
Agricultura de precisión: Diseño e implementación de prototipo de central de monitoreo y control de condiciones ambientales en cultivos de mango

Diego Ernesto Aldana Pérez



UNIVERSIDAD DEL VALLE DE GUATEMALA
Facultad de Ingeniería



**Agricultura de precisión: Diseño e implementación de
prototipo de central de monitoreo y control de condiciones
ambientales en cultivos de mango**

Trabajo de graduación presentado por Diego Ernesto Aldana Pérez para
optar al grado académico de Licenciado en Ingeniería Mecatrónica

Guatemala,

2024

UNIVERSIDAD DEL VALLE DE GUATEMALA
Facultad de Ingeniería




**Agricultura de precisión: Diseño e implementación de
prototipo de central de monitoreo y control de condiciones
ambientales en cultivos de mango**

Trabajo de graduación presentado por Diego Ernesto Aldana Pérez para
optar al grado académico de Licenciado en Ingeniería Mecatrónica


Guatemala,


2024

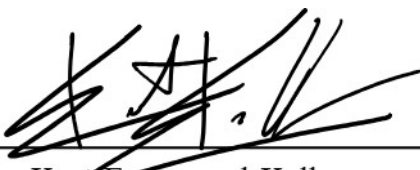
Vo.Bo.:

(f) 
M. Sc. Carlos Esquit

Tribunal Examinador:

(f) 
M.Sc. Carlos Esquit

(f) 
M. Sc. Miguel Enrique Zea Arenales

(f) 
Ing. Kurt Emmanuel Kellner

Fecha de aprobación: Guatemala, 13 de febrero de 2025.

La agricultura, como pilar fundamental de la sociedad, se encuentra en constante evolución, adaptándose a los desafíos de un mundo en cambio. Este trabajo surge de la necesidad de integrar tecnología y sostenibilidad en la producción agrícola, demostrando cómo herramientas de precisión pueden optimizar cultivos y transformar prácticas tradicionales. Durante el desarrollo de esta tesis, he aprendido valiosas lecciones no solo en el ámbito técnico, sino también sobre la importancia del trabajo constante, la dedicación y el apoyo de quienes me rodean.

Este logro no habría sido posible sin el apoyo incondicional de muchas personas que han sido pilares fundamentales en mi vida. En primer lugar, quiero expresar mi más profundo agradecimiento a mis padres y abuelos, quienes con su amor, esfuerzo y sabiduría me han guiado y apoyado en cada paso del camino. A mis hermanas y al resto de mi familia, quienes siempre han sido mi red de seguridad y aliento. A mis amigos, por ser compañeros invaluable que han compartido conmigo los momentos de alegría y los desafíos de este viaje.

Asimismo, quiero extender mi gratitud a todos mis profesores, quienes con su guía, paciencia y conocimientos, me han brindado las herramientas necesarias para llegar hasta aquí. Sus enseñanzas han dejado una marca indeleble en mi formación y en mi crecimiento personal y profesional. un agradecimiento especial a Dios, por darme la oportunidad de llegar a este punto de mi vida. Su fuerza y guía han sido fundamentales en este proceso, permitiéndome superar los obstáculos y encontrar propósito en cada paso del camino.

Este trabajo representa el esfuerzo conjunto de muchas personas y la culminación de un sueño que sería imposible sin el apoyo, el amor y la fe que todos me han brindado.

| | |
|--|------|
| Prefacio | III |
| Lista de figuras | VIII |
| Lista de cuadros | IX |
| Resumen | X |
| Abstract | XI |
| 1. Introducción | 1 |
| 2. Antecedentes | 3 |
| 3. Justificación | 10 |
| 4. Objetivos | 11 |
| 4.1. Objetivo general | 11 |
| 4.2. Objetivos específicos | 11 |
| 5. Alcance | 12 |
| 6. Marco teórico | 13 |
| 6.1. Gestión basada en agricultura de precisión | 13 |
| 6.2. Factores intercampo en la producción de mango | 13 |
| 6.2.1. Temperatura | 14 |
| 6.2.2. Humedad en el suelo | 14 |
| 6.2.3. Suelos y pH | 14 |
| 6.2.4. Luminosidad | 14 |
| 6.2.5. Precipitaciones | 15 |
| 6.3. Sensores de campo | 15 |
| 6.3.1. Microcontrolador ESP32 | 15 |
| 6.3.2. Sensor de humedad en suelo YL-69 | 16 |
| 6.3.3. Sensor de pH analógico Surveyor™ | 17 |

| | |
|---|-----------|
| 6.3.4. Sensor de temperatura y humedad relativa DHT11 | 18 |
| 6.4. Inteligencia Artificial aplicada a patrones de enfermedades foliares | 19 |
| 6.4.1. Redes neuronales y su aplicación en la agricultura | 19 |
| 6.4.2. Arquitectura de redes neuronales convolucionales | 20 |
| 6.4.3. Herramientas para la implementación de CNN | 21 |
| 6.5. Enfermedades foliares en plantaciones de mango | 21 |
| 6.5.1. Antracnosis | 21 |
| 6.5.2. Cancro bacteriano | 22 |
| 6.5.3. Gorgojo cortador de hojas | 23 |
| 6.5.4. Mosquito de las agallas | 24 |
| 6.5.5. Secadera del mango | 26 |
| 6.5.6. Mildiu polvoriento | 27 |
| 6.5.7. Fumagina | 27 |
| 7. Diseño de una plataforma para el monitoreo y control de parámetros ambientales en plantaciones de mango | 29 |
| 7.1. Especificaciones técnicas | 29 |
| 7.2. Criterios de diseño | 30 |
| 7.3. Selección de materiales | 31 |
| 7.4. Diseño conceptual | 31 |
| 7.5. Desarrollo de la estructura | 31 |
| 8. Sistema de detección cualitativo de enfermedades en hojas de mango | 35 |
| 8.1. Configuración de Kaggle y Google Colab: Manejo de base de datos | 36 |
| 8.1.1. Obtención de las imágenes para la clasificación | 36 |
| 8.1.2. Importación de datos a Google Colab desde Kaggle | 36 |
| 8.1.3. Procesamiento de los datos | 37 |
| 8.1.4. Distribución de los datos | 38 |
| 8.2. Configuración del modelo | 40 |
| 8.2.1. Preentrenamiento de la red neuronal | 40 |
| 8.2.2. Estructura del modelo de clasificación | 40 |
| 8.2.3. Optimización y ajuste del modelo | 40 |
| 8.2.4. Optimización | 41 |
| 8.2.5. Evaluación del modelo | 41 |
| 8.3. Entrenamiento y validación | 41 |
| 8.3.1. Estrategias de regularización | 41 |
| 8.4. Resultados del entrenamiento | 42 |
| 8.4.1. Evolución de la pérdida | 42 |
| 8.4.2. Evolución de la precisión | 43 |
| 8.5. Prueba del modelo | 43 |
| 8.6. Guardado e implementación del modelo | 44 |
| 8.6.1. Integración en la interfaz web | 44 |
| 9. Conexión de componentes y funcionamiento del microcontrolador como servidor web | 46 |
| 9.1. Conexión de los sensores al ESP32 | 46 |
| 9.2. Funcionamiento del ESP32 como servidor web | 47 |
| 9.2.1. Recopilación y procesamiento de datos | 47 |

| | |
|--|-----------|
| 9.2.2. Transmisión de datos en tiempo real | 48 |
| 9.3. Interfaz web para la visualización de datos | 48 |
| 9.4. Flujo de información del sistema | 48 |
| 9.5. Conclusión | 49 |
| 10. Implementación de interfaces gráfica para el monitoreo y diagnóstico en cultivos de mango | 50 |
| 10.1. Interfaz para el monitoreo de factores ambientales | 50 |
| 10.1.1. Conexión en tiempo real con WebSocket | 50 |
| 10.1.2. Estética y diseño | 51 |
| 10.2. Interfaz para la detección de enfermedades foliares | 52 |
| 10.2.1. Integración de TensorFlow.js para diagnóstico | 52 |
| 10.2.2. Estética y diseño | 53 |
| 10.3. Interconexión y flujo de trabajo entre interfaces | 53 |
| 10.4. Impacto en la experiencia del usuario | 53 |
| 11. Conclusiones | 55 |
| 12. Recomendaciones | 56 |
| 13. Bibliografía | 57 |
| 14. Anexos | 60 |
| 14.1. Repositorio de código red neuronal para la clasificación de enfermedades foliares | 60 |

Lista de figuras

| | |
|---|----|
| 1. Evolución tecnológica en la agricultura | 4 |
| 2. IoT en agricultura inteligente | 6 |
| 3. Uso de GIS para el control de cantidad de clorofila en las regiones de cultivo [4] | 7 |
| 4. Esquema de central de monitoreo de cultivo utilizado por Z. Cheng-Ju [5] | 8 |
| 5. Microcontrolador ESP32 | 16 |
| 6. Sensor de humedad en suelo YL-69 | 17 |
| 7. Kit para medición de pH en agua | 18 |
| 8. Sensor de humedad DHT11 | 19 |
| 9. Flujo de datos para la clasificación de una CNN [16] | 21 |
| 10. Antracnosis en hoja de mango | 22 |
| 11. Tabla de sintomatología de antracnosis observada en distintas variedades de mango | 22 |
| 12. Cancro bacteriano | 23 |
| 13. Efectos del gorgojo en hojas de mango | 24 |
| 14. Mosquito de las agallas del mango | 25 |
| 15. Síntomas de secadera en mango | 26 |
| 16. Síntomas de mildiu polvoriento en mango | 27 |
| 17. Síntomas de fumagina en mango | 28 |
| 18. Diseño y distribución de estructura | 30 |
| 19. Diseño de la estructura en Inventor | 32 |
| 20. Ejemplo de pruebas en MDF | 33 |
| 21. Estructura en su estado final | 34 |
| 22. Diagrama de flujo de creación de red neuronal para clasificación de enfermedades foliares | 35 |
| 23. Base de datos de 7 enfermedades foliares y el control | 36 |
| 24. Diagrama de flujo carga de información desde Kaggle a Google Colab | 37 |
| 25. Distribución de las imágenes entre el conjunto de entrenamiento y validación | 38 |
| 26. Ejemplo de imágenes generadas mediante el proceso de aumento de datos | 39 |
| 27. Esquema de la arquitectura del modelo | 41 |
| 28. Evolución de la pérdida durante el entrenamiento y validación. | 42 |

| | |
|--|----|
| 29. Evolución de la precisión en el conjunto de entrenamiento y validación. | 43 |
| 30. Resultados de la clasificación del modelo en datos de prueba. | 44 |
| 31. Esquema de conexión de los sensores al microcontrolador ESP32. | 47 |
| 32. Diagrama del flujo de información del sistema. | 49 |
| 33. Diagrama de estructura de interfaz | 51 |
| 34. Interfaz de monitoreo de datos ambientales en vista de escritorio | 52 |
| 35. Interfaz de detección de enfermedades foliares en vista de dispositivo móvil | 54 |

Lista de cuadros

| | |
|---|----|
| 1. Esquema de rango de temperatura para cultivo de mango en cada etapa. . . . | 14 |
| 2. Esquema de rango de aptitud climática y factores. | 15 |

La agricultura en Guatemala enfrenta desafíos significativos debido a la limitada implementación de tecnología moderna en el sector. Este proyecto desarrolla una central de monitoreo de precisión diseñada específicamente para plantaciones de mango, integrando sensores ambientales avanzados y un sistema de diagnóstico foliar basado en inteligencia artificial. La solución consta de dos interfaces principales: la primera, dedicada a la recolección de datos ambientales, utiliza un microcontrolador ESP32 que recopila información en tiempo real sobre temperatura, humedad relativa, pH del suelo, luz y humedad ambiental. Este microcontrolador actúa como un servidor web, permitiendo que los agricultores accedan a una interfaz intuitiva desde dispositivos conectados a la misma red local.

La segunda interfaz, enfocada en el diagnóstico de enfermedades foliares, utiliza una red neuronal convolucional para analizar imágenes de hojas de mango y detectar la presencia de siete posibles patologías, además de hojas saludables. Este análisis se realiza en el navegador mediante TensorFlow.js, asegurando una integración rápida y accesible. Ambas interfaces están interconectadas, proporcionando una visión integral del estado del cultivo al presentar los datos ambientales junto con el diagnóstico foliar en tiempo real.

Esta solución permite a los agricultores tomar decisiones informadas y optimizar el manejo del cultivo al conectar factores críticos del entorno con la salud del follaje. El proyecto demuestra la viabilidad de implementar tecnologías avanzadas en la agricultura local, fomentando la adopción de prácticas de precisión que mejoran la sostenibilidad, la eficiencia y la productividad en el sector agrícola.

Agriculture in Guatemala faces significant challenges due to the limited adoption of modern technology in the sector. This project develops a precision monitoring hub specifically designed for mango plantations, integrating advanced environmental sensors and a foliar diagnostic system powered by artificial intelligence. The solution comprises two main interfaces: the first focuses on environmental data collection, using an ESP32 microcontroller to gather real-time information on temperature, relative humidity, soil pH, light, and air moisture. The microcontroller acts as a web server, enabling farmers to access an intuitive interface from devices connected to the same local network.

The second interface, dedicated to foliar disease diagnosis, employs a convolutional neural network to analyze mango leaf images and identify seven potential diseases, along with healthy leaves. This analysis is conducted in the browser using TensorFlow.js, ensuring quick and accessible integration. Both interfaces are interconnected, offering a comprehensive view of the crop's status by presenting environmental data alongside real-time foliar diagnostics.

This solution empowers farmers to make informed decisions and optimize crop management by linking critical environmental factors with foliar health. The project demonstrates the feasibility of implementing advanced technologies in local agriculture, promoting the adoption of precision practices that enhance sustainability, efficiency, and productivity in agricultural production.

La agricultura en Guatemala enfrenta retos significativos derivados de la falta de implementación de tecnologías modernas, lo que limita la productividad y sostenibilidad del sector agrícola. Este problema afecta particularmente a cultivos como el mango, donde la gestión de variables ambientales y la detección temprana de enfermedades foliares son determinantes para garantizar la calidad y cantidad de la producción.

En el contexto actual, la agricultura de precisión surge como una solución innovadora que combina sensores, redes de comunicación y herramientas de inteligencia artificial para optimizar el manejo de los cultivos. Este enfoque no solo permite un monitoreo constante de las condiciones ambientales, sino también la identificación temprana de problemas que podrían comprometer la productividad. Además, ofrece la posibilidad de tomar decisiones basadas en datos en tiempo real, mejorando así la eficiencia en el manejo de recursos como agua, fertilizantes y pesticidas.

El presente trabajo tiene como objetivo principal desarrollar una central de monitoreo de precisión para plantaciones de mango, integrando dos componentes principales: una interfaz para la recolección de datos ambientales en campo y una interfaz de diagnóstico foliar basada en inteligencia artificial. La primera interfaz, accesible a través de una red local proporcionada por un microcontrolador ESP32, permite a los agricultores obtener información en tiempo real sobre variables como temperatura, humedad, luz, pH del suelo y humedad ambiental. Por otro lado, la segunda interfaz utiliza una red neuronal convolucional para analizar imágenes foliares capturadas con un dispositivo móvil, detectando de manera eficiente la presencia de enfermedades.

Ambas interfaces trabajan de manera complementaria, conectando factores ambientales y de salud foliar en un solo sistema. Este enfoque integral busca mejorar la toma de decisiones en el manejo del cultivo, reduciendo pérdidas y optimizando recursos. A través de este proyecto, se demuestra la viabilidad y el impacto positivo que la agricultura de precisión puede tener en un contexto local, promoviendo prácticas agrícolas sostenibles y más competitivas.

A lo largo de este documento, se detallan los fundamentos teóricos, el diseño del sistema, las pruebas realizadas y los resultados obtenidos, con el objetivo de establecer una base sólida para futuras investigaciones y aplicaciones en la agricultura de precisión en Guatemala.

La agricultura de precisión presenta un enfoque innovador y altamente efectivo para maximizar el rendimiento agrícola, minimizar la variabilidad y optimizar la gestión de recursos. Esta metodología permite un monitoreo detallado de factores clave, como la humedad del suelo, la salud de los cultivos y la calidad del terreno, lo que ayuda a los agricultores a comprender mejor las variaciones en el rendimiento de los cultivos. Al reducir la variabilidad de estos factores, la agricultura de precisión permite una toma de decisiones más informada y oportuna, lo que conduce a una mejora significativa en la productividad y la rentabilidad de las operaciones agrícolas. Además, al optimizar el uso de insumos como agua, fertilizantes y pesticidas, esta metodología también promueve la sostenibilidad ambiental al reducir el desperdicio y minimizar el impacto negativo en los ecosistemas circundantes.

1. Inteligencia Artificial e Internet de las Cosas para una agricultura sostenible e inteligente

La agricultura ha enfrentado desafíos cada vez mayores para satisfacer las demandas de una población mundial en constante crecimiento, el cambio climático y la presión sobre los recursos naturales.

En respuesta a estas presiones, ha surgido un interés creciente en la aplicación de tecnologías modernas, como la Inteligencia Artificial (IA) y el Internet de las Cosas (IoT), para mejorar la eficiencia y sostenibilidad de la agricultura. Investigaciones previas realizadas por A. A. AlZubi y K. Galynao, han destacado el potencial de las tecnologías digitales, incluida la IoT, para abordar los desafíos de sostenibilidad en la agricultura [1]. Estos estudios señalan que la IoT puede contribuir a objetivos económicos, ambientales y sociales sostenibles al permitir el monitoreo y gestión eficiente de los recursos agrícolas. Sin embargo, también han identificado obstáculos como la falta de investigación y desarrollo en Agricultura Sostenible Inteligente (SSA), así como la complejidad en la gestión de datos y la dificultad de comunicación entre plataformas de desarrollo de inteligencia artificial y los dispositivos e interfaces del IoT.

A pesar de los obstáculos, se ha observado un aumento en la adopción de tecnologías como drones, sensores y análisis de datos en la agricultura. Estas tecnologías están transformando la agricultura al proporcionar información detallada sobre las condiciones del suelo, el clima y la salud de los cultivos, lo que permite una toma de decisiones más informada y eficiente por parte de los agricultores.

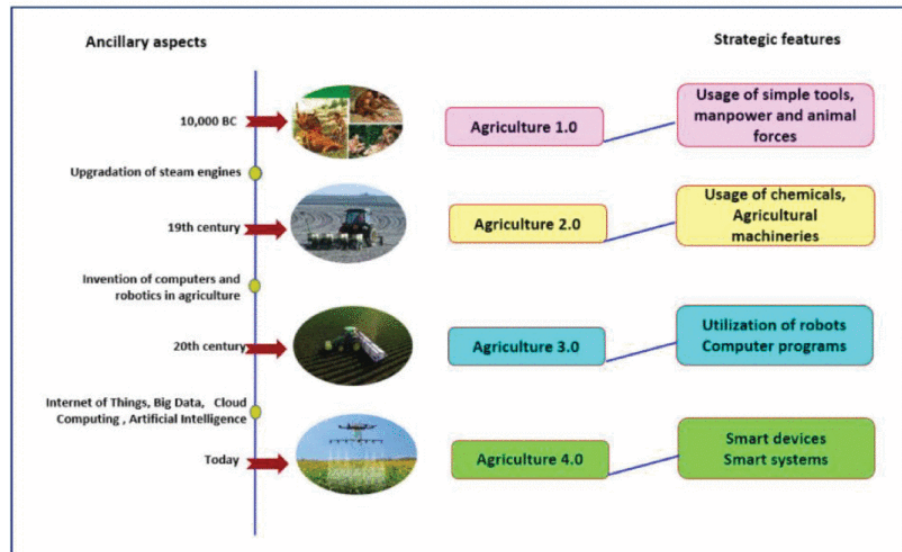


Figura 1: Evolución tecnológica en la agricultura

2. Una revisión completa de las técnicas de visión por computadora asistidas por aprendizaje profundo para la agricultura inteligente en invernaderos

El uso de invernaderos en la agricultura, conocido como Agricultura de Ambiente Controlado (CEA por sus siglas en inglés), ha sido una práctica poderosa en la agricultura moderna. Los invernaderos no son una innovación reciente, ya que se empezaron a utilizar en el siglo XIX en Países Bajos y Francia; su tecnología ha evolucionado significativamente desde entonces. En el artículo escrito por J. U. M. Akbar, S. F. Kamarulzaman, A. J. M. Muzahid, M. A. Rahman y M. Uddin [2] se destaca que una de las principales ventajas de los invernaderos: la capacidad de manipular parámetros ambientales como la temperatura, la intensidad lumínica, la humedad y los niveles de nutrientes, adaptándolos a las necesidades específicas de los cultivos. Esto permite un control preciso y personalizado del entorno de crecimiento de las plantas, lo que resulta en un aumento de la productividad y una mejora en la calidad de los cultivos.

La gestión y el mantenimiento de los invernaderos pueden ser tareas que demandan una considerable cantidad de recursos. Ajustar las condiciones ambientales para alcanzar un rango óptimo que favorezca el crecimiento de diferentes cultivos puede resultar un desafío complejo, ya que requiere un control preciso y constante de variables como la temperatura, la humedad, la luz y la ventilación. Es en este contexto donde entran en juego los invernaderos inteligentes, equipados con tecnología de Internet de las Cosas (IoT).

Estos invernaderos integran sensores y controladores embebidos que recopilan datos en

tiempo real y los transmiten a un servidor en la nube. El sistema puede realizar ajustes automáticos en función de estos datos, minimizando la intervención humana, reduciendo la carga de trabajo para los agricultores y optimizando el uso de recursos como agua y energía. Los invernaderos inteligentes ofrecen una regulación automática de factores críticos como la temperatura, la luz y el riego, así como el control sobre otras operaciones mecánicas. Además de la automatización de las condiciones ambientales, los invernaderos inteligentes proporcionan a los agricultores información valiosa sobre los momentos más adecuados para la cosecha, la calidad del suelo, los requisitos de nutrientes para las plantas y la calidad del agua, lo que reduce la carga de trabajo para los agricultores y optimiza el uso de recursos como agua y energía. Este enfoque basado en datos permite una toma de decisiones más informada, lo que hace que la agricultura sea más fiable y rentable. La agricultura actual ya aprovecha el potencial de la inteligencia artificial (IA) y la visión por computadora para transformar los invernaderos en entornos altamente automatizados y precisos. Estas tecnologías permiten analizar grandes volúmenes de datos en tiempo real, prever necesidades específicas y realizar ajustes detallados en factores como temperatura, humedad e iluminación.

Gracias a la visión por computadora, los sistemas monitorean constantemente el crecimiento de las plantas, detectan enfermedades en etapas tempranas y determinan el momento óptimo para la cosecha. Esto no solo mejora la eficiencia operativa, sino que también permite una gestión proactiva que minimiza pérdidas y maximiza la productividad de los cultivos. La combinación de IA y visión por computadora está redefiniendo la agricultura, llevando la sostenibilidad y la precisión a nuevos niveles.

En resumen, la combinación de la agricultura de invernadero con IoT, IA y visión por computadora está inaugurando una nueva era de agricultura eficiente y basada en datos, transformando el invernadero tradicional en uno de regulación autónoma y altamente eficiente.

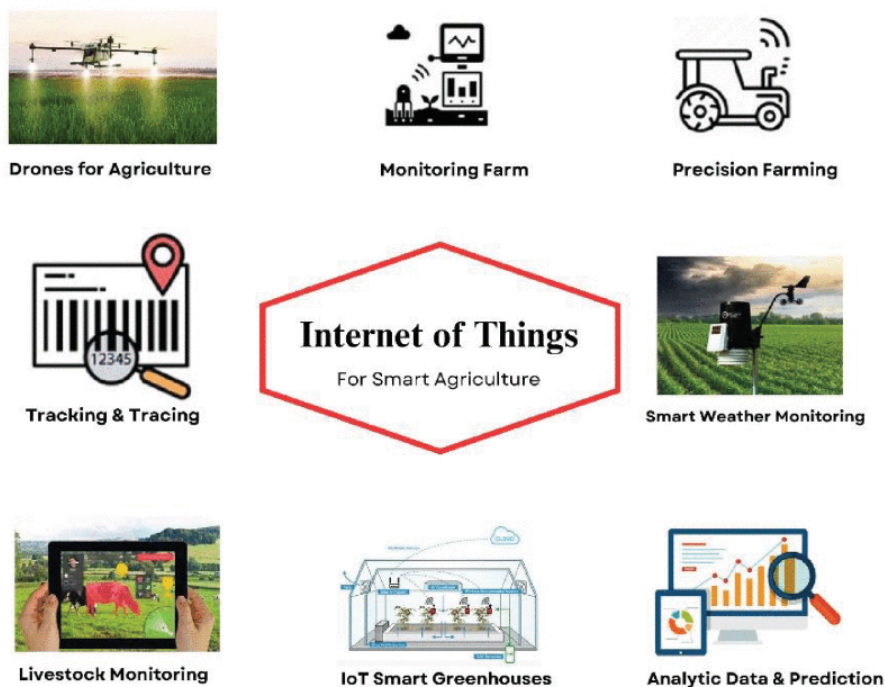


Figura 2: IoT en agricultura inteligente

3. Investigación sobre la aplicación de la agricultura inteligente en la gestión de la producción de algodón

La aplicación de la agricultura inteligente ha surgido como una solución prometedora para mejorar la eficiencia y la sostenibilidad en la producción agrícola. Uno de los sectores donde se ha observado un cambio notable es en la industria del algodón. Anteriormente, la producción de algodón se basaba en métodos tradicionales como riego y aplicaciones de pesticidas programados sin consideración a las condiciones ambientales, que a menudo no eran óptimos para enfrentar los desafíos actuales y futuros. Sin embargo, con el avance de la tecnología, se ha reconocido la necesidad de adoptar enfoques más inteligentes y sofisticados para garantizar la productividad y la rentabilidad en este sector clave de la economía. El trabajo desarrollado por Y. Wang y Y. Yang [3] resalta la importancia de la agricultura inteligente en la gestión de la producción de algodón, integrando diversas tecnologías avanzadas para optimizar procesos y mejorar la calidad del producto final. Entre las tecnologías clave, se destaca la inteligencia artificial, utilizada para identificar características de las plantas y construir sistemas de detección de enfermedades. Además, el uso de Big Data permite la integración de información relacionada con el entorno agrícola, los cultivos y las actividades humanas, lo que facilita un análisis eficiente y preciso para operaciones agrícolas inteligentes.

El estudio también incluye tecnologías como la computación en la nube, los Sistemas de Información Geográfica (SIG) y los Sistemas Expertos (ES), que procesan grandes volúmenes de datos y apoyan la toma de decisiones informadas. Asimismo, la tecnología del Internet de las Cosas (IoT) juega un papel fundamental al habilitar el monitoreo, la observación sistemática y la medición de los rasgos fenotípicos de las plantas de algodón en entornos

agrícolas específicos y en momentos determinados.

Estos rasgos fenotípicos incluyen características como la altura de las plantas, el número de ramas, el tamaño y el color de las hojas, y el desarrollo de las cápsulas de semillas. La recopilación y análisis de estos datos no solo optimiza los procesos agrícolas, sino que también mejora la toma de decisiones estratégicas, garantizando una gestión más eficiente y la producción de algodón de alta calidad.

A pesar de los avances significativos, aún existen desafíos en la adopción generalizada de la agricultura inteligente en la producción de algodón. Estos incluyen la necesidad de infraestructura adecuada, la capacitación de personal especializado y la resolución de problemas de implementación a nivel práctico.




Figura 3: Uso de GIS para el control de cantidad de clorofila en las regiones de cultivo [4]

4. Investigación e implementación de monitoreo ambiental agrícola basado en Internet de las Cosas

En el contexto de la modernización agrícola y el creciente interés en la implementación de tecnologías avanzadas, el estudio sobre sistemas de monitoreo del entorno agrícola basados en Internet de las Cosas (IoT) ha ganado relevancia significativa. La necesidad de sistemas eficientes y de bajo costo que puedan recolectar datos ambientales en tiempo real para mejorar la producción agrícola son visibles en este informe de Zou Cheng-jun, publicado en la Quinta Conferencia Internacional sobre Diseño de Sistemas Inteligentes y Aplicaciones de Ingeniería en 2014 [5]. Se destacan las limitaciones de los sistemas existentes, como el alto costo de construcción de redes y la complejidad operativa, y propone un marco de trabajo basado en IoT que aborda estas deficiencias. Ofrece un enfoque integral que combina diseño de hardware y software para desarrollar un sistema de monitoreo del entorno agrícola altamente eficiente y escalable. El sistema propuesto consta de tres capas: percepción, construcción de red y aplicación. En la capa de percepción, se utilizan sensores específicos para recolectar datos ambientales, como temperatura, humedad y niveles de luz. Estos sensores están conectados a un microcontrolador, como el Arduino UNO o el ESP32, que gestiona la adquisición de datos y su procesamiento inicial. La construcción de red se realiza mediante tecnologías de comunicación inalámbrica, como ZigBee o LoRa, que permiten la transmisión de datos de los sensores a una unidad central de procesamiento. Por último, la capa de aplicación se encarga de procesar los datos recibidos y presentarlos de manera comprensible para el usuario final, posiblemente a través de una plataforma web o una aplicación móvil. Las pruebas experimentales realizadas demuestran la viabilidad y efectividad del sistema propuesto en términos de recolección de datos precisos y consumo de energía reducido. Este trabajo proporciona una base sólida para futuras investigaciones en el campo de la agricultura de precisión y la aplicación de tecnologías IoT en entornos agrícolas.

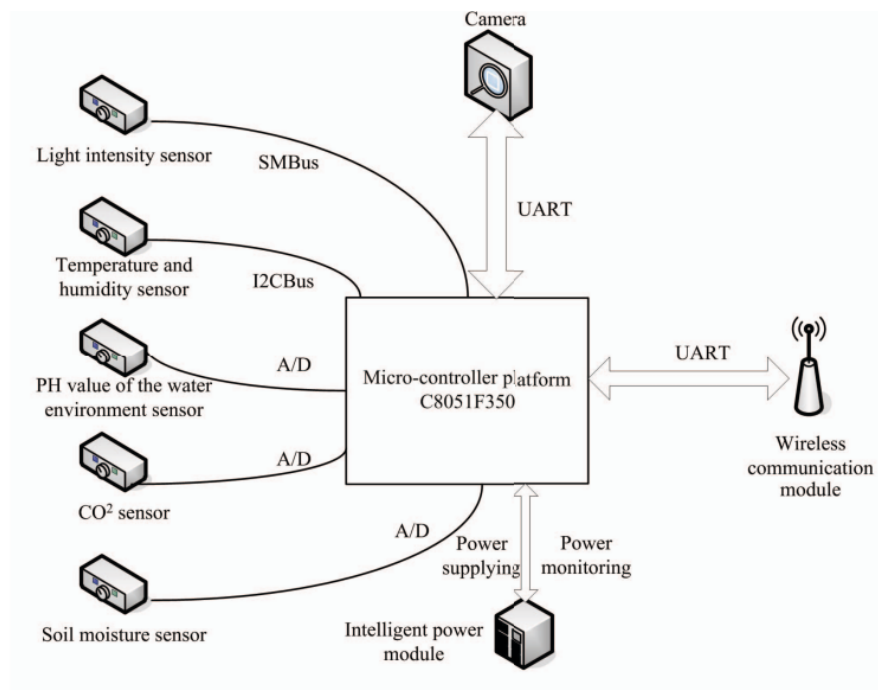


Figura 4: Esquema de central de monitoreo de cultivo utilizado por Z. Cheng-Ju [5]

Considerando la importancia y las limitaciones identificadas en el estudio previo, esta tesis se propone diseñar, implementar y evaluar un sistema de monitoreo del entorno agrícola basado en IoT con un enfoque específico en la eficiencia energética, la escalabilidad y la accesibilidad de los datos. Mediante el desarrollo de este sistema, se busca contribuir al avance de la agricultura moderna y proporcionar herramientas prácticas para mejorar la producción agrícola y la gestión del medio ambiente.

En la actualidad, Guatemala se caracteriza por su dependencia del sector agrícola, el cual representa uno de los principales motores de la economía nacional debido a su significativa contribución al producto interno bruto [6]. Sin embargo, el cambio climático está ejerciendo una creciente presión sobre este sector, alterando los ciclos de preparación, crecimiento y producción de cultivos. Factores como frentes fríos, lluvias extremas y sequías están modificando los patrones meteorológicos, lo que, a su vez, afecta directamente las condiciones de temperatura, luminosidad y humedad. Estas variaciones propician la propagación acelerada de plagas y enfermedades, representando una amenaza constante para la productividad agrícola [7].

Ante estos retos, se vuelve imperativo adoptar herramientas de agricultura de precisión que apoyen la toma de decisiones informadas mediante el uso de tecnologías avanzadas y sostenibles. Estas herramientas, diseñadas para ser climáticamente inteligentes, tienen el potencial de reducir la vulnerabilidad del sector agrícola frente a cambios bruscos en las condiciones ambientales, mientras optimizan la productividad y eficiencia en el manejo de los recursos. Estudios recientes destacan cómo la implementación de estas tecnologías mejora significativamente los procesos relacionados con el control de plagas, la nutrición de los cultivos, la planificación de la siembra y la recolección, reduciendo tiempos y costos, y asegurando decisiones fundamentadas [5].

La creación de una central de monitoreo para las plantaciones de mango representa un avance importante hacia la modernización del sector agrícola en Guatemala. Este sistema permitirá reemplazar prácticas rudimentarias y tradicionales con métodos más precisos y eficientes, mejorando tanto la productividad como la sostenibilidad del cultivo. Además, proporcionará una herramienta clave para enfrentar los desafíos que el cambio climático impone a la agricultura del país, fortaleciendo la resiliencia del sector frente a estas nuevas realidades.

4.1. Objetivo general

Desarrollo de una plataforma para el monitoreo y control de parámetros ambientales en plantaciones de mango.

4.2. Objetivos específicos

- Diseño de plataforma de prueba para la recolección de datos ambientales.
- Desarrollar una red neuronal capaz de procesar imágenes de hojas de mango y determinar si presenta alguna enfermedad foliar.
- Implementación de una interfaz gráfica amigable al uso operativo de un agricultor para la interpretación de la información de campo y estado del follaje.
- Comunicación de datos entre la plataforma en campo con la interfaz visible por el usuario.

El presente proyecto tiene como objetivo diseñar, desarrollar e implementar una solución tecnológica integral que permita optimizar la producción de cultivos de mango en Guatemala mediante herramientas de monitoreo ambiental y diagnóstico foliar. Se desarrolló una central de monitoreo que, a través del uso de sensores especializados y un microcontrolador ESP32, recopila parámetros clave como la temperatura, la humedad del aire y del suelo, el nivel de pH y la intensidad lumínica. Esta información es procesada y presentada en tiempo real mediante una interfaz web accesible y amigable, diseñada específicamente para agricultores.

El sistema también incorpora una interfaz adicional que permite analizar el estado del follaje del cultivo utilizando un modelo de red neuronal convolucional. Este modelo, integrado mediante TensorFlow.js, diagnostica automáticamente enfermedades foliares a partir de imágenes capturadas por los usuarios, brindando recomendaciones claras para su manejo. Ambas interfaces trabajan de manera interconectada, integrando información ambiental y de salud foliar para ofrecer una visión completa del estado del cultivo.

El proyecto comprende el diseño y desarrollo tanto del hardware como del software, incluyendo la configuración de los sensores y del microcontrolador ESP32 como servidor web, así como el diseño de las interfaces gráficas en tecnologías HTML, CSS y JavaScript. Además, se implementó un sistema de comunicación en tiempo real mediante el protocolo WebSocket, lo que permite la actualización constante de los datos. Por otro lado, el modelo de inteligencia artificial fue entrenado para identificar enfermedades comunes en plantaciones de mango, y se validó en condiciones controladas que simulan escenarios reales.

Si bien la solución está enfocada en el monitoreo de factores ambientales y el diagnóstico foliar en cultivos de mango, su arquitectura modular y escalable permite futuras adaptaciones a otros tipos de cultivos. Este proyecto no solo busca mejorar la toma de decisiones de los agricultores al proporcionar información precisa y oportuna, sino también fomentar la adopción de tecnologías de agricultura de precisión en Guatemala, promoviendo así la sostenibilidad, la resiliencia y la eficiencia en el sector agrícola.

6.1. Gestión basada en agricultura de precisión

La implementación de un sistema de monitoreo en una plantación de mango representa una estrategia fundamental en la adopción de la agricultura de precisión, con el objetivo primordial de optimizar la producción y mejorar la gestión agrícola. La naturaleza tropical y subtropical del cultivo de mango implica la influencia de múltiples factores ambientales, como la temperatura, humedad relativa, luminosidad y calidad del suelo, que pueden tener un impacto significativo en el crecimiento, desarrollo y rendimiento de los árboles. Al emplear tecnologías de monitoreo avanzadas, tales como sensores remotos, los agricultores pueden recopilar datos en tiempo real sobre estas variables ambientales clave, permitiendo una evaluación precisa de las condiciones del cultivo en diferentes áreas de la plantación. Esta información detallada y actualizada brinda la base para la toma de decisiones informadas, facilitando la aplicación de prácticas agrícolas específicas y ajustadas a las necesidades de cada zona de la plantación. Además, el monitoreo continuo y la recopilación de datos a lo largo del ciclo de cultivo permiten identificar patrones de crecimiento, detectar anomalías tempranas y prevenir problemas potenciales, como estrés hídrico, deficiencias nutricionales o ataques de plagas y enfermedades. En última instancia, la implementación de un sistema de monitoreo en una plantación de mango no solo contribuye a optimizar la producción y mejorar la calidad de los frutos, sino que también promueve una gestión más eficiente de los recursos naturales y una agricultura más sostenible y resiliente a largo plazo.

6.2. Factores intercampo en la producción de mango

Parte esencial de la agricultura de precisión es el enfoque en las herramientas de recolección de datos. Las plantaciones de mango dependen de diversos factores para la optimización en la producción. Entre los principales factores que afectan la calidad y producción del fruto se encuentran:

6.2.1. Temperatura

El mango crece principalmente en regiones de clima tropical, caracterizado por temperaturas altas durante todo el año y estaciones húmedas y secas, y en zonas de clima subtropical, donde las temperaturas son cálidas pero con mayor variación estacional, debido a su alta sensibilidad al frío, lo que limita su desarrollo en áreas con temperaturas bajas. El mango repite de manera cíclica tres etapas: De vegetación donde el árbol aumenta su follaje, de floración cuando el árbol se prepara para reproducirse y empieza el proceso de crecimiento del fruto y finalmente la etapa de maduración del fruto en la que los esfuerzos de la planta se ven concentrados en la producción frutal. Para cada una de estas etapas existen parámetros de temperatura ideales visibles en el Cuadro [1](#),[8](#)

| Etapa | Crecimiento mínimo | Óptimo | Máximo |
|------------------|--------------------|-----------|--------|
| Vegetativo | 18 °C | 25 °C | 35 °C |
| Floración | 12 °C | 25 °C | 35 °C |
| Maduración | 20 °C | 25 °C | 30 °C |
| Inducción floral | | 10°C-15°C | |

Cuadro 1: Esquema de rango de temperatura para cultivo de mango en cada etapa.

6.2.2. Humedad en el suelo

Respecto a la humedad promedio en suelo, depende de la ubicación geográfica. en plantaciones subtropicales en zonas áridas, la más adecuada para el cultivo del mango debe ser menor del 75 %, considerando que el 100 % es cuando el suelo está totalmente saturado de agua en estado líquido. Este control de un suelo con una humedad controlada, reduce la presencia de enfermedades ocasionadas por hongos [9](#). Si bien el mango soporta bien la falta de humedad, se recomienda que esta no disminuya del 50 %, ya que la falta de agua puede generar una reducción en el tamaño del fruto.

6.2.3. Suelos y pH

Los suelos ideales para el cultivo del mango son aquellos de textura limosa, profundos y con una capa mínima de 75 cm de profundidad, aunque lo ideal serían suelos de 1 a 1,5 m de profundidad y un pH entre 5,5 y 7,0. Puede desarrollarse bien en suelos arenosos, ácidos o alcalinos moderados, siempre y cuando se fertilicen adecuadamente. [8](#)

6.2.4. Luminosidad

El mango no depende de las diferencias en la cantidad de horas de luz por día para la diferenciación floral; sin embargo, requiere una buena luminosidad para su crecimiento, desarrollo reproductivo y rendimiento óptimo. Es poco tolerante a la sombra, y los frutos que reciben más luz desarrollan un mejor color en comparación con aquellos que están menos expuestos. Un fotoperíodo ideal para el cultivo del mango es de 11 a 12.5 horas diarias de luz directa. [10](#).

6.2.5. Precipitaciones

El cultivo del mango requiere precipitaciones medias anuales de alrededor de 1000 mm, lo que proporciona la cantidad de agua necesaria para satisfacer sus necesidades hídricas durante las etapas de crecimiento y desarrollo. Sin embargo, es fundamental que estas lluvias estén bien distribuidas a lo largo del año, asegurando que no causen saturación de agua en el suelo, lo cual podría perjudicar las raíces y limitar la absorción de nutrientes.

Además de la cantidad de lluvia, el mango necesita un tiempo de sequía marcado. Esta fase es crucial, ya que promueve la inducción floral, favoreciendo la producción de flores y, posteriormente, de frutos. La ausencia de este periodo seco puede alterar el ciclo natural de la planta, reduciendo su capacidad de florecer y afectando el rendimiento del cultivo. [11]

| Variable de aptitud | Apto | Moderado | No apto |
|-------------------------------|-----------|-----------|------------|
| pH | 5.5-7.0 | | <4.5, >7.5 |
| Precipitación anual en mm | 1000-2500 | 2500-3000 | +3000 |
| Quincenas secas | 8-12 | 6-8 | -6 |
| Humedad relativa porcentual | 60-80 | 80-85 | +85 |
| Brillo solar en horas diarias | 6-8 | 4-6 | -4 |

Cuadro 2: Esquema de rango de aptitud climática y factores.

6.3. Sensores de campo

Los sensores de campo son componentes fundamentales en la agricultura de precisión, al permitir el monitoreo constante y la gestión eficiente de los recursos y las condiciones ambientales que afectan el crecimiento de los cultivos. Estos dispositivos recopilan información en tiempo real sobre variables críticas como la humedad del suelo, la temperatura atmosférica, la intensidad lumínica, el pH y los niveles de nutrientes presentes en el suelo. Dicha información es procesada y utilizada para facilitar la toma de decisiones basadas en datos, lo que permite optimizar el uso de insumos esenciales, como agua, fertilizantes y pesticidas, de manera más precisa y eficiente.

6.3.1. Microcontrolador ESP32

En este contexto, los microcontroladores juegan un papel fundamental al proporcionar la capacidad de controlar, procesar y comunicar información de manera autónoma. Uno de los microcontroladores más destacados en este ámbito es el ESP32, un dispositivo altamente versátil y potente que ofrece una amplia gama de funcionalidades para aplicaciones de monitoreo agrícola.

El ESP32 es una plataforma de desarrollo de bajo costo basada en un microcontrolador de doble núcleo y arquitectura Xtensa LX6 de Espressif Systems. Por un lado, cuenta con múltiples entradas analógicas de alta precisión. En su forma estándar, cuenta con 18 pines de entrada/salida (I/O) que pueden utilizarse como entradas analógicas. Sin embargo, es importante tener en cuenta que no todos estos pines están disponibles para entradas analógicas

en todas las placas de desarrollo del ESP32, ya que algunos pines pueden estar reservados para funciones específicas o tener limitaciones en su capacidad de entrada analógica. En general, la mayoría de las placas de desarrollo del ESP32 ofrecen al menos 10 pines que pueden utilizarse como entradas analógicas. Esto le permite leer sensores de temperatura, humedad del suelo, niveles de luz y otros parámetros ambientales de manera simultánea y precisa. Esto es crucial para obtener una visión completa y detallada de las condiciones de crecimiento en diferentes áreas de la plantación. [12]




Figura 5: Microcontrolador ESP32

Además, el ESP32 tiene capacidades avanzadas de comunicación. Esta capacidad es especialmente beneficiosa en entornos agrícolas, donde las plantaciones pueden abarcar áreas extensas y remotas.

6.3.2. Sensor de humedad en suelo YL-69

El sensor YL-69 emplea dos electrodos que transmiten corriente a través del suelo, donde la resistencia entre los electrodos varía según la humedad del suelo. En un suelo muy húmedo, la resistencia es baja (circuito cerrado), mientras que en un suelo muy seco, la resistencia es alta (circuito abierto).

Los electrodos están conectados a una tarjeta de acondicionamiento (YL-38), que utiliza un amplificador operacional (OpAmp) en modo comparador para proporcionar tanto una salida digital como una analógica. La salida digital se activa cuando el nivel de humedad es inferior al deseado, nivel que puede ajustarse mediante un potenciómetro en la tarjeta. La salida analógica proporciona un voltaje que varía de 0V en suelos muy húmedos a 5V en suelos muy secos.

Este sensor es ideal para monitorear la humedad del suelo en plantas, recordando cuándo necesitan riego o incluso para implementar un sistema de riego totalmente automatizado. [13]




Figura 6: Sensor de humedad en suelo YL-69

6.3.3. Sensor de pH analógico Surveyor™

El sensor de pH Surveyor™ es un dispositivo diseñado para garantizar mediciones precisas del pH en soluciones líquidas, siendo especialmente útil en el ámbito agrícola. Este sensor combina una sonda de pH analógica altamente compatible con un módulo acondicionador de señal que traduce las lecturas analógicas en señales continuas y fácilmente interpretables. Su diseño compacto, de 54 x 32 mm y con un peso de 15 gramos, permite su integración en sistemas agrícolas modernos, incluso en aquellos con restricciones de espacio.

Opera en un rango de medición de 0.1 a 14.0 pH, con una resolución de 0.1 pH y una precisión de ± 0.2 pH. Su alimentación, que varía entre 3.3V y 5.5V, lo hace adaptable a diversas fuentes de energía, incluidas baterías y sistemas renovables utilizados en áreas rurales. La salida de señal analógica, en un rango de 2.7V a 0.2V, asegura un monitoreo continuo y en tiempo real, lo que lo hace ideal para sistemas de control automatizados.

En el ámbito agrícola, el sensor se utiliza principalmente para monitorear el pH del agua destinada al riego, garantizando condiciones óptimas para la disponibilidad de nutrientes en el suelo. Un pH incorrecto puede bloquear nutrientes esenciales o provocar toxicidad para los cultivos. Este dispositivo también es fundamental en sistemas hidropónicos, donde la solución nutritiva debe mantenerse en un equilibrio químico ideal para maximizar la absorción de nutrientes y el crecimiento de las plantas. En la agricultura de precisión, este se integra fácilmente con sistemas de monitoreo automatizado, lo que permite realizar ajustes en tiempo real a los niveles de pH según las necesidades específicas del cultivo, optimizando así el uso de recursos como agua y fertilizantes.

Otra aplicación importante del sensor es en el control de calidad del agua. Permite verificar que las fuentes utilizadas para riego cumplan con los estándares necesarios para evitar daños en los cultivos. Además, se emplea en el monitoreo ambiental de cuerpos de agua cercanos a zonas agrícolas, asegurando un manejo responsable de los recursos hídricos.

y minimizando impactos negativos en los ecosistemas.

El funcionamiento del sensor está optimizado mediante un circuito de amplificación que mejora la precisión de las mediciones y reduce el ruido de la señal, lo que garantiza datos confiables incluso en entornos desafiantes. Su diseño robusto lo hace resistente a condiciones extremas, como altas temperaturas y humedad, asegurando un rendimiento constante en el campo. La compatibilidad universal con cualquier sonda de pH y su facilidad de instalación lo convierten en una herramienta versátil y esencial para la agricultura moderna, mejorando la productividad y sostenibilidad de las prácticas agrícolas. [14]



Figura 7: Kit para medición de pH en agua

6.3.4. Sensor de temperatura y humedad relativa DHT11

El sensor DHT11 es un dispositivo ampliamente utilizado para medir la temperatura y la humedad ambiental. Este sensor combina un termistor y un sensor capacitivo de humedad para proporcionar lecturas precisas de ambas variables. El DHT11 opera en un rango de voltaje de 3.5V a 5.5V, lo que lo hace compatible con una amplia gama de sistemas electrónicos.

Tiene un rango de medición de humedad del 20 % al 90 % de humedad relativa (RH), con un error de medición de $\pm 5\%$ RH y una resolución de 1 % RH. En cuanto a la temperatura, puede medir en un rango de 0°C a 50°C , con un error de medición de $\pm 2^{\circ}\text{C}$ y una resolución de 1°C . La transmisión de señal del DHT11 puede alcanzar hasta 20 metros, lo que permite su uso en aplicaciones donde la distancia entre el sensor y el controlador es considerable. Sus dimensiones compactas de 19 mm x 17 mm x 19 mm y su peso de 3 gramos facilitan su integración en diversos dispositivos y sistemas.

Es ideal para aplicaciones en sistemas de climatización, monitoreo ambiental y proyectos de automatización del hogar. Su capacidad para medir tanto la temperatura como la humedad lo hace indispensable en situaciones donde es crucial mantener condiciones ambientales

específicas. En sistemas de cultivo, por ejemplo, el control de la humedad y la temperatura es vital para garantizar el crecimiento óptimo de las plantas.

De igual forma proporciona datos digitales que pueden ser fácilmente interpretados por microcontroladores y sistemas de control. La comunicación con el sensor se realiza a través de una única línea de datos, lo que simplifica el diseño del circuito y reduce la cantidad de cables necesarios. [15]




Figura 8: Sensor de humedad DHT11

6.4. Inteligencia Artificial aplicada a patrones de enfermedades foliares

El manejo integrado de plagas y enfermedades en los cultivos requiere información precisa acerca de la incidencia y severidad de las enfermedades, así como de las poblaciones de insectos asociadas. Esta información se recopila mediante métodos de monitoreo diseñados para identificar patrones que permitan tomar decisiones fundamentadas sobre cómo, cuándo y dónde implementar estrategias de control. Para optimizar este monitoreo, se han desarrollado herramientas basadas en inteligencia artificial, como las redes neuronales convolucionales (CNN), las cuales procesan grandes volúmenes de datos y automatizan la identificación de patrones en las hojas de las plantas, facilitando el diagnóstico de enfermedades de manera eficiente.

6.4.1. Redes neuronales y su aplicación en la agricultura

Una red neuronal es un modelo computacional inspirado en el sistema nervioso biológico. Está compuesta por una red de nodos interconectados denominados neuronas artificiales, las cuales procesan datos mediante cálculos iterativos. El aprendizaje en estas redes ocurre a través de la adaptación de los pesos de las conexiones entre las neuronas, ajustándolos en función de los datos procesados. Este ajuste permite a la red identificar patrones en los datos

de entrada y generar respuestas específicas, como clasificar una hoja de planta como sana o enferma.

Las redes neuronales convolucionales (CNN) representan una especialización dentro de las redes neuronales, enfocada en el procesamiento de datos en formato de matriz, como imágenes. Estas redes son ampliamente utilizadas en tareas de visión por computadora debido a su capacidad para extraer automáticamente características relevantes de las imágenes de entrada. Este enfoque permite que las CNN sean particularmente efectivas en la detección de patrones complejos en hojas, como aquellos asociados a enfermedades foliares.

6.4.2. Arquitectura de redes neuronales convolucionales

Las redes neuronales convolucionales están compuestas por diferentes tipos de capas que trabajan en conjunto para procesar y clasificar los datos de entrada. Las principales capas que conforman una CNN son:

1. **Capas convolucionales:** Estas capas aplican filtros (matrices de valores numéricos) sobre las imágenes de entrada para detectar patrones locales, como bordes, texturas y formas. Los resultados de estas operaciones, denominados mapas de características, resaltan las áreas de la imagen donde se encuentran dichos patrones.

2. **Capas de submuestreo o agrupación (pooling):** Estas capas reducen la dimensionalidad de los mapas de características generados por las capas convolucionales, disminuyendo la cantidad de parámetros y preservando las características más importantes. Un método común es el max-pooling, que selecciona el valor más alto en un área específica del mapa.

3. **Capas totalmente conectadas:** En estas capas, cada nodo está conectado con todos los nodos de la capa anterior. Este diseño permite que la red combine las características extraídas en las capas previas y realice la clasificación final, asignando la imagen a una categoría específica, como sana o enferma.

Además de estas capas principales, las CNN incluyen funciones de activación no lineales, como ReLU (Rectified Linear Unit), que introducen no linealidad en el modelo, permitiendo que aprenda patrones complejos de los datos. Las capas de activación se intercalan entre las capas convolucionales y totalmente conectadas para optimizar el aprendizaje del modelo.

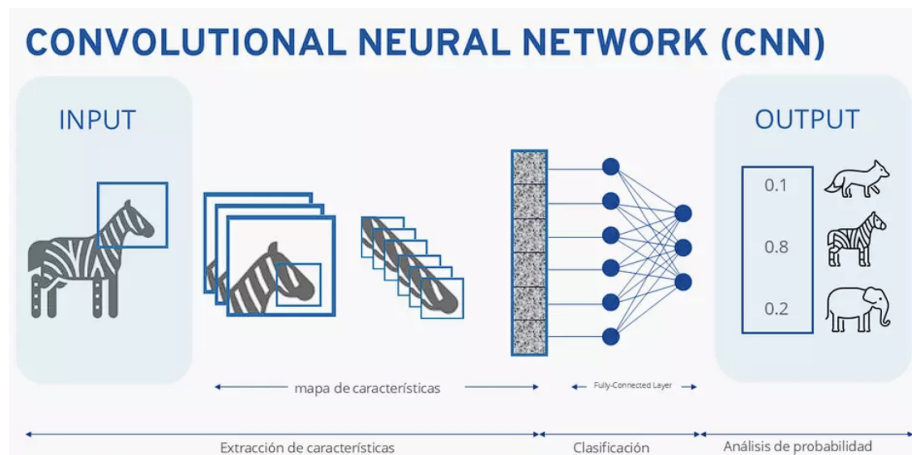


Figura 9: Flujo de datos para la clasificación de una CNN [16]

6.4.3. Herramientas para la implementación de CNN

Para desarrollar redes neuronales convolucionales aplicadas a la agricultura, se utilizan herramientas como TensorFlow, una biblioteca de código abierto desarrollada por Google. TensorFlow permite crear y entrenar modelos de aprendizaje profundo de manera eficiente. Su API TensorFlow Keras simplifica la construcción de redes neuronales, mientras que TensorFlow Estimator facilita el entrenamiento de modelos en entornos distribuidos y paralelos.

Con estas herramientas, es posible procesar grandes bases de datos de imágenes de hojas, entrenar modelos de CNN para identificar patrones de enfermedades y desplegarlos en sistemas agrícolas automatizados. La implementación de este tipo de tecnología en el monitoreo de cultivos mejora significativamente la precisión y eficiencia en la detección temprana de enfermedades foliares. [17]

Además de las capas convolucionales y de submuestreo, las CNN suelen incluir capas de activación no lineales, como ReLU (Rectified Linear Unit), y capas totalmente conectadas al final de la red para realizar la clasificación final. [18]

6.5. Enfermedades foliares en plantaciones de mango

6.5.1. Antracnosis

La antracnosis es una enfermedad fúngica que afecta a diversas plantas, incluyendo el mango, y es causada principalmente por hongos del género *Colletotrichum*, cuyo teleomorfo es *Glomerella*. Esta enfermedad es una de las más devastadoras para el cultivo del mango, generando daños significativos en hojas, flores y frutos, lo que puede afectar tanto la calidad como el rendimiento de la producción. [19]

En las hojas de mango, la antracnosis se manifiesta por la aparición de manchas irregulares de color pardo oscuro o negro, a menudo rodeadas por un halo amarillento. Estas



Figura 10: Antracnosis en hoja de mango

manchas pueden coalescer, provocando la necrosis del tejido y la caída prematura de las hojas. Además, las condiciones de alta humedad favorecen la diseminación de los esporangios del hongo, lo que agrava la severidad de la infección. En fases avanzadas, las hojas afectadas se secan y deforman, lo que compromete la capacidad fotosintética del árbol y, en consecuencia, su vigor.

La capacidad de la antracnosis para infectar diferentes partes del mango y su propagación rápida bajo condiciones favorables la convierte en una de las principales preocupaciones en el manejo sanitario de este cultivo.

| Aislado | Origen | Variedad | Sintomatología observada |
|---------|-------------|-------------|--|
| 1 | Jaruco | Haden | Hojas jóvenes con manchas de forma irregular, color marrón cenizo en la punta y margen, manifestándose enzimamientos aparentando quemaduras. Formación en la parte posterior de las manchas de excrecencias amarillentas en condiciones de alta humedad. |
| 2 | | | |
| 3 | | | |
| 4 | | | |
| 5 | | | |
| 6 | Bizcochuelo | | Manchas irregulares de color marrón claro del ápice a la base de la hoja. |
| 7 | | | |
| 8 | | | |
| 9 | Alquízar | Delicioso | Manchas angulosas de color marrón oscuro a café claro, desde el borde hacia el centro de la hoja sin alcanzar los nervios. |
| 10 | | | |
| 11 | | | |
| 12 | | | |
| 13 | San Diego | | Manchas circulares de forma más o menos regular, color carmelita cenizo en el centro y una franja carmelita oscura. |
| 14 | | | |
| 15 | Jaruco | Haden | Hojas jóvenes con manchas de forma irregular, color marrón cenizo en la punta y margen, manifestándose enzimamientos aparentando quemaduras. Formación en la parte posterior de las manchas de excrecencias amarillentas en condiciones de alta humedad. |
| 16 | | | |
| 17 | Alquízar | Delicioso | Manchas angulosas de color marrón oscuro a café claro, desde el borde hacia el centro de la hoja sin alcanzar los nervios. |
| 18 | | | |
| 19 | Alquízar | Señora | Manchas grandes y regulares de color marrón cenizo en la punta y margen de hojas nuevas del brote vegetativo. |
| 20 | Escambray | Mango macho | Manchas de color marrón en el fruto con hendiduras en el centro. |
| 21 | Alquízar | Señora | Manchas pequeñas, circulares de diámetro de 3 a 4 mm con una franja de color marrón oscuro en el borde y el centro amarillo en los brotes nuevos. |
| 22 | | | |
| | | | Manchas circulares de 5 a 6 mm de diámetro en hojas nuevas, de color marrón con centro más oscuro. |

Figura 11: Tabla de sintomatología de antracnosis observada en distintas variedades de mango

6.5.2. Cancro bacteriano

El cancro bacteriano, también conocido como mancha negra bacteriana, es una enfermedad que afecta al mango y es causada por la bacteria *Xanthomonas axonopodis* pv. *mangiferae*.

raeindicae. Esta patología es de gran importancia debido a los daños que ocasiona en hojas, ramas y frutos, impactando negativamente en la calidad y el rendimiento de la producción.

En las hojas de mango, el cancro bacteriano se manifiesta inicialmente como pequeñas manchas acuosas que evolucionan a lesiones negras y angulares, siguiendo a menudo la venación de la hoja. Estas lesiones pueden estar rodeadas por un halo clorótico (amarillento) y, en condiciones de alta humedad, pueden exudar una sustancia bacteriana viscosa. A medida que la enfermedad avanza, las manchas pueden coalescer, formando áreas necróticas más extensas que conducen a la defoliación prematura. La pérdida de hojas reduce la capacidad fotosintética del árbol, debilitándolo y afectando su productividad.

La propagación de esta enfermedad se ve favorecida por condiciones de alta humedad y temperaturas cálidas, siendo la lluvia y el viento los principales agentes de dispersión de la bacteria. La implementación de prácticas culturales adecuadas y el uso de tratamientos fito-sanitarios específicos son esenciales para el manejo efectivo del cancro bacteriano en cultivos de mango. [20]



Figura 12: Cancro bacteriano

6.5.3. Gorgojo cortador de hojas

El gorgojo cortador de hojas, científicamente conocido como *Deporaus marginatus*, es un insecto que afecta principalmente a los cultivos de mango. Este coleóptero es reconocido por su capacidad para causar daños significativos en las hojas jóvenes, lo que puede comprometer la salud y productividad del árbol.

Las hembras de *Deporaus marginatus* depositan sus huevos en las hojas tiernas del mango. Posteriormente, cortan la hoja cerca del pecíolo, lo que provoca que caiga al suelo. Las larvas emergen y se desarrollan dentro de estas hojas caídas, completando su ciclo de vida en el suelo. Este comportamiento resulta en una defoliación notable, especialmente en brotes jóvenes, lo que reduce la capacidad fotosintética del árbol y, en consecuencia, su vigor y rendimiento.

La presencia del gorgojo cortador de hojas se identifica por la caída de hojas jóvenes con cortes característicos en la base. Además, se pueden observar daños en las hojas remanentes, como perforaciones y áreas masticadas. La infestación severa puede llevar a una reducción en la producción de frutos y afectar la calidad de los mismos.

El manejo de esta plaga incluye prácticas culturales como la recolección y destrucción de hojas caídas para interrumpir el ciclo de vida del insecto. Además, se recomienda la aplicación de insecticidas específicos en momentos clave del desarrollo del gorgojo para minimizar su impacto en el cultivo.^[21]



Figura 13: Efectos del gorgojo en hojas de mango

6.5.4. Mosquito de las agallas

El mosquito de las agallas del mango, conocido científicamente como *Procontarinia marteiana*, es un insecto que causa daños significativos en los cultivos de mango. Este díptero afecta en su mayoría a hojas jóvenes, induciendo la formación de agallas, lo que compromete la salud y productividad de los árboles.

Las hembras de *Procontarinia matteiana* depositan sus huevos en la superficie inferior de las hojas tiernas. Cuando las larvas emergen, penetran en el tejido foliar, alimentándose de este y provocando la formación de agallas características. Estas estructuras se presentan como protuberancias en las hojas que inicialmente son de color verde claro y, con el tiempo, se vuelven marrones. Dependiendo del nivel de infestación, estas agallas pueden deformar severamente las hojas, reduciendo su capacidad fotosintética y, en casos extremos, causando la defoliación prematura.

La infestación por mosquito de las agallas se identifica observando estas deformaciones, así como perforaciones en la superficie inferior de las hojas, que corresponden a los puntos de entrada y salida de las larvas. Una infestación severa puede llevar a una disminución significativa en la producción de frutos y a una reducción de su calidad.

El manejo de esta plaga incluye la poda y destrucción de las partes afectadas del árbol para disminuir la población del insecto. Además, la aplicación de insecticidas específicos en etapas clave del ciclo de vida del mosquito es esencial para reducir su impacto. El uso de estrategias integradas de manejo de plagas, que combinen prácticas culturales y control químico, es crucial para controlar eficazmente a esta plaga y mitigar los daños en el cultivo de mango. [22]



Figura 14: Mosquito de las agallas del mango

6.5.5. Secadera del mango

La secadera del mango, conocida en inglés como *dieback*, es una enfermedad fúngica que afecta a los árboles de mango, causada principalmente por especies del género *Lasiodiplodia*, como *Lasiodiplodia theobromae*. Esta enfermedad es de gran relevancia debido a los daños que ocasiona en ramas, hojas y frutos, afectando considerablemente la calidad y el rendimiento de la producción.

Los síntomas iniciales de la secadera incluyen el marchitamiento y secado de las puntas de las ramas, progresando hacia la base. Las hojas afectadas muestran decoloración, volviéndose amarillas o marrones, y eventualmente caen prematuramente. En etapas avanzadas, se observa la muerte regresiva de ramas enteras, acompañada de exudación de goma en las áreas afectadas. La corteza puede presentar lesiones necróticas y, en casos severos, el árbol completo puede morir.

La propagación de esta enfermedad se ve favorecida por condiciones de alta humedad y temperaturas cálidas. Las esporas del hongo se diseminan a través del viento, la lluvia y herramientas contaminadas. Las prácticas culturales inadecuadas, como la poda incorrecta o el estrés hídrico, pueden predisponer a los árboles a la infección.

El manejo de la secadera del mango incluye prácticas culturales como la poda y destrucción de las partes afectadas para reducir la fuente de inóculo. Además, se recomienda la aplicación de fungicidas específicos en momentos clave del ciclo de vida del hongo para minimizar su impacto en el cultivo. La implementación de estrategias de manejo integrado de enfermedades es esencial para controlar eficazmente la secadera y mitigar los daños asociados. [23]



Figura 15: Síntomas de secadera en mango

6.5.6. Mildiu polvoriento

El mildiu polvoriento, también conocido como oídio, es una enfermedad fúngica que afecta a diversas plantas, incluyendo el mango. Esta patología es causada por el hongo *Oidium mangiferae*, que se manifiesta principalmente en hojas, flores y frutos jóvenes, comprometiendo la salud y productividad del árbol.

Los síntomas iniciales del mildiu polvoriento incluyen la aparición de un recubrimiento blanco o grisáceo similar al polvo en la superficie de las hojas, brotes y flores. Este micelio fúngico puede provocar deformaciones en las hojas, que se tornan amarillentas y, en casos severos, caen prematuramente. Las inflorescencias afectadas pueden sufrir necrosis, lo que resulta en una reducción significativa de la fructificación. Los frutos jóvenes infectados pueden presentar manchas superficiales y deformaciones, afectando su desarrollo y calidad.

La propagación de esta enfermedad se ve favorecida por condiciones de alta humedad y temperaturas moderadas. Las esporas del hongo se diseminan a través del viento, la lluvia y herramientas contaminadas. Las prácticas culturales inadecuadas, como la poda incorrecta o el estrés hídrico, pueden predisponer a los árboles a la infección.

El manejo del mildiu polvoriento incluye prácticas culturales como la poda y destrucción de las partes afectadas para reducir la fuente de inóculo. Además, se recomienda la aplicación de fungicidas específicos en momentos clave del ciclo de vida del hongo para minimizar su impacto en el cultivo. La implementación de estrategias de manejo integrado de enfermedades es esencial para controlar eficazmente el mildiu polvoriento y mitigar los daños asociados. [24](#)



Figura 16: Síntomas de mildiu polvoriento en mango

6.5.7. Fumagina

La fumagina, también conocida como negrilla, es una enfermedad fúngica que afecta a diversas plantas, incluyendo el mango. Esta patología es causada por hongos saprófitos,

principalmente del género *Capnodium*, que crecen sobre la superficie de las hojas, ramas y frutos, formando una capa negra y hollinosa.

Los síntomas de la fumagina se manifiestan como un recubrimiento negro en las partes afectadas de la planta, resultado del crecimiento del micelio y esporas del hongo. Aunque la fumagina no penetra en los tejidos vegetales ni se alimenta directamente de la planta, su presencia puede interferir con la fotosíntesis al bloquear la luz solar, lo que debilita al árbol y reduce su productividad. Además, la apariencia oscura y sucia de los frutos disminuye su valor comercial.

La fumagina se desarrolla sobre la melaza excretada por insectos chupadores como pulgones, cochinillas y moscas blancas. Por lo tanto, la presencia de estos insectos es un factor predisponente para la aparición de la enfermedad. Condiciones de alta humedad y poca ventilación favorecen el crecimiento del hongo.

El manejo de la fumagina se centra en el control de las poblaciones de insectos productores de melaza mediante el uso de insecticidas adecuados y prácticas culturales que promuevan la salud del árbol. La limpieza de las partes afectadas y la mejora de la circulación de aire en el dosel del árbol también contribuyen a reducir la incidencia de la enfermedad. 25



Figura 17: Síntomas de fumagina en mango

Diseño de una plataforma para el monitoreo y control de parámetros ambientales en plantaciones de mango

En este capítulo se detalla el proceso desarrollado para el diseño y construcción de una estructura funcional, orientada al monitoreo eficiente de las condiciones ambientales. Para garantizar un desempeño óptimo, se estableció la necesidad de separar físicamente los componentes electrónicos del área de medición, con el objetivo de minimizar interferencias, proteger los elementos sensibles y asegurar la integridad de los datos recolectados.

El diseño de esta estructura respondió a criterios técnicos que priorizan la modularidad, facilidad de montaje y adaptabilidad a diferentes entornos de uso. A lo largo del capítulo, se describen las etapas del desarrollo, desde la conceptualización inicial hasta la implementación final, incluyendo las decisiones de diseño, materiales seleccionados y la integración del sistema electrónico con los dispositivos de medición.

7.1. Especificaciones técnicas

El diseño del sistema se fundamenta en la integración de sensores de monitoreo precisos, una distribución espacial optimizada y materiales cuidadosamente seleccionados para garantizar funcionalidad, adaptabilidad y durabilidad. Las variables monitorizadas incluyen luz, pH del agua, temperatura ambiental, humedad ambiental y humedad del suelo, todas ellas esenciales para el correcto manejo del sistema y el desarrollo del cultivo.

La luz, como uno de los factores más críticos para el crecimiento de las plantas, se mide utilizando un sensor que registra la intensidad lumínica en lux. Este sensor se ubica en una posición estratégica que recibe iluminación directa, evitando obstrucciones que puedan comprometer la calidad de las lecturas. El pH del agua, otro parámetro clave, es monitoreado mediante un sensor sumergido en un depósito lateral. Este depósito está diseñado para

facilitar la calibración del sensor y prevenir derrames que puedan afectar el sistema. La temperatura ambiental es medida mediante un sensor ubicado en un área protegida de fuentes de calor externas y corrientes de aire que podrían alterar las mediciones. La humedad relativa del ambiente es controlada por un sensor situado en un punto central del espacio de cultivo, lo que asegura mediciones precisas al minimizar interferencias externas. Finalmente, la humedad del suelo es monitoreada con un sensor especializado, resistente a la corrosión, que se instala en un ángulo que optimiza el contacto con el medio.

En cuanto a los componentes electrónicos, el microcontrolador actúa como el núcleo del sistema. Este dispositivo integra un procesador de datos y un módulo Wi-Fi que permite la transmisión en tiempo real de las lecturas hacia una interfaz web. Para protegerlo de condiciones adversas, el microcontrolador está instalado en un compartimento aislado de la humedad. Los módulos de comunicación están diseñados para operar con estabilidad en entornos con diferentes niveles de interferencia, garantizando una conexión confiable siempre y cuando exista una red a la cual conectarse desde el microcontrolador.

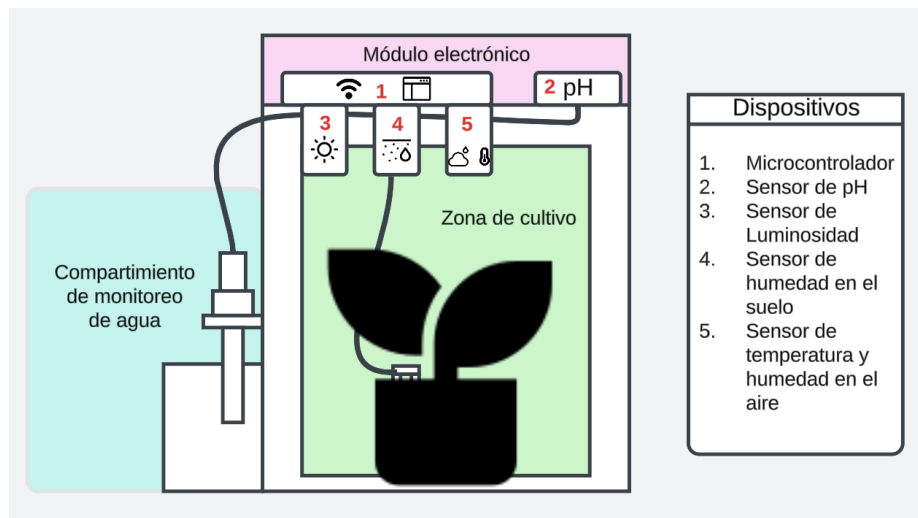


Figura 18: Diseño y distribución de estructura

7.2. Criterios de diseño

El diseño estructural se fundamentó en principios que aseguran la funcionalidad, adaptabilidad y durabilidad del sistema. La modularidad fue uno de los criterios centrales, permitiendo que cada componente pueda ser desmontado y reemplazado de manera sencilla. Esto permite la integración de sensores adicionales y la calibración periódica. Este enfoque facilita el mantenimiento periódico y permite futuras actualizaciones. La estabilidad de la estructura se logra mediante una base cuadrada que distribuye uniformemente el peso, minimizando riesgos de vuelco o desplazamiento accidental.

7.3. Selección de materiales

La selección de materiales fue fundamental para garantizar la funcionalidad y durabilidad del sistema. El acrílico se utilizó como material base debido a su alta resistencia mecánica, ligereza y transparencia. Estas propiedades permiten una inspección visual directa de los componentes internos sin necesidad de desmontar la estructura, mejorando tanto la funcionalidad como la estética. El acrílico también es resistente a la humedad y a variaciones ambientales, características que lo hacen ideal para entornos donde la condensación y el agua son comunes.

Para sellar las uniones, se utilizó silicona impermeable específica para acrílicos. Este material asegura un sellado hermético y duradero, protegiendo los componentes electrónicos de posibles filtraciones. Además, la silicona transparente mantiene la estética del diseño, permitiendo un acabado limpio y profesional. El uso de tecnología de corte láser fue clave para garantizar precisión en las piezas, reduciendo el tiempo de ensamblaje y el desperdicio de material.

7.4. Diseño conceptual

El diseño conceptual fue desarrollado inicialmente en software de diseño CAD de Autodesk *Inventor*, donde se modelaron las especificaciones técnicas y se optimizó la disposición interna de los componentes. El sistema se dividió en tres áreas principales: la parte superior, destinada a la electrónica; la parte inferior, dedicada al cultivo de la planta y a los sensores de luz y humedad del suelo; y un compartimento lateral para el depósito de agua con el sensor de pH. Este modelo permitió detallar rutas de cables, asegurar la ventilación adecuada en áreas electrónicas y optimizar el espacio para el mantenimiento.

La configuración rectangular de cada módulo fue seleccionada por la eficiencia del espacio operativo que proporciona en cada uno de los sectores del sistema. Las piezas fueron diseñadas con un grosor de 3 mm, compatible con las placas de acrílico utilizadas, lo que permitió un corte preciso mediante la cortadora láser.

Tras el diseño digital, se construyó un prototipo físico en MDF para validar la funcionalidad antes de proceder a la fabricación en acrílico. Este prototipo permitió identificar ajustes necesarios, como ampliar ciertas aperturas para facilitar el acceso a los componentes, y confirmar la estabilidad de la estructura.

7.5. Desarrollo de la estructura

La fabricación final en acrílico siguió las especificaciones del diseño conceptual, integrando las mejoras identificadas en el prototipo.

En el acabado final de la estructura se dejaron los bordes de cada una de las caras con un patrón rectangular para encajar cada una de estas con el fin de evitar la instalación de tornillos, lo que simplificó el armado y garantizó la estabilidad estructural. La tapa removible




Figura 19: Diseño de la estructura en Inventor

en la parte superior facilita el acceso a los componentes electrónicos, mientras que las demás secciones ofrecen acceso independiente a los sensores y al depósito de agua.

Durante el desarrollo, se resolvieron desafíos técnicos relacionados con el ajuste de las piezas y la aplicación de silicona, asegurando un sellado uniforme y un acabado estético. Este enfoque iterativo permitió crear una estructura robusta, funcional y preparada para operar de manera confiable en su entorno previsto.



Figura 20: Ejemplo de pruebas en MDF




Figura 21: Estructura en su estado final

 Sistema de detección cualitativo de enfermedades en hojas de mango

En esta sección se explican los pasos que se llevaron a cabo para poder crear un sistema que fuera capaz de determinar si el follaje del árbol de mango se encuentra afectado por antracnosis, cancro bacteriano, gorgojo, síntomas de muerte regresiva, agallas producidas por mosquito *Asphondylia auripila*, mildiú polvoroso y fumagina. Para ello se utilizó la base de datos *MangoLeafBD Dataset* [26] con la cual se entrenó una red neuronal recurriendo al lenguaje de programación Python con la librería de Tensorflow. Esto dio como resultado un modelo de clasificación múltiple de alta precisión exportable para su uso en una interfaz web.

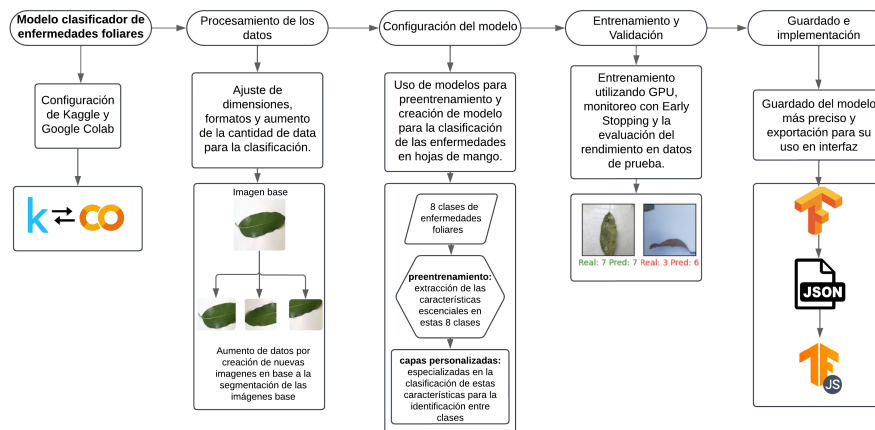


Figura 22: Diagrama de flujo de creación de red neuronal para clasificación de enfermedades foliares

8.1. Configuración de Kaggle y Google Colab: Manejo de base de datos

8.1.1. Obtención de las imágenes para la clasificación

Este modelo de clasificación múltiple fue entrenado utilizando la información brindada por la universidad Jahangir Nagar instaurada en Bangladesh los cuales publicaron una base de datos con 4000 imágenes de 240x320 en formato JPG separadas en 8 categorías (500 imágenes de cada categoría). Esta información se obtuvo de la plataforma Kaggle la cual fungió de puente para trasladar esta base de datos al ambiente de programación Google Colab.

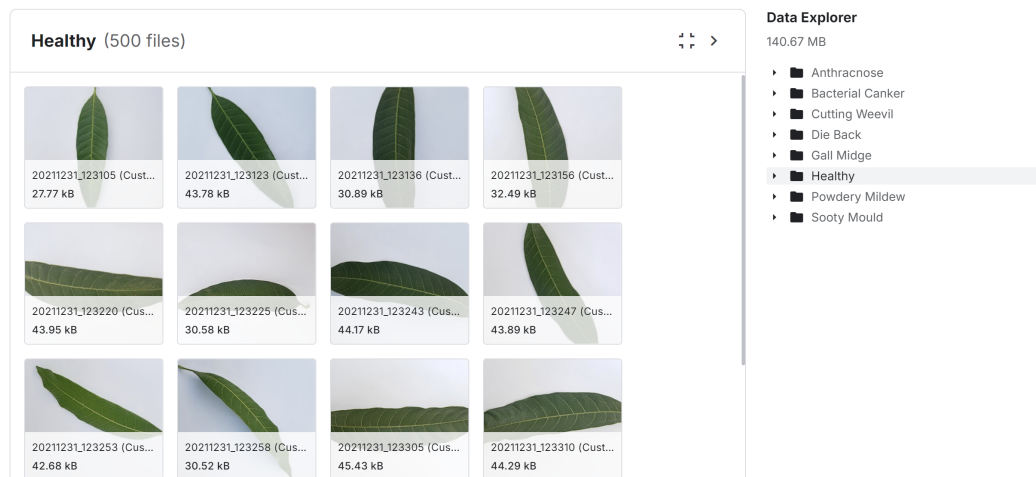


Figura 23: Base de datos de 7 enfermedades foliares y el control

8.1.2. Importación de datos a Google Colab desde Kaggle

El proceso de importación de datos desde Kaggle a Google Colab permitió acceder y manipular la base de datos requerida para el entrenamiento del modelo. Utilizando herramientas integradas de Kaggle, se estableció una conexión entre el repositorio de la plataforma y el entorno de Colab, donde los datos fueron descargados y organizados en un directorio local. Esta configuración optimizó la gestión de los datos y garantizó un flujo eficiente de trabajo.

La integración entre Kaggle y Google Colab no solo facilitó el acceso a la base de datos, sino que también permitió el uso de GPU para acelerar el procesamiento de imágenes, reduciendo significativamente el tiempo de entrenamiento del modelo. Este enfoque demostró ser práctico y escalable para proyectos de aprendizaje automático que manejan grandes volúmenes de datos.

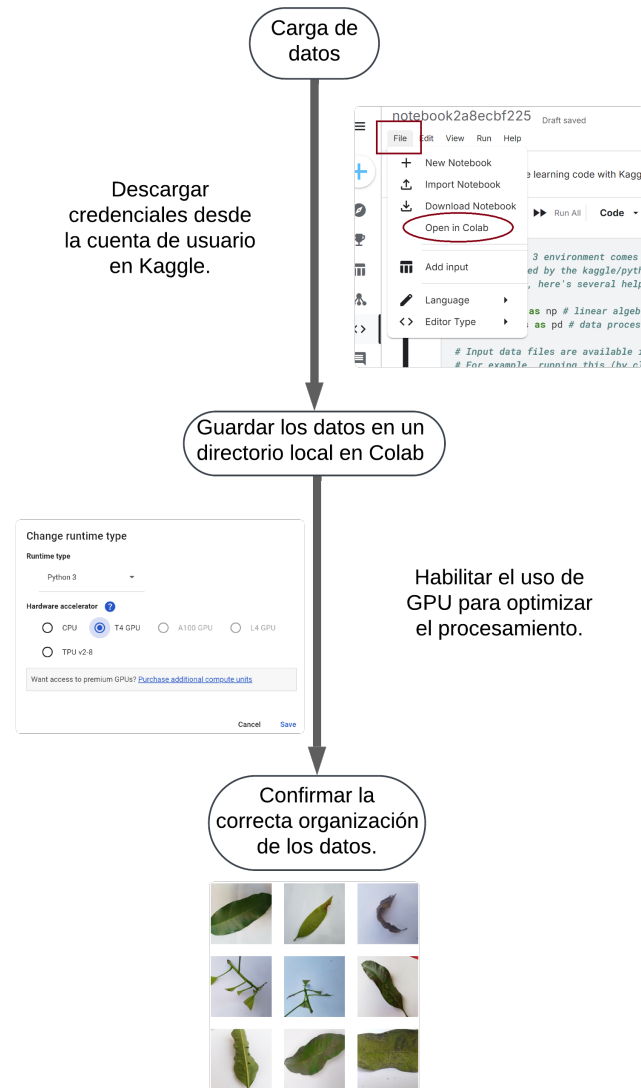


Figura 24: Diagrama de flujo carga de información desde Kaggle a Google Colab

8.1.3. Procesamiento de los datos

El conjunto de datos original fue sometido a un proceso de transformación para maximizar su utilidad en el entrenamiento del modelo. Este proceso consistió en ajustar las dimensiones de las imágenes y aplicar técnicas de generación de nuevas imágenes que aumentaron la variedad del conjunto de datos, mejorando así la capacidad del modelo para reconocer patrones y realizar clasificaciones precisas.

Preprocesamiento de las imágenes

Todas las imágenes se redimensionaron a un formato cuadrado de 224x224 píxeles, un tamaño estándar utilizado para arquitecturas de modelos preentrenados como *Inception V3*.

Este ajuste permitió que las imágenes fueran compatibles con el modelo al tiempo que redujo la cantidad de información innecesaria, optimizando el tiempo de procesamiento. Este paso asegura que todas las imágenes del conjunto tengan un formato uniforme, facilitando el aprendizaje del modelo.

8.1.4. Distribución de los datos

Para garantizar que el modelo pueda aprender de manera efectiva y evaluar su desempeño, los datos se dividieron en dos subconjuntos principales: el *conjunto de entrenamiento* y el *conjunto de validación*.

El conjunto de entrenamiento, compuesto por el 80 % de las imágenes (3200), fue utilizado para enseñar al modelo a identificar las características clave que diferencian las clases. Por otro lado, el conjunto de validación, que incluye el 20 % restante (800 imágenes), se utilizó para medir el rendimiento del modelo en datos no vistos durante el entrenamiento. Esta separación es fundamental para evaluar si el modelo puede generalizar correctamente en lugar de simplemente memorizar las imágenes del conjunto de entrenamiento.

Ambos conjuntos se organizaron en carpetas separadas, y cada carpeta contenía imágenes etiquetadas de acuerdo con la categoría a la que pertenecen. Este flujo de datos asegura que las imágenes ingresen al modelo de manera ordenada, permitiendo un análisis eficiente.

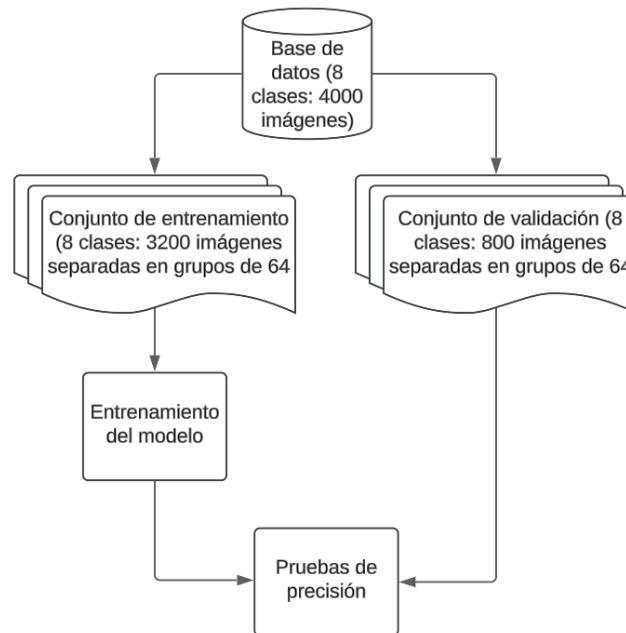


Figura 25: Distribución de las imágenes entre el conjunto de entrenamiento y validación

Aumento de datos

Para mejorar la capacidad del modelo de generalizar a nuevas imágenes, se generaron variaciones de las imágenes originales mediante un proceso conocido como *aumento de datos*. Este método simula la recolección de imágenes adicionales aplicando transformaciones a las ya existentes, como rotaciones, desplazamientos, ampliaciones (zoom) y ajustes en la orientación. Estas transformaciones introdujeron variabilidad en el conjunto de datos, lo que ayuda al modelo a reconocer patrones en condiciones similares a las que se encontraría en un entorno real.

Por ejemplo, algunas imágenes se rotaron aleatoriamente o se ampliaron para simular acercamientos. También se aplicaron desplazamientos horizontales y verticales, simulando pequeños cambios en la posición de las hojas, y se generaron imágenes invertidas horizontalmente para representar diferentes perspectivas. Estas modificaciones reducen el riesgo de *sobreajuste*, un fenómeno donde el modelo memoriza características específicas del conjunto de entrenamiento (imágenes con las que el modelo estructuró su clasificación) en lugar de aprender patrones generales aplicables a nuevos datos.



Figura 26: Ejemplo de imágenes generadas mediante el proceso de aumento de datos

Este enfoque estructurado permitió entrenar al modelo con una gran cantidad de ejemplos y validar su desempeño en un conjunto separado, asegurando que los resultados obtenidos sean representativos de su rendimiento en datos reales.

8.2. Configuración del modelo

8.2.1. Preentrenamiento de la red neuronal

Para el desarrollo del modelo, se utilizó una red neuronal preentrenada conocida como *InceptionV3*, la cual ya había sido entrenada previamente con millones de imágenes de un conjunto llamado *ImageNet*. Este conjunto contiene datos visuales muy variados, lo que permite al modelo identificar características generales como formas, texturas y patrones comunes en imágenes.

El modelo fue configurado para procesar imágenes ajustadas al tamaño de 224x224 píxeles, garantizando que fueran compatibles con su estructura. Las partes iniciales de esta red neuronal fueron utilizadas como una base para identificar características generales en las imágenes de hojas. Estas características ya aprendidas se mantuvieron fijas (sin ser modificadas), permitiendo que el modelo se enfoque en aprender únicamente las particularidades específicas de las enfermedades foliares en las capas agregadas posteriormente. Este proceso, conocido como *transferencia de aprendizaje*, permite aprovechar modelos complejos ya entrenados, reduciendo el tiempo de desarrollo y mejorando la precisión.

8.2.2. Estructura del modelo de clasificación

A partir de las características generales identificadas por *InceptionV3*, se añadieron capas adicionales que adaptaron el modelo a la tarea específica de clasificar las hojas en 8 categorías distintas. Las nuevas capas procesan las características extraídas para identificar patrones únicos relacionados con las enfermedades foliares.

El flujo de datos en el modelo comienza en una capa que organiza la información en un formato más sencillo para las capas siguientes. Después, esta información se procesa en una serie de capas especializadas que destacan relaciones y diferencias entre las clases. Finalmente, la capa de salida genera probabilidades asociadas a cada una de las categorías, indicando el nivel de confianza del modelo en su predicción.

8.2.3. Optimización y ajuste del modelo

Para mejorar la eficiencia del modelo durante el entrenamiento, se aplicaron técnicas como:

1. **Regularización:** Se implementaron ajustes que ayudan a evitar que el modelo dependa demasiado de características específicas del conjunto de entrenamiento, lo que podría limitar su capacidad de generalización. Esto se logra promoviendo la simplicidad del modelo y reduciendo su complejidad innecesaria.

2. **Dropout:** Se desactivaron aleatoriamente algunas conexiones dentro del modelo durante el entrenamiento para evitar que se vuelva demasiado dependiente de ciertos patrones.

3. **Batch Normalization:** Esta técnica ayudó a estabilizar los cálculos dentro del mo-

delo, acelerando el entrenamiento y mejorando su rendimiento.

8.2.4. Optimización

El modelo fue entrenado para minimizar los errores cometidos al clasificar las imágenes. Para ello, se utilizó un método matemático que ajusta los parámetros internos del modelo en cada iteración, optimizando su capacidad de predicción. El algoritmo seleccionado para este proceso fue *Adam*, ampliamente utilizado en modelos de aprendizaje profundo por su eficiencia en problemas complejos.

8.2.5. Evaluación del modelo

Para medir el rendimiento del modelo durante el entrenamiento, se utilizó una métrica llamada *precisión*. Esta métrica calcula el porcentaje de predicciones correctas en relación con el total de imágenes analizadas, lo que permite evaluar si el modelo está aprendiendo correctamente. Además, se utilizó una *función de pérdida* que cuantifica los errores cometidos por el modelo, guiando su aprendizaje para mejorar con cada iteración.




Figura 27: Esquema de la arquitectura del modelo

8.3. Entrenamiento y validación

8.3.1. Estrategias de regularización

Para mejorar el desempeño del modelo y evitar problemas como el *sobreaajuste* (cuando el modelo aprende características específicas del conjunto de entrenamiento pero no puede generalizar a datos nuevos), se aplicaron dos estrategias clave:

Detención temprana (*Early Stopping*)

La detención temprana es una técnica que finaliza el entrenamiento del modelo cuando este deja de mejorar en los datos de validación, previniendo que el modelo memorice excesivamente los datos del conjunto de entrenamiento. En este caso, si durante 10 iteraciones consecutivas no se observó una mejora en el rendimiento del modelo, el entrenamiento se interrumpió automáticamente.

Además, se guardaron los mejores resultados alcanzados hasta ese momento, lo que aseguró que el modelo final utilizara los parámetros óptimos logrados durante el proceso de entrenamiento.

Guardado del mejor modelo (*Model Checkpoint*)

Se implementó un mecanismo para almacenar automáticamente el modelo que mostró el mejor desempeño durante el entrenamiento, evaluado en términos de pérdida en los datos de validación. Este modelo se guardó como un archivo, permitiendo su reutilización en futuras pruebas o implementaciones sin necesidad de repetir el proceso de entrenamiento. Esto es especialmente útil para ahorrar recursos computacionales en proyectos de larga duración.

8.4. Resultados del entrenamiento

8.4.1. Evolución de la pérdida

El desempeño del modelo se evaluó monitoreando la *pérdida*, un indicador que mide qué tan lejos están las predicciones del modelo de los valores reales. El gráfico de la Figura 28 muestra cómo esta métrica evolucionó durante el entrenamiento.

La línea azul representa la pérdida en el conjunto de entrenamiento, la cual disminuyó consistentemente, indicando que el modelo aprendió a adaptarse a los datos. Por otro lado, la línea naranja muestra la pérdida en el conjunto de validación. Aunque también disminuyó inicialmente, comenzó a estabilizarse hacia el final, lo que refleja que el modelo logró un buen equilibrio entre aprendizaje y generalización.




Figura 28: Evolución de la pérdida durante el entrenamiento y validación.

En iteraciones posteriores, como se observa en la Figura 28, la pérdida en el conjunto de validación comenzó a fluctuar, lo que puede ser indicativo de *sobreajuste* leve. Este comportamiento subraya la importancia de las estrategias de regularización utilizadas.

8.4.2. Evolución de la precisión

La precisión, que mide el porcentaje de predicciones correctas realizadas por el modelo, también se monitoreó durante el entrenamiento. En la Figura 29, se puede observar que la precisión en el conjunto de entrenamiento aumentó rápidamente y se estabilizó por encima del 95 % después de unas pocas iteraciones.

En el conjunto de validación, la precisión también mostró un aumento inicial, pero comenzó a fluctuar hacia las últimas iteraciones, reflejando la dificultad de mantener un rendimiento consistente en datos no vistos.

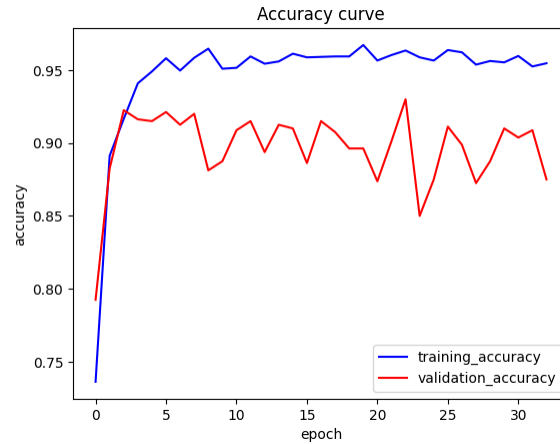


Figura 29: Evolución de la precisión en el conjunto de entrenamiento y validación.

8.5. Prueba del modelo

Para validar la capacidad del modelo, se utilizó un grupo de 64 imágenes de prueba. El modelo logró clasificar correctamente el 95.31 % de las imágenes, lo que indica un alto nivel de precisión en su desempeño.

Estos resultados confirman la efectividad del modelo para distinguir entre las diferentes categorías de enfermedades foliares, demostrando su utilidad para la clasificación precisa en escenarios reales.

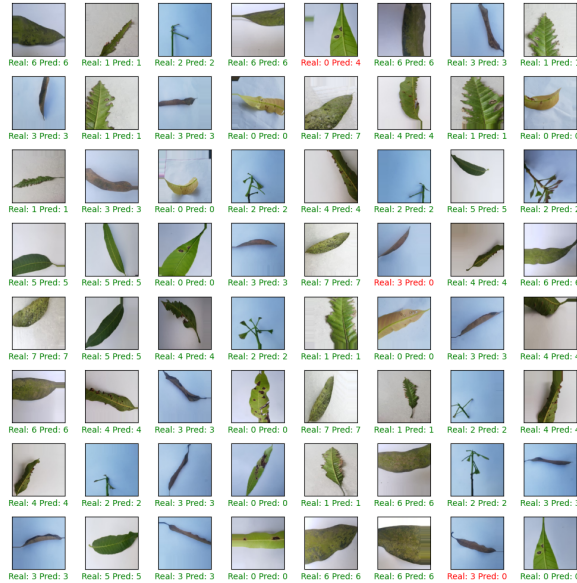


Figura 30: Resultados de la clasificación del modelo en datos de prueba.

8.6. Guardado e implementación del modelo

Una vez finalizado el entrenamiento y validación del modelo, este fue preparado para su implementación en una interfaz web utilizando TensorFlow.js. Este proceso involucró convertir el modelo entrenado al formato requerido para su uso en navegadores y empaquetarlo adecuadamente para su distribución.

El modelo entrenado, almacenado inicialmente en un archivo estándar de TensorFlow con extensión *.h5*, fue transformado al formato compatible con TensorFlow.js. Este formato divide el modelo en dos componentes principales: 1. Un archivo JSON, que contiene la arquitectura del modelo y los metadatos necesarios para su configuración. 2. Fragmentos binarios (o *shards*) que almacenan los pesos del modelo, organizados para ser cargados de manera eficiente en navegadores.

La conversión al formato de TensorFlow.js fue realizada mediante una herramienta que traduce los datos del modelo al estándar web. Esta conversión permite que el modelo pueda ser cargado directamente desde una aplicación web y ejecutado en el navegador del usuario, eliminando la necesidad de servidores externos para el procesamiento.

Posteriormente, los archivos generados (el archivo JSON y los *shards*) fueron organizados en una carpeta que fue comprimida en un archivo ZIP. Esto facilitó su distribución y descarga, permitiendo transferirlos de manera rápida y segura al entorno de desarrollo web.

8.6.1. Integración en la interfaz web

El modelo convertido fue integrado en la interfaz web utilizando TensorFlow.js. Al cargar la página web, el archivo JSON se emplea para reconstruir la arquitectura del modelo en el navegador, mientras que los *shards* son utilizados para cargar los pesos del modelo. Este

enfoque permite que las predicciones y cálculos se realicen completamente del lado del cliente, mejorando la velocidad de respuesta..

Este método de implementación asegura que el sistema sea escalable y accesible para cualquier usuario con un navegador compatible, manteniendo la portabilidad y eficiencia del modelo entrenado.

Conexión de componentes y funcionamiento del microcontrolador como servidor web

En este capítulo se describe cómo el microcontrolador ESP32 recopila datos de los sensores conectados, actúa como servidor para transmitir esta información a una interfaz web y permite a los usuarios acceder a los datos en tiempo real cuando están conectados a la misma red local. Además, se detallan las funciones principales del sistema y la interacción entre el hardware y el software.

9.1. Conexión de los sensores al ESP32

El sistema utiliza el microcontrolador ESP32 para gestionar la conexión con varios sensores que monitorean las condiciones ambientales del cultivo. Estos sensores incluyen un módulo de sensor de luz con fotoresistor, un sensor de pH Atlas Surveyor, un sensor de temperatura y humedad del aire DHT11, y un sensor de humedad del suelo YL69. Cada uno de estos dispositivos tiene un rol específico para garantizar que los datos críticos del entorno se recopilen de manera precisa.

El módulo sensor de luz mide la intensidad lumínica en lux, un parámetro importante para evaluar la cantidad de luz que recibe el cultivo. Este dato es fundamental para optimizar el crecimiento y desarrollo de las plantas. El sensor de pH Atlas Surveyor monitorea la acidez o alcalinidad del agua en el sistema, lo que permite mantener un balance óptimo de nutrientes para el desarrollo saludable del cultivo. Por su parte, el sensor DHT11 mide la temperatura y la humedad relativa del aire, valores esenciales para evaluar las condiciones climáticas y el impacto en la evapotranspiración de las plantas. Finalmente, el sensor de humedad del suelo YL69 mide el contenido de agua en el sustrato, ayudando a identificar si las plantas tienen suficiente acceso a agua para su desarrollo.

La Figura 31 muestra cómo están organizados estos sensores en relación con el ESP32, destacando su distribución para optimizar el monitoreo de las condiciones ambientales del cultivo.

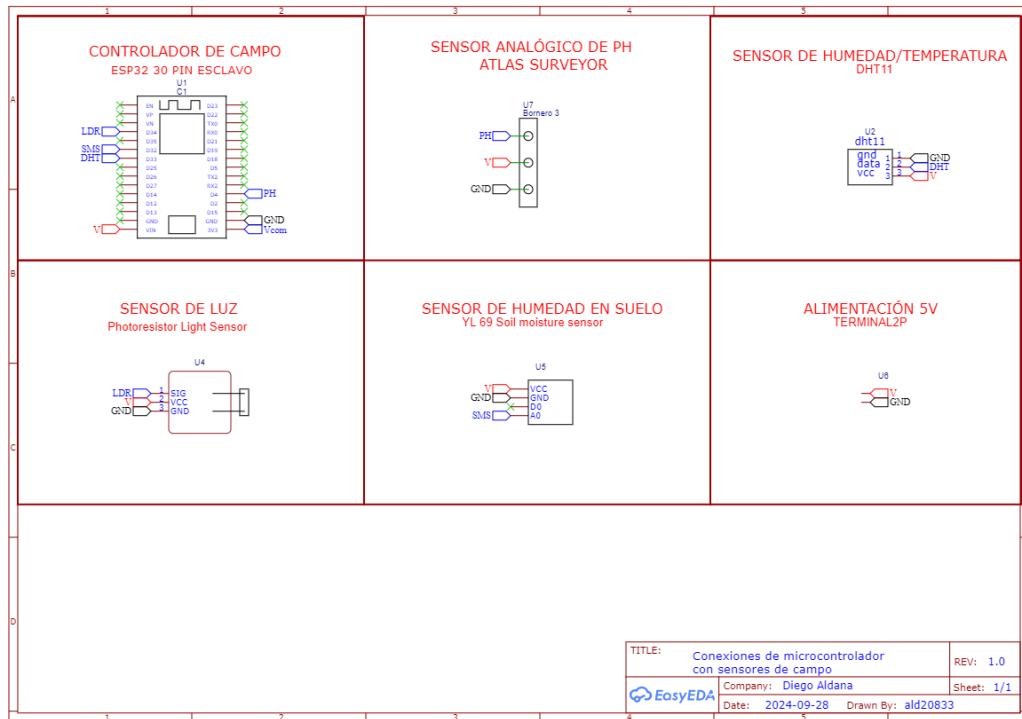


Figura 31: Esquema de conexión de los sensores al microcontrolador ESP32.

9.2. Funcionamiento del ESP32 como servidor web

El ESP32 no solo actúa como un controlador para los sensores, sino que también funciona como un servidor web. Esto significa que puede transmitir los datos recopilados a una interfaz web accesible para los usuarios. Esta funcionalidad es posible gracias al módulo Wi-Fi integrado del ESP32, que permite conectar el microcontrolador a una red local. Una vez conectado, el ESP32 recibe una dirección IP que los usuarios pueden utilizar para acceder a la interfaz desde cualquier dispositivo dentro de la misma red.

9.2.1. Recopilación y procesamiento de datos

El ESP32 lee continuamente los datos enviados por los sensores y los procesa para convertirlos en información útil. Por ejemplo, el sensor de luz genera valores de voltaje que el ESP32 traduce a lux mediante cálculos específicos. De manera similar, los datos del sensor de humedad del suelo y del sensor DHT11 se procesan para representar porcentajes de humedad y temperatura en grados Celsius. El sensor de pH proporciona valores analógicos que el ESP32 calibra para obtener mediciones precisas de acidez.

Todos los datos recopilados se organizan en un formato estandarizado llamado JSON (JavaScript Object Notation), un formato ligero y fácil de interpretar tanto por humanos como por máquinas. Este formato permite que los datos sean enviados a la interfaz web de manera clara y eficiente.

9.2.2. Transmisión de datos en tiempo real

Para garantizar que los datos recopilados por el ESP32 estén siempre actualizados en la interfaz web, se utiliza una tecnología llamada WebSocket. A diferencia de métodos tradicionales como HTTP, WebSocket permite una conexión continua entre el servidor (ESP32) y el cliente (el navegador del usuario). Esto significa que los datos se transmiten automáticamente a la interfaz web en intervalos regulares, sin necesidad de que el usuario recargue la página.

Cuando un usuario abre la interfaz web, el ESP32 le envía los datos recopilados por los sensores. Este proceso ocurre en ciclos de aproximadamente tres segundos, asegurando que la información mostrada sea casi en tiempo real. Además, el sistema puede manejar múltiples usuarios conectados al mismo tiempo, enviando los datos a todos los clientes simultáneamente sin afectar el rendimiento.

9.3. Interfaz web para la visualización de datos

La interfaz web, desarrollada en HTML, CSS y JavaScript, está diseñada para ser sencilla e intuitiva. Su principal objetivo es presentar los datos de los sensores de manera clara, permitiendo a los usuarios monitorear fácilmente las condiciones de su cultivo. Cada parámetro ambiental (temperatura, humedad del aire, intensidad lumínica, humedad del suelo y pH) se muestra en una tarjeta independiente, resaltando la información clave.

Los usuarios pueden acceder a esta interfaz ingresando la dirección IP del ESP32 en el navegador web de su dispositivo. Una vez establecida la conexión, los datos se actualizan automáticamente gracias al sistema WebSocket. Esto asegura que la información presentada sea siempre la más reciente.

9.4. Flujo de información del sistema

El sistema opera siguiendo un flujo lógico que garantiza la integración eficiente entre los sensores, el microcontrolador y la interfaz web. El proceso comienza con la recopilación de datos por parte de los sensores, que envían señales al ESP32. El microcontrolador procesa estas señales, organiza los datos en formato JSON y los transmite a los dispositivos conectados mediante WebSocket. Finalmente, la interfaz web presenta estos datos de manera visual.

La Figura [32](#) ilustra este flujo, destacando cada etapa del proceso desde la recopilación de datos hasta la visualización en la interfaz.

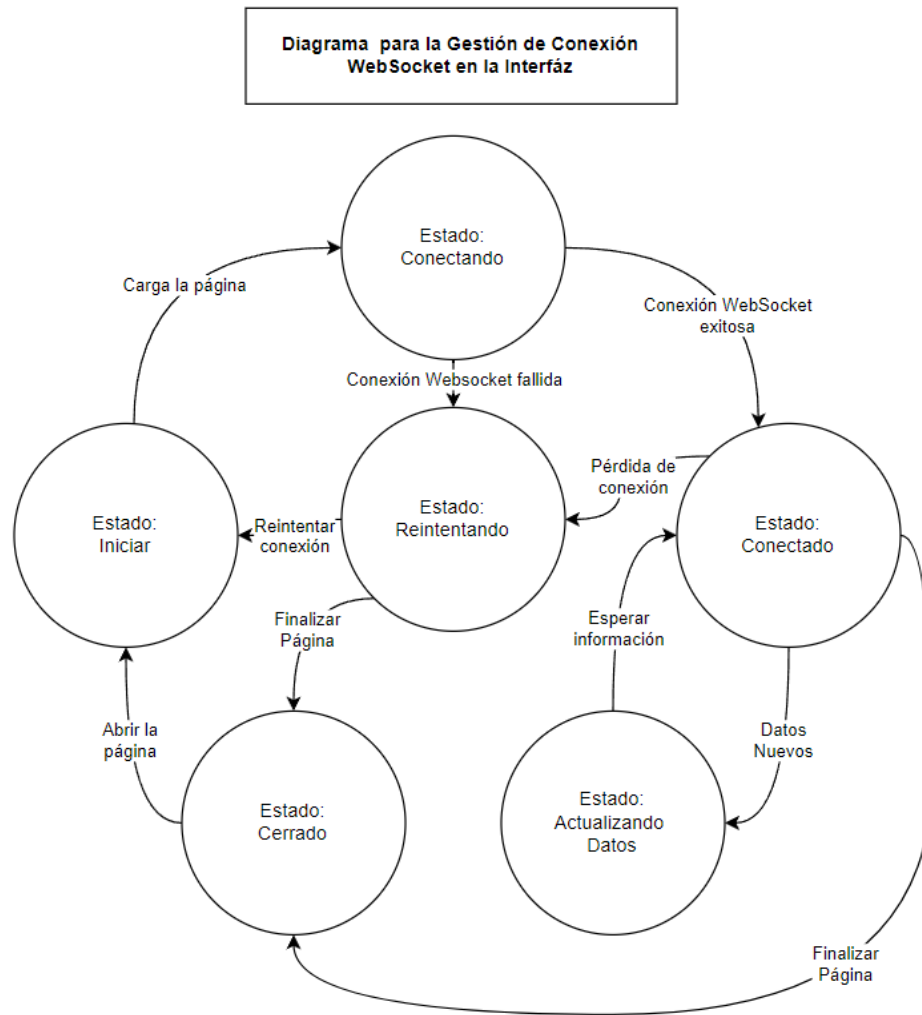


Figura 32: Diagrama del flujo de información del sistema.

9.5. Conclusión

El ESP32, gracias a su capacidad para recopilar datos de sensores y actuar como servidor web, permite monitorear en tiempo real las condiciones ambientales de un cultivo. La combinación de hardware eficiente y una interfaz web accesible asegura que los usuarios puedan tomar decisiones informadas basadas en datos precisos. Este sistema es una solución práctica y efectiva para gestionar cultivos de manera inteligente.

Implementación de interfaces gráfica para el monitoreo y diagnóstico en cultivos de mango

Conforme a los objetivos del proyecto, se desarrollaron dos interfaces gráficas orientadas a optimizar la experiencia del agricultor en el monitoreo y diagnóstico de los cultivos de mango. La primera interfaz presenta las condiciones ambientales del cultivo en tiempo real, mientras que la segunda facilita el diagnóstico de enfermedades foliares mediante un modelo de red neuronal integrado.

Ambas interfaces están conectadas mediante enlaces URL, lo que garantiza una navegación fluida entre sus funcionalidades y permite una experiencia integral para el usuario.

10.1. Interfaz para el monitoreo de factores ambientales

Esta interfaz, desarrollada utilizando HTML, CSS y JavaScript, muestra de forma clara y accesible los datos obtenidos de sensores instalados en el cultivo. Su diseño minimalista busca resaltar la información más importante, facilitando la toma de decisiones.

10.1.1. Conexión en tiempo real con WebSocket

La conexión en tiempo real entre la interfaz y los sensores instalados en el campo se realiza mediante el protocolo WebSocket. Este protocolo permite una comunicación bidireccional entre el servidor ESP32, encargado de recolectar los datos de los sensores, y el navegador donde se ejecuta la interfaz.

El manejo de WebSocket en JavaScript sigue los siguientes pasos principales:

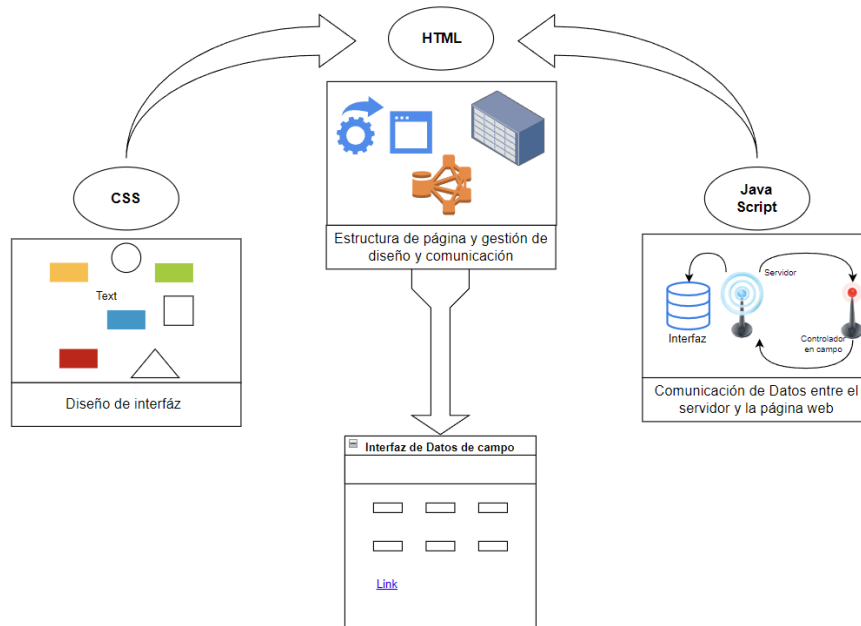


Figura 33: Diagrama de estructura de interfaz

- **Inicialización de la conexión:** Al cargar la página web, se establece automáticamente un canal de comunicación con el servidor mediante la creación de un objeto *WebSocket*, al que se le proporciona la URL del servidor.
- **Recepción de datos:** El navegador escucha continuamente los mensajes enviados por el servidor, que contienen los valores capturados por los sensores (temperatura, humedad, luz, etc.) en formato JSON. Estos datos se interpretan y se asignan dinámicamente a los elementos HTML correspondientes en la interfaz.
- **Manejo de reconexiones:** En caso de que la conexión se interrumpa, se implementa un sistema de reconexión automática que reintenta conectarse tras un intervalo corto, garantizando la disponibilidad continua de la información.

Esta configuración permite que las tarjetas de la interfaz se actualicen en tiempo real, asegurando que el usuario siempre tenga acceso a las condiciones más recientes del cultivo.

10.1.2. Estética y diseño

El diseño visual utiliza colores y elementos que resaltan las mediciones clave. La tipografía seleccionada (Arial o alternativas legibles) asegura una experiencia uniforme en cualquier dispositivo. Las tarjetas adaptables se organizan en cuadrículas dinámicas, ajustándose automáticamente al espacio disponible.

El encabezado, ubicado en una barra de navegación, incluye un título descriptivo que permite al usuario identificar rápidamente el propósito de la aplicación. Las tarjetas que

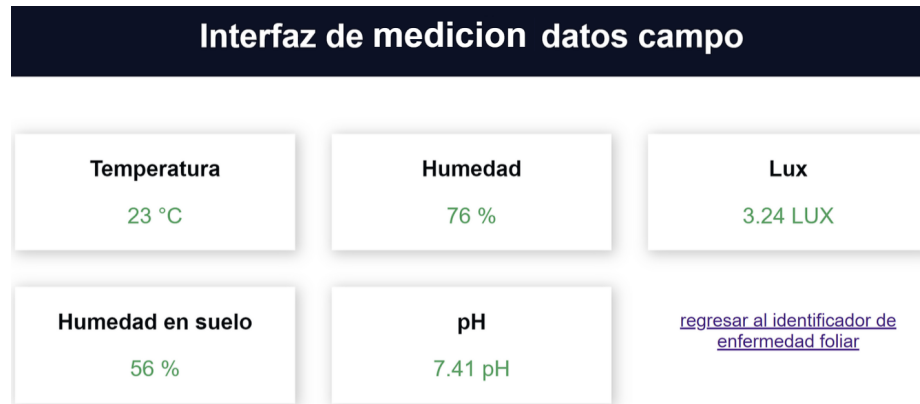


Figura 34: Interfaz de monitoreo de datos ambientales en vista de escritorio

contienen los datos tienen un diseño limpio con fondos blancos y texto resaltado en colores que facilitan su interpretación.

10.2. Interfaz para la detección de enfermedades foliares

Esta interfaz, diseñada para ser intuitiva, emplea TensorFlow.js para ejecutar el modelo de red neuronal en el navegador. Permite al usuario capturar imágenes de hojas y diagnosticar su estado en tiempo real, sin depender de servidores externos. Tiene la misma estructura de desarrollado utilizando HTML, CSS y JavaScript como sucede con la interfaz de datos de campo

10.2.1. Integración de TensorFlow.js para diagnóstico

El modelo previamente entrenado fue convertido al formato compatible con TensorFlow.js, lo que permite cargar y ejecutar el modelo directamente en el navegador. Este enfoque elimina la necesidad de procesar las imágenes en un servidor remoto, optimizando la velocidad y reduciendo la dependencia de infraestructura externa.

El flujo de trabajo para la integración del modelo incluye los siguientes pasos:

- **Carga del modelo:** Al iniciar la interfaz, el archivo JSON, que describe la arquitectura del modelo, y los *shards* que contienen los pesos entrenados se cargan en el navegador utilizando las funciones de TensorFlow.js.
- **Captura de la imagen:** La interfaz utiliza la *API* (conjunto de reglas, protocolos y herramientas que permite a dos sistemas o aplicaciones comunicarse entre sí) de video en HTML para capturar una imagen del follaje. Esta imagen se preprocesa para ajustarse al tamaño requerido por el modelo (224x224 píxeles).
- **Predicción en tiempo real:** Una vez que la imagen está lista, se pasa como entrada al modelo, que devuelve un diagnóstico en forma de probabilidades asociadas a cada

clase (enfermedades foliares o estado saludable). El diagnóstico se presenta al usuario de forma clara y directa en la interfaz.

10.2.2. Estética y diseño

La interfaz de detección de enfermedades foliares está diseñada para ser simple, intuitiva y funcional. Utiliza un fondo blanco con texto negro para asegurar legibilidad, mientras que los resultados se destacan en color verde para captar la atención del usuario. La tipografía principal es Arial o Helvetica, seleccionada por su claridad y profesionalismo, con textos grandes y en negrita para los diagnósticos.

El diseño es completamente responsivo, adaptándose automáticamente a cualquier tamaño de pantalla, ya sea móvil, tableta o computadora. Los botones de acción están ubicados en la parte inferior de la pantalla para facilitar su acceso. El botón de captura permite cambiar la orientación de la cámara y tomar imágenes del follaje, que son procesadas para diagnóstico.

10.3. Interconexión y flujo de trabajo entre interfaces

Ambas interfaces están conectadas mediante enlaces dinámicos que permiten al usuario cambiar entre el monitoreo ambiental y el diagnóstico foliar con facilidad. Esta integración asegura una experiencia unificada, donde el agricultor puede consultar el estado general de su cultivo y realizar diagnósticos específicos sin interrupciones.

10.4. Impacto en la experiencia del usuario

El diseño de estas interfaces combina claridad visual y funcionalidad técnica, haciendo que las herramientas sean accesibles incluso para usuarios con poca experiencia en tecnologías avanzadas. La capacidad de ejecutar el modelo directamente en el navegador elimina la necesidad de infraestructura costosa, demostrando cómo las tecnologías modernas pueden aportar soluciones escalables y prácticas en la agricultura.



Figura 35: Interfaz de detección de enfermedades foliares en vista de dispositivo móvil

- Se desarrolló un sistema de monitoreo que recopila y transmite en tiempo real datos de temperatura, humedad del aire y del suelo, pH y luz, utilizando sensores integrados a un microcontrolador ESP32 que funciona como servidor web.
- La red neuronal convolucional implementada clasificó hojas de mango en ocho categorías de salud foliar, logrando una precisión del 93% en entrenamiento y 95% en validación, demostrando su efectividad para el diagnóstico de enfermedades agrícolas.
- Las interfaces gráficas diseñadas permitieron una visualización clara y accesible de los datos ambientales y diagnósticos foliares, facilitando la toma de decisiones en el manejo del cultivo.
- La estructura del sistema y sus componentes demostraron la viabilidad de la agricultura de precisión en el contexto local, optimizando la eficiencia y reduciendo la dependencia de métodos tradicionales.
- Este proyecto sienta las bases para futuras aplicaciones tecnológicas en el sector agrícola, promoviendo sostenibilidad y mejorando la competitividad de la agricultura en Guatemala.

- Considerar la implementación de bibliotecas más modernas para el entrenamiento de la red neuronal, como PyTorch o Keras, con el objetivo de evitar posibles problemas de compatibilidad y facilitar la integración con herramientas actuales.
- Ampliar el sistema de monitoreo con la incorporación de nuevos sensores que permitan medir variables adicionales como dióxido de carbono, presión atmosférica o salinidad del suelo, mejorando la capacidad de control y manejo de las condiciones ambientales.
- Incrementar la cantidad de imágenes en el conjunto de datos para entrenar la red neuronal, aumentando la diversidad de muestras y mejorando así la precisión y generalización del modelo en la clasificación de enfermedades foliares.
- Extender el banco de datos incluyendo un mayor número de enfermedades foliares relevantes para el cultivo de mango y otros cultivos regionales, incrementando la utilidad del sistema en diversos contextos agrícolas.
- Optimizar la conexión entre la red neuronal y la interfaz web mediante mejoras en la implementación de TensorFlow.js o explorando herramientas alternativas que garanticen una mayor eficiencia y menor tiempo de respuesta.
- Diseñar y desarrollar un modelo modular para el sistema de sensores, que permita a los agricultores seleccionar y adaptar los sensores en función de las necesidades específicas de cada cultivo, promoviendo la flexibilidad y versatilidad del sistema.

- [1] A. A. AlZubi y K. Galyna, “Artificial Intelligence and Internet of Things for Sustainable Farming and Smart Agriculture,” *IEEE Access*, vol. 11, págs. 78 686-78 692, 2023. DOI: [10.1109/ACCESS.2023.3298215](https://doi.org/10.1109/ACCESS.2023.3298215).
- [2] J. U. M. Akbar, S. F. Kamarulzaman, A. J. M. Muzahid, M. A. Rahman y M. Uddin, “A Comprehensive Review on Deep Learning Assisted Computer Vision Techniques for Smart Greenhouse Agriculture,” *IEEE Access*, vol. 12, págs. 4485-4522, 2024. DOI: [10.1109/ACCESS.2024.3349418](https://doi.org/10.1109/ACCESS.2024.3349418).
- [3] Y. Wang e Y. Yang, “Research on Application of Smart Agriculture in Cotton Production Management,” en *2020 International Workshop on Electronic Communication and Artificial Intelligence (IWECAI)*, 2020, págs. 120-123. DOI: [10.1109/IWECAI50956.2020.00032](https://doi.org/10.1109/IWECAI50956.2020.00032).
- [4] H. Erden y E. Çamaşırcıoğlu, “Satellite imagery acquisition planning,” en *2015 Fourth International Conference on Agro-Geoinformatics (Agro-geoinformatics)*, 2015, págs. 113-116. DOI: [10.1109/Agro-Geoinformatics.2015.7248146](https://doi.org/10.1109/Agro-Geoinformatics.2015.7248146).
- [5] Z. Cheng-Jun, “Research and Implementation of Agricultural Environment Monitoring Based on Internet of Things,” en *2014 Fifth International Conference on Intelligent Systems Design and Engineering Applications*, 2014, págs. 748-752. DOI: [10.1109/ISDEA.2014.170](https://doi.org/10.1109/ISDEA.2014.170).
- [6] H. T. Lara, *Sector agrícola en Guatemala*, 2021. dirección: <https://www.mapa.gob.es/es/ministerio/ministerio-exterior/america-central-caribe/2021fichaicexagricolaguarctcm30-576578.pdf>.
- [7] S. De Agricultura Y Desarrollo Rural, *El cambio climático afecta al campo ¿cómo enfrentarlo?* 2015. dirección: <https://www.gob.mx/agricultura/es/articulos/el-cambio-climatico-afecta-al-campo-como-enfrentarlo#:~:text=Estos%20cambios%20afectan%20el%20rendimiento,devastadoras%20en%20el%20sector%20agropecuario.>
- [8] J. Mora, J. Gamboa y R. Murillo, “Guía para el cultivo del mango,” *MINISTERIO DE AGRICULTURA Y GANADERIA*,

- [9] “El cultivo del mango, Mangifera indica, y su comportamiento frente a las condiciones ambientales y de manejo,” *Boletín mensual INSUMOS Y FACTORES ASOCIADOS A LA PRODUCCIÓN AGROPECUARIA*, vol. 31,
- [10] J. García, “Adaptación del cultivo de mango al cambio climático,” 2010, Consultado el 25 de noviembre de 2024. dirección: <https://repositorio.iica.int/bitstream/handle/11324/3020/BVE17068938e.pdf?sequence=1>.
- [11] J. M. Hermoso González et al., “Introducción al cultivo del mango en el sur peninsular,” 2018, Consultado el 25 de noviembre de 2024. dirección: <https://avogoconsulting.com/subtropicales/4-condiciones-ambientales-claves-para-mango/>.
- [12] E. Systems, *ESP32 Series*.
- [13] *Sensor de humedad de suelo YL-69*. dirección: <https://laelectronica.com.gt/modulo-sensor-de-humedad-de-suelo>.
- [14] *pH Composite electrode manual*, ETC1. dirección: <https://atlas-scientific.com/embedded-solutions/surveyor-analog-ph-sensor-meter/?srsltid=AfmB0oq5U5zndk6l7G7hjU69RvcfTiJV-udv4jk5or1d6w9e1Qc0hivG>.
- [15] *DHT Humidity Temperature Sensor*, ETC. dirección: <https://html.alldatasheet.es/html-pdf/1440068/ETC/DHT11/60/1/DHT11.html>.
- [16] IONOS by 11, *Convolutional Neural Network: ¿qué es y cómo funciona?* Consultado el 25 de noviembre de 2024, 2024. dirección: <https://www.ionos.mx/digitalguide/paginas-web/desarrollo-web/convolucional-neural-network/>.
- [17] *¿Qué son las redes neuronales convolucionales?* | IBM. dirección: <https://www.ibm.com/es-es/topics/convolutional-neural-networks>.
- [18] *Convolutional Neural Network (CNN)*. dirección: <https://www.tensorflow.org/tutorials/images/cnn>.
- [19] L. A. Valdés, D. Calero Consuegra, M. E. Carballo, M. Capote, I. González, J. M. Alvarez et al., “Caracterización Morfológica, Cultural Y Patogénica De Aislados De Colletotrichum Sp. Produciendo Antracnosis En Mango (Mangifera Indica L.),” *LA GRANJA. Revista de Ciencias de la Vida*, vol. 26, n.º 2, págs. 38-51, 2017.
- [20] J. Crane y R. Gazis, “Bacterial Black Spot (BBS) of Mango in Florida,” *EDIS*, vol. 2018, n.º 3, págs. 1-5, 2018. dirección: <https://edis.ifas.ufl.edu/publication/HS1369>.
- [21] M. Rashid et al., “Life-table study of mango leaf cutting weevil, Deporaus marginatus Pascoe (Coleoptera: Curculionidae) feeding on four mango cultivars,” *Journal of Asia-Pacific Entomology*, vol. 20, n.º 1, págs. 96-101, 2017. DOI: [10.1016/j.aspen.2016.11.011](https://doi.org/10.1016/j.aspen.2016.11.011).
- [22] Y. Shimizu, N. Moriya, O. Jahana, M. Matsumura y M. Takeuchi, “Effects of sixteen insecticides on the mango gall midge Procontarinia mangicola (Shi) (Diptera: Cecidomyiidae) infesting mango leaves,” *International Journal of Tropical Insect Science*, vol. 43, págs. 601-608, 2023. DOI: [10.1007/s42690-023-00962-3](https://doi.org/10.1007/s42690-023-00962-3).
- [23] J. Abdollahzadeh, A. Javadi, E. Mohammadi Goltapeh, R. Zare y A. Phillips, “Filogenia y morfología de cuatro nuevas especies de Lasiodiplodia de Irán,” *Persoonia: Molecular Phylogeny and Evolution of Fungi*, vol. 25, págs. 1-10, 2010. DOI: [10.3767/003158510X524150](https://doi.org/10.3767/003158510X524150).

- [24] K. P. Akhtar y S. S. Alam, "Powdery Mildew of Mango: A Review," *Pakistan Journal of Biological Sciences*, vol. 3, n.º 7, págs. 1119-1122, 2000. DOI: [10.3923/pjbs.2000.1119.1122](https://doi.org/10.3923/pjbs.2000.1119.1122).
- [25] A. Rebolledo-Martínez, A. L. del Ángel-Pérez, N. Peralta-Antonio y G. Díaz-Padilla, "Control de fumagina (*Capnodium mangiferae* Cooke & Brown) con biofungicidas en hojas y frutos de mango "Manila"," *Tropical and Subtropical Agroecosystems*, vol. 16, n.º 3, págs. 355-362, 2013. dirección: <https://www.redalyc.org/pdf/939/93929595007.pdf>.
- [26] A. Sawkat, I. Muhammad, A. Sarder Iftekhar et al., *MangoLeafBD Dataset*, 2022. DOI: [10.17632/hxsnvwtly3r.1](https://doi.org/10.17632/hxsnvwtly3r.1).

14.1. Repositorio de código red neuronal para la clasificación de enfermedades foliares

Este enlace dirige al repositorio donde se encuentra la programación de la red neuronal para la clasificación de enfermedades foliares en Python mediante Tensorflow: [Repositorio Red Neuronal](#).