimizar el monitoreo de cultivos, reducir el uso excesivo de productos químicos y mejorar la seguridad de los trabajadores al minimizar su exposición a sustancias tóxicas. En última instancia, esta propuesta busca impulsar un manejo agrícola más eficiente y sostenible, beneficiando tanto a productores como al medio ambiente.

METODOLOGÍA

El desarrollo de esta metodología la cual se visualiza en la Figura 1, se conforma de las siguientes etapas: recopilación de datos, pre-procesamiento de imágenes, etiquetado de imágenes, implementación de arquitectura CCN y desarrollo de la aplicación móvil.

Figura 1. Metodología implementada.




Recopilación de datos

Se creó un conjunto de datos de imágenes de hojas de chile habanero utilizando dispositivos móviles: Samsung A32 (64 MP), Oppo Reno 7 (64 MP), Xiaomi POCO C40 (13 MP), y Xiaomi POCO X3 NFC (64 MP). Para asegurar la calidad y reducir el sesgo entre dispositivos, se seleccionaron fotografías teniendo en cuenta el factor de iluminación y enfoque nítido en las hojas.

Para la sintonización del modelo se conformó un conjunto de datos compuesto por 900 imágenes en total y se clasificaron en tres categorías: estrés abiótico, estrés biótico y hojas sanas, cada carpeta cuenta con 300 imágenes.

Pre-procesamiento

El preprocesamiento consistió en quitar el fondo de las imágenes a negro, para ese proceso se utilizó el editor PhotoRoom la cual brinda la facilidad de remover el fondo de la imagen en su totalidad como se muestra en la Figura 2 para después insertarle un fondo negro y obtener una mayor discriminación como se muestra en la figura 3.

Figura 2. Región de Interés.**Figura 3.** Aplicación de fondo negro.

Etiquetado de imágenes

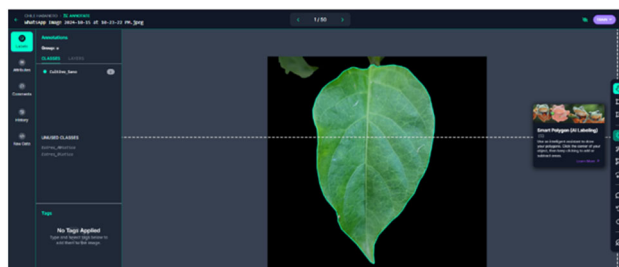
Para el etiquetado de imágenes se emplearon dos herramientas clave:

Supervisely

Esta herramienta permite procesar conjuntos de datos de hasta 25 MB y admite una amplia variedad de formatos de imagen, incluyendo JPEG, PNG y TIFF. Se utilizó la herramienta *Smart tool* para agilizar el proceso de etiquetado ya que nos ayuda a seleccionar áreas con contornos complejos.

Roboflow

Es una herramienta de etiquetado de imágenes basada en inteligencia artificial que ofrece funcionalidades avanzadas para la anotación de objetos. En particular, se utilizó la herramienta *Smart Polygon* como se observa en la Figura 4, la cual aprovecha modelos de aprendizaje automático para sugerir polígonos que delimitan con mayor precisión los objetos de interés en comparación con los cuadros delimitadores tradicionales.

Figura 4. Etiquetado de imagen.

Entrenamiento de la arquitectura MobileNet-v2

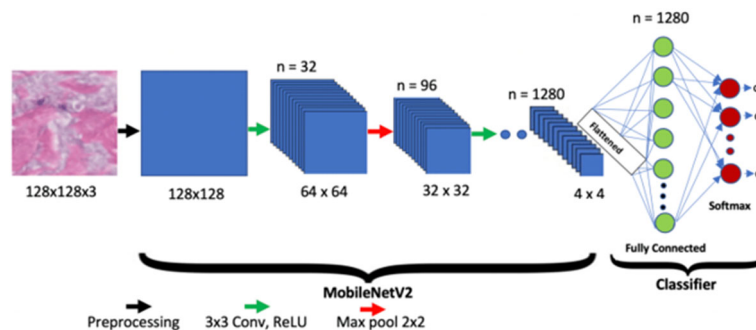
El entrenamiento del modelo se realizó utilizando la página web Google Colaboratory, la cual permite utilizar recursos de computación gratuitos como GPU.

Los hiperparámetros que se utilizaron para controlar el proceso de entrenamiento para el modelo fueron:

- Imágenes para entrenamiento: 700
- Imágenes para validación: 100
- Imágenes de prueba: 100
- Etiquetas: Las etiquetas fueron tres diferentes Hojas_Sanas, Estrés_Biotico y Estrés_Abiotico.
- Img: El tamaño de la imagen de entrada fue de 224 x 224.
- Lote (batch): El tamaño de imágenes procesadas fueron de 64.
- Épocas: Las épocas que se utilizaron fueron 50.

MobileNetV2: Es una arquitectura de CNN optimizada para dispositivos móviles y aplicaciones con restricciones de recursos computacionales la cual ofrece un equilibrio entre eficiencia y precisión, siendo ideal para implementaciones en campo con hardware limitado. MobileNetV2 Es una red neuronal convolucional con 53 capas de profundidad, puede cargar una versión pre-entrenada de la red entrenada en más de un millón de imágenes desde la base de datos ImageNet (Krizhevsk, 2012). La red preentrenada puede clasificar imágenes en 1000 categorías de objetos, en la Figura 5 se muestra el diagrama de la arquitectura de MobileNet-v2.

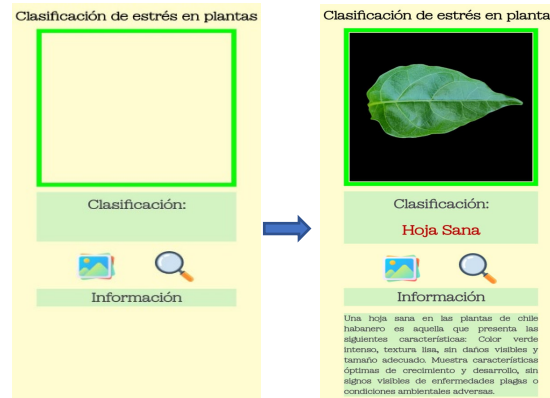
Figura 5. Diagrama de la arquitectura de MobileNet-v2.



Desarrollo de la aplicación

Para la clasificación de imágenes se desarrolló una interfaz capaz de ejecutarse en dispositivos móviles o en entornos con recursos limitados, la Figura 6 ejemplifica la interfaz de usuario.

Figura 6. Representación de la aplicación móvil.



RESULTADOS

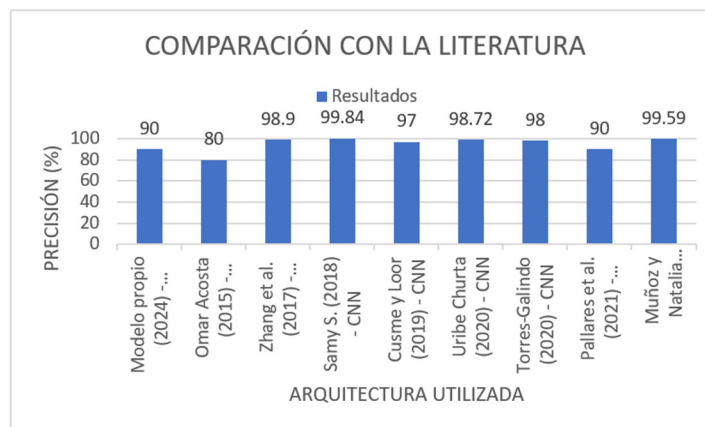
Con base a la experimentación de probar tres modelos de redes neuronales convolucionales, los resultados se muestran en la Tabla 2, esto considerando que la sintonización de los hiperparámetros fue la misma para los tres modelos al igual que las propiedades de las imágenes de entrada.

Tabla 2 Concentrado de los experimentos realizados.

Modelo CCN	Sensibilidad	Especificidad	Exactitud	Precisión	F1 Score
YOLO V8	78.26	88.23	82.5	90.00	83.72
Detectron3	86.66	72.00	77.5	65.00	74.28
MovilNet-V2	94.73	90.47	91.89	90.00	93.30

En la Figura 7 podemos observar los resultados que se obtuvieron con el modelo MobileNet-v2 y la comparación de los resultados en los reportes de la literatura.

Figura 7. Comparación de arquitectura propuesta.



CONCLUSIONES

La implementación de una metodología basada en aprendizaje profundo para la detección de estrés en plantas de chile habanero demuestra valores aceptables al utilizar redes neuronales convolucionales, en específico el modelo (MobileNet-v2) en combinación con herramientas tales como Roboflow y Google Colab, además de contribuir en la formación de recurso humano y favorecer a la comunidad en la detección de enfermedades de manera oportuna. Se realizaron tres experimentos para clasificar hojas de chile habanero en tres categorías: estrés_biotico, estrés_abiotico y hojas_sanas. En el primer experimento el modelo alcanzo una precisión promedio del 76%, en el segundo experimento la precisión mejoro a 82%, destacando un buen rendimiento en hojas con estrés biótico (88% de precisión) y en el tercer experimento logro alcanzar una precisión del 90%, en este caso la clasificación de hojas sanas fue la más precisa con un 93%.

En general, los resultados obtenidos destacan la eficacia de MobileNetV2 como una herramienta prometedora para detectar estrés en cultivos, con un enfoque particular en su implementación en dispositivos móviles. No obstante, también evidencian la importancia de contar con un conjunto de datos más amplio y representativo para mejorar el desempeño en la clasificación de categorías más complejas, como el estrés abiótico. Este trabajo representa un avance significativo hacia la automatización del monitoreo de cultivos, reduciendo la dependencia de métodos manuales y promoviendo un uso más racional de recursos químicos. El desarrollo de tecnologías avanzadas que permitan identificar de forma rápida y precisa las enfermedades o plagas del chile habanero nos ayudara a automatizar el proceso de diagnóstico, reduciendo los errores humanos y mejorando la eficiencia del monitoreo de la planta, esto les permitirá a los agricultores aplicar tratamientos más específicos, solo cuando sea necesario, evitando el uso excesivo de productos químicos.

La implementación de visión artificial y arquitecturas como YOLOV8, Detrectron2 o MobileNetV2 nos permite un análisis más detallado y continuo, reduciendo la carga de trabajo manual y mejorando la precisión en la detección.

BIBLIOGRAFÍA

- Apowersoft. (s. f.). *Multimedia solutions for business and daily needs*. <https://www.apowersoft.com/>
- Fagro de México. (2023, 6 de noviembre). El estrés biótico y abiótico: Fenómenos que pueden causar grandes pérdidas en la producción agrícola. *Blog de Fagro*. <https://blogdefagro.com/agricultura/el-estres-biotico-y-abiotico-fenomenos-que-puedencausar-grandes-perdidas-en-la-produccion-agricola/>
- Google. (s. f.). *Colaboratory FAQ*. <https://research.google.com/colaboratory/intl/es/faq.html>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems* (Vol. 25, pp. 1097–1105). <https://proceedings.neurips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf>

- Lau, N. R., González, M. M., Antonio, A. A. G., & Estévez, M. M. (s. f.). *Efecto del estrés hídrico sobre la producción de capsaicinoides en chile habanero (Capsicum chinense)*. Sociedad Mexicana de Bioquímica. https://smbb.mx/congresos%20smbb/merida05/TRABAJOS/AREA_II/CII-34.pdf
- Méndez-Espinoza, C., & Vallejo-Reyna, M. Á. (2019). Mecanismos de respuesta al estrés abiótico: Hacia una perspectiva de las especies forestales. *Revista Mexicana de Ciencias Forestales*, 10(56), e567. <https://doi.org/10.29298/rmcf.v10i56.567>
- Velásquez-Valle, R., Reveles-Torres, L. R., & Reveles-Hernández, M. (2013). *Manejo de las principales enfermedades del chile para secado en el norte centro de México* (Folleto técnico núm. 50). INIFAP, Campo Experimental Zacatecas. <https://zacatecas.inifap.gob.mx/publicaciones/EnfChilS.pdf>
- Pravia, A. (2023, 25 de mayo). Tipos de estrés en las plantas: Guía básica para agricultores. *Symborg*. <https://symborg.com/mx/actualidad-mx/tipos-de-estres-en-las-plantas-guia-basica-para-agricultores/>
- Roboflow. (s. f.). *Computer vision tools for developers and enterprises*. <https://roboflow.com/>