

Diseño de un sistema de detección temprana para el virus del mosaico del tomate en cultivos de tomates (*Solanum Lycopersi*

Fischer Juárez, Erick Alberto

2023

<https://hdl.handle.net/20.500.11777/5914>

<http://repositorio.iberopuebla.mx/licencia.pdf>

Diseño de un sistema de detección temprana para el virus del mosaico del tomate en cultivos de tomates (*Solanum Lycopersicum*)

Chávez Varela Eduardo (Sexto semestre en Ingeniería en Comunicaciones y Electrónica)¹, Fischer Juárez Erick Alberto (Sexto semestre en Ingeniería Mecatrónica)¹, Lameda Díaz Stevanato Leon (séptimo semestre en Ingeniería en Sistemas Computacionales)¹, Suárez Falcón Valeria Samantha (séptimo semestre en Ingeniería en Sistemas Computacionales)¹, Morúa Álvarez Nora del Rocío (profesor responsable)¹, Girón Nieto Huber (profesor asesor)¹ y Ochoa García Oliver (profesor asesor)¹

¹Universidad Iberoamericana Puebla, San Andrés Cholula, Puebla, México.

Resumen

El jitomate (*Solanum lycopersicum*), perteneciente a la familia *Solanaceae*, es una planta herbácea de hasta 3 metros de altura, con ramas verdes dispersas y hojas ovadas a elípticas. México, especialmente Puebla, destaca en su producción, alcanzando 2,860,305.2 toneladas en 2019, donde el estado contribuyó con 125 mil toneladas [1]. El virus del mosaico del tomate (ToMV) afecta gravemente los cultivos al reducir rendimiento y calidad, ya que la propagación del ToMV se da por contacto, ya sea por el viento, manos de operarios, ropa o herramientas contaminadas. Los síntomas incluyen patrones de mosaico en las hojas, reducción del crecimiento y distorsión en los frutos. En este proyecto se propone un sistema de detección temprana mediante aprendizaje automático, Raspberry Pi y Python. La metodología del sistema comprende investigación, recopilación de datos, desarrollo de modelos de aprendizaje automático y procesamiento de imágenes digitales. La Raspberry Pi 4B y la cámara Raspberry Pi 5MP se seleccionaron por su rendimiento y accesibilidad, el modelo se entrenó con imágenes de *Kaggle*, y la implementación se probó y ajusto continuamente. Los resultados destacan la eficacia del sistema para detectar el virus del mosaico del tomate, con ajustes en código y modelo para mejorar precisión y velocidad de respuesta, la interfaz de usuario se optimizó para facilitar la interpretación de resultados, la capacidad de adaptarse a condiciones variables y diversidad de datos refuerza su utilidad. El proyecto logra el diseño eficaz de un sistema de detección para el virus del mosaico del tomate en cultivos de jitomate.

Palabras clave: virus del mosaico del tomate, procesamiento de imágenes, aprendizaje automático.

***Autor Corresponsal:** erick.fischer@iberopuebla.mx

Introducción

El jitomate (*Solanum lycopersicum*) es una especie de planta que forma parte de la familia *Solanaceae* y posee una significativa relevancia comercial a nivel global. Se trata de una planta herbácea que puede alcanzar una altura de hasta 3 metros, con un crecimiento erecto a decumbente y ramas verdes que presentan tricomas de tono blanquecino distribuidos de manera dispersa. Sus hojas, que oscilan entre 8 y 35 cm de longitud y de 3 a 10 cm de ancho. Estas hojas se disponen de forma alterna y tienen una forma que varía entre ovada y elíptica [2].

El tomate, científicamente conocido como *Solanum lycopersicum*, figura como el décimo cultivo más significativo en México, según datos proporcionados por el Instituto Nacional de Estadística y Geografía (INEGI). En el año 2019, el país logró una impresionante producción de 2,860,305.2 toneladas de jitomate, distribuidas en extensas áreas de cultivo que abarcaron 42,383.3 hectáreas [3].

En este contexto, resulta destacable la participación del estado de Puebla, que se posiciona como el séptimo actor más relevante a nivel nacional en la producción de jitomate. Durante el mismo año, Puebla contribuyó significativamente al panorama agrícola del país al generar una producción estimada en 125 mil toneladas de este fruto versátil [1].

Estos datos subrayan la importancia económica y agrícola del cultivo de jitomate en México, evidenciando la contribución sustancial de Puebla a la producción nacional. Una de las enfermedades más comunes del jitomate (*Solanum lycopersicum*) es el virus del mosaico del tomate

(ToMV) Este virus es altamente contagioso y puede causar daños significativos en las plantas de tomate. Su impacto en los cultivos se debe a la reducción del rendimiento y la calidad de los frutos, lo que puede tener consecuencias económicas graves.

La forma de transmisión de este virus es esencialmente por contacto. El contacto de una planta enferma con una planta sana, provocado por el viento o a través de las manos de los operarios, de su ropa o de herramientas de trabajo contaminadas, es suficiente para transmitirlo. Además, el virus es transmitido por la semilla del tomate, estando localizado en las envueltas de la semilla y, en menor proporción, en el endospermo, pero no en el embrión. El virus puede conservarse en el endospermo hasta 9 años.

Los síntomas del virus del mosaico del tomate incluyen: Patrones de mosaico en las hojas: Las hojas de las plantas infectadas pueden mostrar patrones de mosaico, con áreas de colores claros y oscuros, lo que da lugar a un aspecto mosaico característico.

Reducción del crecimiento: Las plantas infectadas tienden a mostrar un crecimiento reducido, lo que afecta el tamaño y la vigorosidad de las plantas.

Distorsión en los frutos: Los frutos de las plantas infectadas pueden mostrar deformidades, arrugas o manchas, lo que reduce su calidad y valor comercial.

La infección por el virus del mosaico del tomate en los cultivos de tomate puede tener un impacto económico significativo en la agricultura. Sin embargo, es importante destacar que la magnitud de este impacto puede variar según varios factores, incluyendo la severidad de la infección, el

momento en que ocurre durante la temporada de cultivo y las prácticas de manejo utilizadas por los agricultores. Aquí hay una evaluación general del impacto económico que esta infección puede tener:

Reducción en el rendimiento: El virus del mosaico del tomate puede causar una disminución significativa en el rendimiento de los cultivos de tomate. Las plantas infectadas pueden producir menos frutos y los frutos pueden ser más pequeños y de menor calidad. Esto puede resultar en una pérdida directa de ingresos para los agricultores, ya que producen menos tomates para la venta.

Costos de control: Los agricultores a menudo deben tomar medidas para controlar la propagación del virus del mosaico del tomate, como la eliminación de plantas infectadas, la aplicación de insecticidas para controlar los vectores (por ejemplo, áfidos) y la implementación de prácticas de manejo más estrictas. Estos controles pueden aumentar los costos de producción.

Pérdida de mercado: Los tomates infectados por el virus del mosaico pueden ser menos atractivos para los compradores y los consumidores debido a su calidad reducida. Esto puede llevar a una pérdida de mercado para los agricultores, ya que los compradores pueden buscar productos de mejor calidad en otros lugares.

Impacto en la cadena de suministro: Si una región experimenta una alta incidencia de infección por el virus del mosaico del tomate en los cultivos de tomate, esto puede afectar la disponibilidad y los precios de los tomates en el mercado local y nacional. Esto puede tener un impacto en toda la cadena de suministro, desde los agricultores hasta los minoristas y los consumidores.

Algunos de los métodos para el tratamiento del virus del mosaico del tomate son:

Termoterapia de la semilla seca con calor seco a 80°C durante 24 horas. Elimina el virus de las envolturas de la semilla de forma eficaz [4].

Inmersión de la semilla en una solución de fosfato de sodio al 10% durante 15 minutos y posteriormente en hipoclorito sódico al 0,525% durante 30 minutos [5]. Es necesario lavar con agua abundante después del tratamiento.

Medidas profilácticas: Deben aplicarse de manera estricta medidas de higiene y limpieza de las estructuras destinadas a la producción de plántulas. Así como lavar los útiles de trabajo y las manos con una solución de jabón potásico después de tocar cada planta o sumergir las manos en leche desnatada.

Desinfección del suelo para evitar contaminaciones originadas a partir de raíces y restos vegetales mediante biofumigación o solarización.

La agricultura de precisión se basa en la idea de aplicar la cantidad correcta de recursos en el momento y lugar adecuados. Utiliza la tecnología de la información para adaptar el manejo de suelos y cultivos a la variabilidad presente en un área específica. Esto implica el empleo de sistemas como el GPS y dispositivos electrónicos para recopilar datos sobre los cultivos. La agricultura de precisión se destaca por su capacidad para optimizar la gestión de grandes extensiones de tierra. Una de sus principales ventajas es la capacidad de analizar los resultados de los ensayos en sectores individuales dentro de un mismo terreno,

lo que permite ajustar el manejo de manera diferenciada en cada uno de ellos [6].

Lo que diferencia a la agricultura de precisión de la agricultura convencional radica en que la agricultura convencional considera el terreno de cultivo como homogéneo y, por lo tanto, la distribución de los insumos se hace de forma promedio, distribuyendo un valor promedio el insumo por todo el campo, mientras que, por otro lado, la agricultura de precisión toma en cuenta las diferencias de distintas variables entre secciones del terreno, y en base a ellas es como distribuye los insumos.

En este contexto, el presente proyecto propone el diseño de un sistema de detección temprana para el virus del mosaico en cultivos de jitomate (*Solanum lycopersicum*). La metodología se basa en la aplicación de modelos de aprendizaje automático mediante la plataforma *Teachable Machine*, en combinación con tecnologías como Raspberry Pi y el lenguaje de programación Python. Este enfoque innovador busca no solo detectar la presencia del virus, sino también optimizar el proceso de detección, haciendo la tecnología accesible y beneficiosa para los agricultores y profesionales del sector.

Metodología

Diseño de Prototipo

Para la materialización efectiva del proyecto, se implementó una metodología estructurada en la fase de diseño del prototipo. Este enfoque garantizó la coherencia entre la concepción teórica y la aplicación práctica del sistema de detección del virus del mosaico del tomate en cultivos de tomate.

Esta metodología aseguró un enfoque sistemático desde la selección del cultivo hasta la implementación del sistema de detección del virus del mosaico del tomate en cultivos de tomate, integrando elementos clave como la investigación, la recopilación de datos, el desarrollo del modelo de aprendizaje automático y la captación y procesamiento de imágenes en tiempo real. Primero, se procedió a identificar y seleccionar la planta de jitomate como el cultivo de estudio en el estado de Puebla. Posteriormente, se realizó una investigación detallada sobre el virus del mosaico del tomate (ToMV), confirmando su presencia en el estado.

Posteriormente, se llevó a cabo una detallada revisión de los requisitos funcionales y no funcionales predefinidos para establecer las bases del prototipo. Esta etapa incluyó la identificación minuciosa de características esenciales, tales como la portabilidad, la eficiencia en la captación de imágenes y la precisión en la clasificación del modelo de aprendizaje automático.

Seguidamente, se procedió a la selección cuidadosa de componentes hardware y software para la implementación del prototipo. La elección de la Raspberry Pi 4B y la cámara Raspberry Pi 5MP se fundamentó en su capacidad para proporcionar un equilibrio óptimo entre rendimiento, tamaño compacto y acceso a GPIO.

Materiales

Tabla 1: Materiales utilizados para el diseño

Pieza	Descripción
-------	-------------

Raspberry pi modelo B	La Raspberry Pi 4 Model B es una computadora de placa única (SBC) desarrollada por la Fundación Raspberry Pi, cuenta con un procesador Broadcom BCM2711 de cuatro núcleos Cortex-A72 a 1.5 GHz, opciones de memoria RAM de 2 GB, 4 GB o 8 GB, y múltiples puertos USB 3.0 y 2.0 para conectividad.
Innomaker Módulo de cámara Raspberry Pi 5MP 1080P	Módulo de cámara de bajo costo y ángulo más amplio que está diseñado para ser totalmente compatible con la cámara oficial Raspberry Pi. Compatible con Libcamera y Raspicam.
Cable Micro HDMI a HDMI 2.1	Un cable Micro HDMI a HDMI 2.1 es un cable diseñado para conectar dispositivos con puertos Micro HDMI, como ciertos modelos de cámaras, tabletas o dispositivos de video, a dispositivos con puertos HDMI estándar.




Fig. 1. Diagrama de la Raspberry Pi 4 Modelo B.

Hardware del Sistema

Se utilizó la computadora de placa única (SBC) Raspberry Pi 4 Modelo B, desarrollada por la Fundación Raspberry Pi, fue lanzada en junio de 2019 y presenta mejoras significativas en comparación con sus predecesoras. Equipada con un procesador Broadcom BCM2711 de cuatro núcleos Cortex-A72 a 1.5 GHz, representa un avance considerable con respecto a la Raspberry Pi 3, brindando un rendimiento notablemente mejorado. La Raspberry Pi 4 permite la ejecución de aplicaciones más robustas y facilita la multitarea. Su conectividad se destaca con dos puertos USB 3.0 y dos puertos USB 2.0, posibilitando transferencias rápidas de datos y conexión con diversos periféricos. Además, incorpora un puerto Ethernet Gigabit para mejorar la velocidad de conexión a redes, junto con soporte para WiFi 802.11ac y Bluetooth 5.0, facilitando la conectividad inalámbrica.

Con dos puertos HDMI capaces de admitir hasta dos monitores 4K, la Raspberry Pi 4 resulta idónea para

aplicaciones multimedia y de visualización. Mantiene la compatibilidad con los puertos GPIO (General Purpose Input/Output) de versiones anteriores, permitiendo la conexión con diversos dispositivos y componentes electrónicos. Esta computadora de placa única se encuentra disponible en variantes de 2 GB, 4 GB y 8 GB de memoria RAM LPDDR4, para este proyecto se eligió la variante de 2 GB, para el almacenamiento, utiliza una tarjeta microSD para el sistema operativo y los datos, y se alimenta mediante un conector USB-C, lo que simplifica la fuente de energía y mejora la eficiencia en comparación con modelos anteriores. Sin embargo, cabe destacar que la Raspberry Pi 4 puede experimentar calentamiento en cargas de trabajo intensivas, lo que motivó la adición de un disipador de calor y un ventilador para controlar la temperatura.

Estas características convierten a la Raspberry Pi 4 en una opción versátil y potente para prototipos de sistemas de monitoreo. Para este propósito, la elección de la variante de 2 GB de RAM se basa en su accesibilidad económica y suficiente capacidad para un sistema de monitoreo básico con una cámara de 5MP y aplicaciones asociadas. Este enfoque permite evaluar la viabilidad del sistema mientras se mantiene una eficiencia operativa.

Software del Sistema

La metodología de software adoptada para el desarrollo del sistema de detección del virus del mosaico del tomate en cultivos de tomate se rigió por principios estructurados y eficientes. A continuación, se detallan las fases y procesos específicos que conformaron la metodología de software. La creación del modelo clasificador de aprendizaje automático se realizó a través de la plataforma *Teachable Machine*. Este proceso comprendió las siguientes fases:

- **Carga del Dataset:** Se incorporaron imágenes representativas de hojas sanas e infectadas con el virus del mosaico del tomate desde *Kaggle*.
- **Configuración del Modelo:** Se ajustaron parámetros como 50 épocas y una tasa de aprendizaje de 0.001 para optimizar el rendimiento del modelo.
- **Exportación a TensorFlow:** El modelo entrenado se exportó utilizando la biblioteca de *TensorFlow*, para su integración y compatibilidad futura.

Para garantizar la captura sistemática de imágenes, se optó por una solución de software implementada en Python, respaldada por la biblioteca *picamera2*. Esta elección se alineó con la integración eficiente entre el código y el hardware seleccionado, la Raspberry Pi 4B y la cámara Raspberry Pi 5MP. El script en Python facilitó la automatización del proceso de captura, permitiendo la adquisición de imágenes en intervalos regulares con precisión y eficacia.

El programa de clasificación automática de imágenes se diseñó en Python, abordando las siguientes etapas:

- Importación de Bibliotecas: Se integraron las bibliotecas esenciales como *Keras*, *PIL*, *NumPy*, *OpenCV*, entre otras.
- Carga del Modelo y Etiquetas: El modelo *TensorFlow* se cargó, y las etiquetas de clases se extrajeron del archivo "labels.txt".
- Procesamiento de Imágenes: Se implementó el procesamiento de imágenes, incluyendo redimensionamiento, normalización y predicciones del modelo.
- Gestión de Carpetas: La administración eficaz de las carpetas de entrada y salida se llevó a cabo, eliminándolas y recreándolas al finalizar el procesamiento.
- Se llevaron a cabo pruebas sistemáticas y continuas para evaluar el rendimiento del sistema en diversas condiciones y escenarios. Los ajustes necesarios se realizaron tanto en el código como en la configuración del modelo según los resultados obtenidos. En paralelo, se perfeccionó el programa en Python encargado de la clasificación y procesamiento de las imágenes capturadas. Este proceso abarcó desde la carga del modelo *TensorFlow* hasta la normalización de imágenes y la asignación de etiquetas a las predicciones, permitiendo la identificación precisa del virus del mosaico del tomate en las hojas de tomate.

Las pruebas iterativas desempeñaron un papel crucial en la evaluación y mejora del prototipo. Ajustes continuos se realizaron para asegurar la eficacia y confiabilidad del sistema en diversas condiciones ambientales y variaciones en la apariencia de las hojas de tomate.

Resultados y Discusión

Al principio, el modelo de aprendizaje automático pudo haber tenido dificultades para procesar grandes conjuntos de datos de imágenes de manera eficiente. La optimización del código implicó revisar algoritmos y técnicas de procesamiento para reducir la carga computacional y mejorar la velocidad de respuesta del sistema. Esto es crucial para aplicaciones en tiempo real, donde la rapidez en la detección de enfermedades es esencial.

La optimización del código también se enfocó en mejorar la precisión del modelo y su capacidad para generalizar patrones.

Esto implicó ajustes en los hiper parámetros del algoritmo de aprendizaje automático, así como la implementación de técnicas de aumento de datos para enriquecer el conjunto de entrenamiento. Un modelo más preciso garantiza resultados confiables y reducción de posibles falsos positivos y negativos. Los conjuntos de datos utilizados para entrenar modelos de aprendizaje automático a menudo presentan desbalances, donde la proporción de imágenes de plantas saludables puede ser significativamente mayor que las infectadas (o viceversa). La optimización del código se centró en técnicas para abordar este desafío, como el uso de

pesos de clase o métodos de re-muestreo, asegurando que el modelo no esté sesgado hacia una categoría dominante.

```

Clase: Healthy
Puntuación de Confianza: 0.9584005
1/1 [=====] - 0s 18ms/step
Clase: Healthy
Puntuación de Confianza: 0.9969055
1/1 [=====] - 0s 17ms/step
Clase: Healthy
Puntuación de Confianza: 0.99971086
1/1 [=====] - 0s 17ms/step
Clase: Healthy
Puntuación de Confianza: 0.9410529
1/1 [=====] - 0s 17ms/step
Clase: Healthy
Puntuación de Confianza: 0.9992034
1/1 [=====] - 0s 16ms/step
Clase: Healthy
Puntuación de Confianza: 0.9999274
1/1 [=====] - 0s 17ms/step
Clase: Healthy
Puntuación de Confianza: 0.9992719
1/1 [=====] - 0s 17ms/step
Clase: Healthy
Puntuación de Confianza: 0.99986553

```

Fig. 2. Resultados de puntuación de confianza.

La optimización del código también se enfocó en mejorar la precisión del modelo y su capacidad para generalizar patrones. Esto implicó ajustes en los hiper parámetros del algoritmo de aprendizaje automático, así como la implementación de técnicas de aumento de datos para enriquecer el conjunto de entrenamiento. Un modelo más preciso garantiza resultados confiables y reducción de posibles falsos positivos y negativos. Los conjuntos de datos utilizados para entrenar modelos de aprendizaje automático a menudo presentan desbalances, donde la proporción de imágenes de plantas saludables puede ser significativamente mayor que las infectadas (o viceversa). La optimización del código se centró en técnicas para abordar este desafío, como el uso de pesos de clase o métodos de remuestreo, asegurando que el modelo no esté sesgado hacia una categoría dominante.

La efectividad del monitor no solo depende de la precisión del modelo, sino también de la facilidad de uso para los agricultores. La optimización del código se extendió a la creación de una interfaz de usuario intuitiva que permitiera a los usuarios interactuar de manera efectiva con el sistema, interpretar los resultados y tomar decisiones informadas.

Las condiciones de iluminación en las imágenes pueden variar significativamente, lo que representa un desafío para el reconocimiento preciso. Estrategias como el ajuste dinámico de la exposición y la normalización de la iluminación fueron implementadas para mejorar la robustez del modelo. La presencia de diversas enfermedades fúngicas requirió una mayor atención a la diversidad del conjunto de datos.

En el ámbito de la agricultura, la detección temprana de enfermedades en plantas es crucial para garantizar cosechas saludables y productivas. Recientemente, hemos llevado a cabo pruebas exhaustivas de un novedoso sistema de monitoreo basado en reconocimiento de imágenes mediante aprendizaje automático. Este sistema utiliza inteligencia artificial para analizar imágenes de plantas y determinar la presencia de enfermedades virales. A continuación, presentamos los resultados detallados en una tabla comparativa que demuestra la efectividad del sistema.

Tabla 2: Comparativa de Resultados para la detección de enfermedad fúngica en plantas.

Pruebas	Saludable	Infectada	Porcentaje de Confianza
Fig. 3	✓	X	95.7%
Fig. 4	X	✓	97.9%
Fig. 5	✓	X	99.3%
Fig. 6	✓	X	99.7%
Fig. 7	X	✓	99.5%

La tabla comparativa refleja la capacidad del sistema de monitoreo basado en reconocimiento de imágenes con aprendizaje automático para detectar la presencia de enfermedades virales en plantas. A pesar de algunos falsos positivos y negativos, la precisión general del sistema es destacable. Estos resultados respaldan la eficacia del enfoque de aprendizaje automático en la identificación temprana de enfermedades en plantas, lo que puede resultar fundamental para la toma de decisiones en la agricultura moderna.

La implementación exitosa de este sistema de monitoreo representa un avance significativo en la agricultura moderna. Aunque la perfección absoluta puede ser difícil de alcanzar, la combinación de inteligencia artificial y la experiencia humana proporciona una herramienta poderosa para mejorar la gestión de enfermedades en los cultivos. Este sistema no solo fortalece la resiliencia de los agricultores ante posibles brotes, sino que también sienta las bases para futuros desarrollos en el campo de la agricultura de precisión.



Fig. 3. Hoja detectada como saludable con un nivel de confianza de 95.7%.



Fig.4. Hoja detectada como infectada con un nivel de confianza de 97.9%.



Fig.5. Hoja detectada como saludable con un nivel de confianza de 99.3%.



Fig.6. Hoja detectada como saludable con un nivel de confianza de 99.7%.

También la optimización del código desempeñó un papel crucial en la transformación del monitor de enfermedades virales en plantas en una herramienta robusta y confiable. Superar los desafíos técnicos no solo mejoró la precisión del modelo, sino que también garantizó su capacidad para adaptarse a diversas situaciones agrícolas, haciendo que el sistema sea una contribución valiosa a la gestión de enfermedades en los cultivos ; Igualmente el entrenamiento con data sets desempeña un papel fundamental en proyectos de inteligencia artificial (AI) que utilizan aprendizaje automático para el reconocimiento de imágenes en el contexto del proyecto la calidad y diversidad del conjunto de datos de entrenamiento tienen un impacto directo en la eficacia y la capacidad del modelo para realizar predicciones precisas. Un conjunto de datos bien diversificado contribuye a la generalización del modelo. La AI no solo aprende a reconocer las imágenes específicas del conjunto de entrenamiento, sino que también adquiere la capacidad de aplicar esos conocimientos a nuevas imágenes no vistas anteriormente. Esto es crucial para enfrentar situaciones del mundo real, donde las condiciones de iluminación, perspectivas y tipos de plantas pueden variar ampliamente. Entrenar con un conjunto de datos representativo ayuda a reducir el sesgo en el modelo. Un sesgo podría surgir si el modelo se entrena solo con un tipo específico de imágenes, lo que limitaría su capacidad para generalizar y detectar enfermedades en diversas situaciones. Un conjunto de datos

equilibrado y diverso contribuye a una mayor precisión en las predicciones.

En resumen, un conjunto de datos bien seleccionado, que incluya imágenes de plantas saludables e infectadas en diversas condiciones, permitirá que la AI aprenda a distinguir patrones específicos asociados a la presencia de enfermedades. Este enfoque contribuirá a la precisión del sistema, permitiendo que los resultados de la detección sean confiables y aplicables en una variedad de situaciones agrícolas. En resumen, la calidad del entrenamiento con *Datasets* es un factor crítico que moldea el rendimiento y la utilidad práctica de las soluciones de aprendizaje automático para el reconocimiento de imágenes.

En las etapas iniciales, el modelo de aprendizaje automático se pudo haber enfrentado dificultades al procesar grandes conjuntos de datos de imágenes de manera eficiente. La magnitud de este desafío se vislumbró en la necesidad de optimizar el código, una tarea que involucró la revisión profunda de algoritmos y técnicas de procesamiento. La celeridad en la detección de enfermedades se vuelve esencial, especialmente en aplicaciones en tiempo real, y la optimización del código surgió como un vehículo para reducir la carga computacional y mejorar la velocidad de respuesta del sistema.

El mundo agrícola no sigue un guion preestablecido; está sujeto a condiciones variables, desde cambios climáticos hasta diferentes patologías de enfermedades virales. La optimización del código no solo consideró la eficiencia del sistema en condiciones controladas, sino que también abordó la necesidad de adaptarse a desafíos del mundo real. Estrategias como el ajuste dinámico de la exposición y la normalización de la iluminación se incorporaron para mejorar la robustez del modelo, asegurando su desempeño incluso en condiciones de iluminación variables.

La optimización del código desempeñó un papel crucial en esta transformación. Superar los desafíos técnicos no solo mejoró la precisión del modelo, sino que también garantizó su capacidad para adaptarse a diversas situaciones agrícolas. Desde la eficiencia en el procesamiento de datos hasta la interfaz de usuario intuitiva, cada mejora contribuyó a un sistema más sólido y práctico. Paralelamente, el entrenamiento con data sets se presentó como otro componente clave. La calidad y diversidad del conjunto de datos de entrenamiento fueron determinantes en la capacidad del modelo para aprender patrones, generalizar conocimientos y ofrecer resultados confiables en diversas situaciones agrícolas. Un conjunto de datos bien seleccionado, equilibrado y diverso permitió a la inteligencia artificial distinguir patrones específicos asociados a la presencia de enfermedades, contribuyendo así a la precisión del sistema. La optimización integral, desde el código hasta

el conjunto de datos, ha transformado nuestro sistema de monitoreo en una herramienta robusta, precisa y adaptable. El impacto en la agricultura moderna va más allá de la simple detección de enfermedades. La combinación de tecnología avanzada, optimización continua y entrenamiento con data sets es esencial para continuar con el progreso en la eficiencia del mundo laboral, así como con las implicaciones para la seguridad alimentaria y la sostenibilidad este enfoque integral no solo aborda la eficiencia técnica y la precisión del modelo, sino que también destaca la adaptabilidad a desafíos agrícolas reales.

Conclusiones, perspectivas y recomendaciones

En conclusión, el proyecto ha alcanzado con éxito el objetivo general de diseñar un sistema de detección para el virus del mosaico del tomate en cultivos de tomate. A través de la implementación de una metodología cuidadosamente planificada, se logró una caracterización efectiva del entorno de estudio, identificando la planta de jitomate y el virus del mosaico del tomate como elementos clave en el proyecto.

La obtención de imágenes para el modelo de aprendizaje automático se llevó a cabo de manera eficiente mediante la recopilación de conjuntos de datos de hojas sanas e infectadas de *Kaggle*. La creación y configuración del modelo en *Teachable Machine*, seguido de su exportación a *TensorFlow*, proporcionaron una herramienta confiable para la clasificación de hojas en el sistema. La integración de hardware y software se logró mediante la selección de una Raspberry Pi 4B y una cámara Raspberry Pi 5MP, respaldada por un código en Python utilizando la biblioteca *picamera2*, esta combinación permitió la captura sistemática de imágenes en intervalos regulares.

El programa en Python para la clasificación y procesamiento de imágenes demostró ser efectivo. Desde la carga del modelo pre entrenado hasta la gestión de carpetas y el procesamiento en tiempo real, el sistema automatizado cumplió su propósito de manera eficiente y precisa.

En cuanto a las perspectivas futuras, se sugiere explorar la optimización continua del modelo de aprendizaje automático y considerar la aplicación del sistema en diversos entornos para evaluar su adaptabilidad. La incorporación de sensores adicionales en la Raspberry Pi podría enriquecer aún más la información recopilada.

Este proyecto, al diseñar un sistema integral y accesible para la detección temprana del virus del mosaico del tomate, representa una contribución significativa al campo de la tecnología aplicada a la agricultura, proporcionando herramientas valiosas para la gestión y protección de los cultivos.

Referencias

1. Universidad Veracruzana (2020, noviembre 14). **Solanum lycopersicum L.** Disponible en: <https://www.uv.mx/herbariocib/2020/11/14/solanumlycopersicuml/#:~:text=La%20flor%20posee%20un%20cáliz,color%20amarillo%3B%20el%20estilo%20de>
2. Instituto Nacional de Estadística y Geografía (2019). **Superficie sembrada o plantada por cultivo.** Disponible en: <https://www.inegi.org.mx/temas/agricultura/>
3. Universidad Autónoma del Estado de Puebla (2019, mayo 15). **Puebla ocupa el 7º lugar a nivel nacional en producción de jitomate.** Disponible en: <https://upaep.mx/colaboradores/boletin/comunicados/3491-puebla-ocupa-el-7º-lugar-a-nivel-nacional-en-producción-de-jitomate>
4. Laterrot H. y Pecaut. P. (1969). Gene Trn-2: new source. Report of the Tomato Genetics Cooperative 19: 13-14.
5. Gooding, G. (1975). **Inactivation of Tomato mosaic virus on tomato seed with trisodium orthophosphate and sodium hypochlorite.** Plant Disease Reporter 59, 770-772.
6. García, E., & Flego, F. (2008). **Agricultura de precisión.** Revista Ciencia y Tecnología, 8, 99-116Gallager R. G.