

CREACIÓN DE UN SISTEMA DE INFORMACIÓN SOBRE CULTIVOS APOYADO EN INTELIGENCIA ARTIFICIAL E IOT

CREATION OF A CROP INFORMATION SYSTEM SUPPORTED BY ARTIFICIAL INTELLIGENCE AND IOT

Rosique de Dios Raúl¹, Alor Salaya Livi Deysi², Almeyda Vázquez Karina³,
Galindo Cruz Nicolás⁴, Ulloa Pimienta Ana Ruth⁵

<https://doi.org/10.61117/ipsumtec.v9i1.450>

¹Tecnológico Nacional de México/ Instituto Tecnológico Superior de Villa la Venta, raul.rd@laventa.tecnm.mx, <https://orcid.org/0009-0007-3314-0674>

²Tecnológico Nacional de México/ Instituto Tecnológico Superior de Villa la Venta, LD@laventa.tecnm.mx, <https://orcid.org/0009-0003-3462-8349>

³Tecnológico Nacional de México/ Instituto Tecnológico Superior de Villa la Venta, almeydakarina79@gmail.com, <https://orcid.org/0009-0006-5722-1965>

⁴Tecnológico Nacional de México/ Instituto Tecnológico Superior de Villa la Venta, galindonicolas1981@gmail.com, <https://orcid.org/0009-0008-8108-2912>

⁵Tecnológico Nacional de México/ Instituto Tecnológico Superior de Villa la Venta, anar.up@laventa.tecnm.mx, <https://orcid.org/0000-0003-1375-4736>

Resumen - Actualmente no solo México, sino también muchos países enfrenta importantes desafíos agrícolas derivados de la alteración del clima, la aparición de plagas y la baja automatización en procesos productivos. Ante este panorama la presente investigación, plantea la creación de un sistema de información sobre cultivos apoyado en inteligencia artificial, con el propósito de impulsar la innovación rural y fortalecer la seguridad alimentaria mediante soluciones tecnológicas accesibles y escalables. La actividad agrícola continúa dependiendo de métodos tradicionales poco sustentables, lo que limita la incorporación de herramientas modernas y dificulta la transición hacia prácticas más eficientes. El estudio se desarrolló de forma metodológica misma que consta de tres fases: la primera es diseño del hardware IoT, en la segunda fase se desarrollo del software de visión artificial y finalmente la última fase de interpretación de los datos para la toma de decisiones. El sistema propone el desarrollo de un dispositivo IoT emisor-receptor con capacidad de transmisión de datos sensoriales análogos y digitales a través de radiocomunicación LoRa, complementado con un sistema de visión artificial basado en YOLOv8 para la detección de la salud de los cultivos. La integración de estas tecnologías busca optimizar el uso del agua y avanzar hacia la sostenibilidad agrícola. Asimismo, se emplea Python en la implantación de algoritmos con inteligencia artificial que permiten identificar enfermedades en las plantas y activar sistemas de riego únicamente cuando la humedad del suelo lo requiere, reduciendo el desperdicio de recursos hídricos. Este enfoque contribuye a la construcción de un modelo agrícola más sustentable, eficiente y resiliente, capaz de responder a las necesidades actuales y futuras del sector, posicionando la innovación tecnológica como un eje estratégico para el desarrollo rural y la seguridad alimentaria en México.

Palabras Clave: Agricultura 4.0, Desarrollo Sustentable, Inteligencia Artificial, Internet de las Cosas, LoRaWAN, Visión Computacional.

Abstract - Currently, not only Mexico, but many other countries face significant agricultural challenges stemming from climate change, the emergence of pests, and low levels of automation in production processes. Given this scenario, this research proposes the creation of a crop information system supported by artificial intelligence, with the aim of promoting rural innovation and strengthening food security through accessible and scalable technological solutions. Agricultural activity continues to rely on traditional, unsustainable methods, which limits the adoption of modern tools and hinders the transition to more efficient practices.

The study was developed using a three-phase methodology: the first phase involves the design of the IoT hardware, the second phase the development of the machine vision software, and the final phase the interpretation of the data for decision-making. The system proposes the development of an IoT transmitter-receiver device capable of transmitting analog and digital sensor data via LoRa radio communication, complemented by a YOLOv8-based machine vision system for detecting crop health. The integration of these technologies aims to optimize water use and advance agricultural sustainability. Python is also used to implement artificial intelligence algorithms that identify plant diseases and activate irrigation systems only when soil moisture requires it, reducing water waste. This approach contributes to building a more sustainable, efficient, and resilient agricultural model, capable of responding to the sector's current and future needs, positioning technological innovation as a

strategic pillar for rural development and food security in Mexico.

Key words – Agriculture 4.0, Sustainable Development, Artificial Intelligence, Internet of Things, LoRaWAN, Computer Vision.

INTRODUCCIÓN

La agricultura actual se enfrenta a un panorama desafiante caracterizado por la crisis climática, el aumento de plagas y el limitado nivel de modernización en los procesos productivos. Estos factores no solo afectan a México, sino también a numerosos países que dependen de sistemas agroalimentarios vulnerables y poco sustentables. Las tecnologías aplicadas al sector agrícola avanzan con rapidez hacia un nuevo enfoque: la agricultura 4.0. En este modelo, la digitalización, la automatización y la inteligencia artificial adquieren un rol fundamental en la producción de cultivos, especialmente en tareas como el manejo de malezas y la gestión de plagas. **¡Error! No se encuentra el origen de la referencia.** Estas aplicaciones no solo aumentan la eficiencia y sostenibilidad de los sistemas agrícolas, sino que también mejoran la productividad y la resiliencia frente al cambio climático.

Esta evolución presenta desafíos y oportunidades a la vez, como la incorporación de tecnologías emergentes: el internet de las cosas (IoT) y la inteligencia artificial (IA) se ha convertido en una alternativa estratégica para impulsar la innovación rural y garantizar la seguridad alimentaria. La creación de un sistema de información sobre cultivos apoyado en inteligencia artificial e IoT se convierte en un eje fundamental para la transición hacia un modelo agrícola más eficiente y sustentable, en el cual la visión computacional, desempeña un papel clave al permitir la identificación temprana de plagas, enfermedades y deficiencias nutricionales en las plantas mediante el análisis automatizado de imágenes capturadas en campo. La Visión Computacional, (V.C.) es una rama de la inteligencia artificial, cuyo objetivo es proveer del sentido de la vista a un computador o robot para que éstos puedan interactuar de forma más eficiente en ambientes complejos (uso de la visión como sensor adicional. En términos generales, se trata de una rama de la inteligencia artificial cuyo objetivo es proporcionar a los sistemas computacionales la facultad de “ver” y procesar información visual para interactuar de forma más eficiente en ambientes complejos 0.

Esta capacidad de reconocimiento visual, combinada con algoritmos de aprendizaje profundo, ofrece a los productores herramientas precisas para la toma de decisiones, reduciendo el uso indiscriminado de agroquímicos y favoreciendo un desarrollo sustentable que prioriza la conservación de los recursos naturales y la protección del medio ambiente [3]. Asimismo, la integración de sensores IoT con sistemas de inteligencia artificial posibilita la recopilación continua de datos

sobre humedad, temperatura y calidad del suelo, generando un ecosistema digital que promueve la agricultura de precisión y fortalece la seguridad alimentaria en comunidades rurales[4]. En este sentido, la inteligencia artificial no solo se presenta como un recurso tecnológico, sino como un catalizador de innovación que impulsa la productividad agrícola y contribuye a la resiliencia de los sistemas de cultivo frente a los retos del cambio climático, consolidando así un paradigma donde la tecnología se convierte en aliada estratégica para garantizar la sostenibilidad y la competitividad del sector agrícola.

Se considera que el más grande desafío del sector agrícola es la integración de tecnologías de diversas áreas del conocimiento, que permitan una verdadera transformación digital en productos, servicios, procesos y nuevos modelos de negocios [5] [6].

Este nuevo paradigma revolucionario se ha extendido al sector agrícola con la creación de la agricultura 4.0, la cual apropia conocimientos y se prepara para el futuro mediante la adopción de nuevas tecnologías como el internet de las cosas, big data, computación en la nube, robótica avanzada e inteligencia artificial en la cadena de producción de los agro negocios [7].

La llamada agricultura 4.0 ha demostrado su potencial para transformar la producción mediante el uso de sensores, algoritmos de visión artificial y sistemas de comunicación que permiten optimizar recursos y mejorar la salud de los cultivos[8]. Algunas investigaciones afirman que en este tipo de sistemas de información de IA y algoritmos de machine learning (ML) son tecnologías que emergen para el análisis de gran cantidad de datos aplicados al sector agrícola [9].

La construcción de modelos basados en IA, por ejemplo: redes neuronales artificiales, redes neuronales convolucionales y aprendizaje por refuerzo, son tareas muy exigentes, pero las estimaciones paramétricas son útiles para resolver problemas con visión de futuro [10][11]. ML ha sido usado en el control de repeticiones de aplicación de pesticidas en la agricultura [12], fertilidad y productividad del suelo[13].

Otro recurso tecnológico representativo en el ámbito agrícola es el internet de las cosas (IoT) mismo que destaca el potencial de los sensores inalámbricos en las diversas etapas del cultivo, desde el inicio de la preparación de tierra hasta el transporte de la cosecha. Es una tecnología usada en este tipo de estudio también conocida como la computación en la nube. Este termino es relevante en agricultura, por la operatividad con IoT, ya que no solamente es una tecnología, sino que integra muchas cosas[11]. Es un sistema informático basado en Internet, que proporciona hardware, software, servicios de plataforma para almacenamiento de diversas

aplicaciones, textos, imágenes y vídeos de información agrícola [14].

Sin embargo, también plantea desafíos por la integración de tecnologías con prácticas agrícolas [15]. La tecnología LoRa emerge como una alternativa prometedora y eficiente para la transmisión a larga distancia en áreas rurales para el monitoreo agrícola[16].

El presente estudio se orienta hacia el desarrollo de un sistema de información agrícola que integra un dispositivo IoT emisor-receptor con capacidad de transmitir datos de sensores análogos y digitales a través de radiocomunicación LoRa, complementado con un sistema de visión artificial basado en YOLOv8.

De acuerdo[17], estas herramientas permiten monitorear en tiempo real la salud de los cultivos, optimizar el uso de recursos agrícolas y fortalecer la capacidad de respuesta ante amenazas fitosanitarias, todo ello mediante soluciones accesibles y escalables para el entorno rural.

Esta propuesta busca responder a la necesidad de modernizar las prácticas agrícolas, reduciendo la dependencia de métodos tradicionales y promoviendo un modelo más eficiente y sostenible. La implementación de algoritmos en Python permitirá identificar enfermedades en las plantas y activar sistemas de riego únicamente cuando la humedad del suelo lo requiere, lo que contribuye a disminuir el desperdicio de agua y avanzar hacia la sostenibilidad.

Este estudio contribuye al desarrollo sustentable agrícola al integrar tecnologías IoT-LoRa y visión artificial, permitiendo un uso más eficiente de recursos, reducción de impactos ambientales y fortalecimiento de la seguridad alimentaria.

DESARROLLO Metodología

El sistema se desarrolló bajo un enfoque iterativo con un diseño de ingeniería (Prototipar, Ensayar y Repetir) mismo que permitió ajustar continuamente los componentes de hardware y software en función de los resultados obtenidos en campo, asegurando su pertinencia y aplicabilidad en escenarios agrícolas reales. En la primera fase, el diseño del hardware IoT se orientó a la selección de sensores de humedad, temperatura y calidad del aire, cuya precisión y bajo consumo energético resultan esenciales para la sostenibilidad del sistema[18]. Posteriormente, la segunda fase se centró en el desarrollo del software de visión computacional, empleando algoritmos de inteligencia artificial capaces de identificar plagas y anomalías en los cultivos mediante el análisis de imágenes capturadas en tiempo real, lo que coincide con las tendencias actuales en agricultura digital[19].

Finalmente, la tercera fase consistió en la interpretación de los datos para la toma de decisiones, donde se aplicaron técnicas de aprendizaje automático para generar modelos predictivos que apoyan la gestión eficiente de recursos hídricos y nutricionales, contribuyendo directamente al desarrollo sustentable y a la seguridad alimentaria[8]. Esta metodología, al combinar prototipado, ensayo y repetición, no solo asegura la mejora continua del sistema, sino que también fortalece la resiliencia de los productores frente a los retos y necesidades de la variabilidad climática en los cultivos.

Diseño de la Red de Sensores IoT y Comunicación LoRa

Para garantizar la operatividad en zonas rurales carentes de infraestructura de telecomunicaciones convencional, se diseñó una arquitectura de red de largo alcance (LPWAN) basada en la tecnología LoRa. La red opera bajo una topología de estrella, donde múltiples nodos sensores (emisores) transmiten telemetría a un nodo central (Gateway/Receptor) encargado del procesamiento y la actuación.



Figura 1. Arquitectura de nodos
Fuente. Elaboración propia.

La arquitectura de Hardware de los nodos emisores y nodos de monitoreo fue diseñado como un sistema embebido autónomo. El núcleo de procesamiento es el microcontrolador ESP32-S3, seleccionado por su arquitectura de doble núcleo Xtensa® LX7 de 32 bits, que ofrece la capacidad de cómputo necesaria para el pre-procesamiento de datos en el borde (Edge Computing) y su eficiencia energética.



Figura 2. Arquitectura de Esp32.

Fuente. *Elaboración propia.*

Para la adquisición de variables físicas, se implementaron sensores de humedad del suelo capacitivos v1.2. A diferencia de los sensores resistivos tradicionales, la tecnología capacitiva evita la electrólisis y corrosión de los electrodos, extendiendo la vida útil del dispositivo en ambientes de alta salinidad y humedad, un factor crítico para la sostenibilidad del mantenimiento industrial.



Figura 3. Sensor de humedad de suelo.

Fuente. *Elaboración propia.*

La transmisión de datos se realiza mediante el módulo transceptor LoRa Reyax RYLR998, que opera a través de una interfaz UART. Este módulo fue configurado para operar en la banda de frecuencia de 915 MHz, optimizando la penetración de señal en entornos con vegetación densa.




Figura 4. Antenas LoRa Reyax 998.

Fuente. *Elaboración propia.*

La gestión energética y autonomía de los nodos que operan en ubicaciones remotas, se implementó un sistema de alimentación autosustentable compuesto por paneles fotovoltaicos y bancos de baterías de litio recicladas. Para maximizar la autonomía, se programó el micro controlador bajo una rutina de "Deep Sleep" (sueño profundo). En este modo, el sistema permanece inactivo consumiendo energía mínima (en el orden de los microamperios) y "despierta" únicamente en intervalos programados para tomar lecturas de los sensores, transmitir el paquete de datos vía LoRa y

volver a dormir. Esta estrategia de gestión energética resolvió los problemas iniciales de autonomía detectados en las fases piloto.

El nodo receptor actúa como la pasarela (Gateway) entre la red LoRa local y la nube. Al recibir las tramas de datos provenientes de los emisores, este dispositivo realiza dos funciones críticas:

Telemetría IoT: A través de una conexión WiFi (cuando está disponible) o datos móviles, sube los registros a la plataforma ThingSpeak para la visualización histórica y análisis de tendencias.

Control de Actuadores: El sistema integra un módulo de relevadores de 4 canales (5V-120/220V, 10A). Basado en la lógica de control programada, si la humedad reportada es inferior al umbral crítico del 40%, el Gateway activa los contactores de las bombas de riego de manera sectorizada, garantizando que el agua se suministre solo a las áreas que fisiológicamente lo requieren.

Sistema de Visión Artificial para Control de Calidad del Cultivo

Para el aseguramiento de la calidad del cultivo y la detección temprana de estrés biótico, se desarrolló un software de visión computacional modular utilizando el lenguaje de programación Python 3.11. La arquitectura del software integra librerías especializadas: OpenCV para el pre-procesamiento de imágenes en el espacio de color BGR a RGB, Ultralytics para la inferencia de modelos de aprendizaje profundo, y Tkinter para la interfaz gráfica de usuario (GUI), permitiendo una interacción intuitiva para los operadores agrícolas.

Para el control de calidad del cultivo se considero también el modelo YOLOv8 (You Only Look Once, versión 8) porque representa un avance reciente en el campo de las CNN, diseñado para realizar detecciones rápidas y precisas en tiempo real. Su arquitectura optimizada permite abordar problemas complejos de clasificación y detección con un balance eficiente entre precisión y velocidad, incluso en condiciones de recursos computacionales limitados. Esto lo convierte en una herramienta ideal para su aplicación en entornos agrícolas, donde la disponibilidad de hardware especializado es a menudo restringida[20].

La arquitectura del modelo y entrenamiento implementó el algoritmo YOLOv8 (You Only Look Once, versión 8), seleccionado por su arquitectura de red neuronal convolucional (CNN) de una sola etapa, que ofrece un equilibrio óptimo entre precisión (mAP) y velocidad de inferencia, crucial para el procesamiento en tiempo real en dispositivos de borde. Esta tecnología se convierte en una herramienta ideal para su aplicación en entornos

agrícolas, donde la disponibilidad de hardware especializado es a menudo restringida.

El modelo fue entrenado utilizando un conjunto de datos híbrido, compuesto por imágenes recolectadas en cultivos de la región sur de Tabasco y aumentadas sintéticamente mediante la plataforma Roboflow para mejorar la generalización. El proceso de entrenamiento constó de 50 épocas, logrando la convergencia de las funciones de pérdida de caja (box_loss) y clasificación (cls_loss) hacia valores mínimos estables, lo que indica un aprendizaje efectivo de las características morfológicas de las patologías.




Figura 5. Segmentación de datos en Roboflow.
Fuente. Elaboración propia.

El algoritmo implementado procesa imágenes y video en tiempo real. El proceso de inferencia utiliza un umbral de confianza ajustable para filtrar falsos positivos. El sistema etiqueta las detecciones y genera estadísticas de conteo por clase, permitiendo al usuario visualizar la incidencia de enfermedades en el lote inspeccionado.

Ec. (1) Lógica de detección e inferencia (fragmento de código): resultados = modelo(img, stream=False, conf=confidence_threshold)

El algoritmo opera bajo una lógica secuencial de inspección automatizada:

Adquisición: El sistema captura el flujo de video desde las cámaras CCTV o archivos estáticos.

Inferencia: La imagen es procesada por la red neuronal, que predice las coordenadas de las cajas delimitadoras (bounding boxes) y la probabilidad de clase.

Filtrado Estadístico: Se aplica un umbral de confianza ajustable (configurado inicialmente a = 0.20) para descartar falsos positivos. Solo las detecciones con una confianza $C > a$ son procesadas.

Ec. (2) Criterio de validación: $D_{\text{valid}} = \{d \in D \mid \text{Conf}(d) > 0.20\}$

Clasificación Taxonómica: El sistema mapea los índices de clase detectados a sus nombres científicos y comunes utilizando un diccionario de traducción interno.

Visualización y Conteo: Se renderizan las cajas delimitadoras y etiquetas sobre la imagen original y se actualizan los contadores estadísticos en el dashboard en

tiempo real, permitiendo calcular la tasa de incidencia de la enfermedad en el lote inspeccionado.



Figura 6. Interfaz de usuario.
Fuente. Elaboración propia.

Esta metodología permite no solo identificar la presencia de patógenos como la Roya (*Puccinia sorghi*) o el Tizón, sino cuantificar la severidad de la infección basándose en la densidad de detecciones por hoja, proporcionando datos duros para la toma de decisiones agronómicas.

Estandarización del Proceso de Riego

Desde la perspectiva de la Ingeniería Industrial, el riego tradicional representa un proceso no estandarizado, sujeto a una alta variabilidad introducida por el factor humano y la evaluación empírica. Para mitigar esto, se diseñó un algoritmo de control de lazo cerrado que transforma el riego en un proceso determinista basado en datos cuantitativos.

Lógica de Control y Algoritmo

El sistema opera bajo una lógica de control On-Off con histéresis para proteger los actuadores. Se definió un setpoint crítico de humedad del suelo (H_{min}) del 40%, determinado como el límite inferior seguro antes de que el cultivo entre en estrés hídrico.

El algoritmo, ejecutado en el nodo Gateway, consulta periódicamente la telemetría de los sensores distribuidos. La lógica de decisión sigue el siguiente pseudocódigo estandarizado:

1. Lectura: Obtener el valor promedio de humedad (H_{actual}) del sector i .
2. Decisión:
 - a. Si $H_{\text{actual}} < 40$: Activar Relevador K (Encender Bomba).
 - b. Si $H_{\text{actual}} > 60\%$: Desactivar Relevador K (Apagar Bomba).

Resultados del Entrenamiento de Visión Artificial

El modelo YOLOv8 fue entrenado durante 50 épocas. El comportamiento del entrenamiento, visible en las gráficas de pérdida y métricas, muestra una convergencia estable. La pérdida de clasificación (cls_loss) disminuyó progresivamente de 3.75 a aprox. 2.25, indicando que el modelo aprendió efectivamente a distinguir entre las 27 clases disponibles.

El rendimiento global del modelo se evaluó mediante la curva de Precisión-Recall (PR), obteniendo una Precisión Media (mAP) al 50% de intersección sobre la unión (IoU) de 0.346 para todas las clases. Aunque el puntaje F1 máximo global se situó en 0.31 con un umbral de confianza de 0.155, el análisis detallado por clase revela un desempeño superior en los cultivos objetivo de esta investigación.




Figura 7. Resultados de entrenamiento.

Fuente. Elaboración propia.

DISCUSIÓN Y ANÁLISIS DE RESULTADOS

Los resultados obtenidos a partir de la implementación del prototipo se discuten a continuación, evaluando el desempeño técnico frente a los objetivos de sostenibilidad y optimización operativa planteados. El análisis se divide en tres pruebas fundamentales: eficiencia de la red de telemetría, validación del modelo de visión artificial y cuantificación del ahorro hídrico.

Prueba 1: Alcance y Fiabilidad de la Red IoT. Se evaluó la capacidad de transmisión del módulo LoRa Reyax 998 en un entorno rural con vegetación media. Las pruebas de campo confirmaron un enlace estable de transmisión de datos hasta una distancia de 14 km en línea de vista. Esto valida la viabilidad técnica de la arquitectura LPWAN propuesta para superar la brecha de conectividad en zonas agrícolas sin infraestructura de internet, cumpliendo con el objetivo de accesibilidad tecnológica. Además, la implementación del modo de "sueño profundo" (deep sleep) en el micro controlador ESP32 demostró ser efectiva para la autonomía energética, permitiendo la operación continua con baterías recicladas y paneles solares, eliminando la dependencia de la red eléctrica convencional.

Prueba 2: Precisión del Modelo de Visión Artificial. El análisis del entrenamiento del algoritmo YOLOv8 revela una convergencia estable de las pérdidas de caja y clasificación durante las 50 épocas ejecutadas, indicando

un aprendizaje efectivo de las características morfológicas. Aunque la Precisión Media global (mAP 0.5) se situó en 0.346, un análisis desglosado mediante la matriz de confusión normalizada demuestra una alta efectividad en los cultivos objetivo de la región. Específicamente, el sistema logró identificar correctamente el 75% de los casos de Tizón Foliar del Maíz (Corn leaf blight).

Desde una perspectiva de ingeniería industrial aplicada al control de calidad, estos valores son aceptables para un sistema de alerta temprana, ya que permiten al agricultor segregar lotes afectados y aplicar medidas correctivas focalizadas, reduciendo la merma del cultivo que, según pruebas preliminares, mejoró el rendimiento en un 20%. Sin embargo, se observa una confusión cruzada significativa en patologías visualmente similares del tomate, lo que sugiere la necesidad futura de balancear el dataset para robustecer la generalización del modelo.

Prueba 3: Estandarización del Riego y Ahorro Hídrico

La implementación del algoritmo de control basado en el umbral de humedad del 40% transformó el proceso de riego de una actividad empírica a una operación estandarizada. La monitorización a través de la plataforma ThingSpeak permitió verificar la correlación directa entre la temperatura ambiente y la humedad del suelo, validando la respuesta automática de los actuadores.

Al comparar el consumo volumétrico, el sistema automatizado redujo el uso de agua en un 50% respecto al método de riego tradicional por inundación o calendario fijo empleado anteriormente en la zona de prueba. Este resultado responde directamente al objetivo de sostenibilidad, demostrando que la tecnificación de bajo costo puede mitigar significativamente el estrés hídrico sin comprometer la salud del cultivo.

Los resultados discutidos evidencian que la integración de IoT, visión computacional e inteligencia artificial en el prototipo desarrollado constituye una alternativa viable para avanzar hacia la sostenibilidad agrícola y la optimización operativa. La fiabilidad de la red de telemetría, la capacidad predictiva del modelo de visión artificial y la estandarización del riego demuestran que el sistema no solo responde a los objetivos técnicos planteados, sino que también aporta beneficios tangibles en términos de eficiencia energética, reducción de pérdidas y uso racional del agua.

Estos hallazgos confirman el potencial de la propuesta como herramienta de apoyo a la toma de decisiones en entornos rurales, al tiempo que señalan áreas de mejora como el balance de datasets para fortalecer la generalización del modelo que deberán abordarse en futuras investigaciones para consolidar su impacto en la seguridad alimentaria y el desarrollo sustentable.

1) Conectividad y autonomía energética en entornos rurales (IoT-LoRa).

Los resultados de alcance (≈ 14 km en línea de vista) y operación autosustentable confirman que una arquitectura LPWAN basada en LoRa es técnicamente viable para telemetría agrícola donde la infraestructura convencional es limitada. Este hallazgo concuerda con la evidencia de que LoRa/LPWAN permite monitoreo de grandes áreas con bajo consumo y enlaces estables, aun en escenarios con vegetación y orografía compleja [15][16]. La estrategia de deep sleep y abastecimiento fotovoltaico utilizada en el prototipo refuerza la literatura que destaca la eficiencia energética como factor crítico de escalabilidad y sostenibilidad en despliegues IoT agrícolas [14][15].

2) Visión computacional y desempeño de YOLOv8 para alerta temprana.

Aunque el mAP global obtenido (≈ 0.35 @IoU 0.5) es mejorable, el desempeño específico en cultivos objetivo (p. ej., Tizón Foliar en maíz) lo posiciona como sistema funcional de alerta temprana. Este patrón-utilidad práctica con margen de refinamiento es consistente con revisiones que reportan que el deep learning en agricultura logra resultados sólidos cuando hay datos locales y curación del conjunto [3][9]. Estudios recientes con YOLOv8 en fitosanidad de frutales muestran ganancias relevantes tras balanceo y aumentación del dataset, lo cual respalda priorizar curación de datos y clases difíciles como próximo paso [20][1].

3) Estandarización del riego y ahorro hídrico mediante control basado en datos.

La reducción del consumo de agua ($\sim 50\%$) frente a riego empírico coincide con evidencia de que integrar sensores de humedad, modelos de IA y automatización puede optimizar volúmenes, frecuencia y oportunidad del riego, impactando de forma directa en sostenibilidad y resiliencia productiva [10][18]. La transición de reglas simples (on - off con histéresis) hacia esquemas predictivos se alinea con tendencias de agricultura de precisión, donde el pronóstico y la integración de variables edafoclimáticas elevan la eficiencia y la estabilidad de los cultivos [9][10].

4) Integración Agricultura 4.0: datos, adopción y escalabilidad.

La convergencia IoT-IA-comunicación se tradujo en decisiones accionables (segmentación de lotes, riego sectorizado), lo que es coherente con el paradigma Agricultura 4.0 que enfatiza cadenas de valor intensivas en datos, trazabilidad y servicios digitales [11][4]. No obstante, la literatura advierte que la adopción depende de factores socio técnicos disponibilidad de datos de calidad, capacidades locales y modelos de gobernanza por lo que la escalabilidad requiere protocolos de datos, ciberseguridad y estrategias de capacitación para que el

beneficio técnico se sostenga en implementaciones reales [5] [19].

CONCLUSIONES

La presente investigación logró cumplir con el objetivo general de desarrollar e implementar un sistema integral de monitoreo agrícola que fusiona el Internet de las Cosas (IoT) y la Inteligencia Artificial para optimizar procesos en zonas rurales de baja infraestructura. Se demostró la viabilidad técnica de utilizar la tecnología LoRa para la transmisión de telemetría en distancias de hasta 14 km sin dependencia de internet local, validando una arquitectura de comunicación robusta y accesible para el campo mexicano.

En relación con los objetivos de sostenibilidad y optimización de recursos, la estandarización del proceso de riego mediante lógica de control automático permitió una reducción del 50% en el desperdicio de agua en comparación con los métodos tradicionales.

En conjunto, los resultados confirman que la convergencia IoT - IA - control de procesos posibilita una agricultura de precisión asequible, escalable y contextualizada, capaz de traducir datos en intervenciones oportunas que mejoran la eficiencia en el uso de recursos, disminuyen la incertidumbre operativa y fortalecen la seguridad alimentaria en entornos rurales.

Las líneas de investigación futuras que permitirán complementar un mejor desarrollo del sistema son:

1.- Mejora del desempeño del modelo y robustez del dataset multimodal: profundizar en el balanceo de clases, la incorporación de imágenes multispectrales, hiperespectrales y el aprendizaje autosupervisado para elevar la generalización, reducir confusiones entre patologías visualmente similares y robustecer la detección en condiciones de iluminación variable y oclusiones; complementariamente, explorar técnicas de active learning en campo para anotar de forma eficiente casos difíciles y acelerar ciclos de mejora continua.

2.- Control inteligente de riego y fertirrigación con predicción: evolucionar del esquema on - off con histéresis hacia control predictivo basado en modelos (MPC) que integre pronóstico meteorológico, dinámica de humedad del suelo y fenología del cultivo, con el fin de optimizar volumen, momento y sectorización del riego & fertirrigación, maximizando ahorro hídrico y estabilidad productiva bajo escenarios de variabilidad climática.

AGRADECIMIENTOS

A los agricultores del programa sembrando vida de Ciudad la Venta por permitir hacer pruebas del sistema en sus campos de cultivo.

BIBLIOGRAFÍA

- [1] Hernández Salazar, C. A., González Estrada, O. A., & González Silva, G. (2024). "Integración de la inteligencia artificial y la agricultura de precisión en cultivos de café," *Rev. UIS Ing.*, vol. 23, no. 4, pp. 145-158.
doi: <https://doi.org/10.18273/revuin.v23n4-2024012>
- [2] Olmi, H. (2019). Visión por computador: su historia y algunos principales hitos. *Revista Ingeniería al Día*, Universidad Central de Chile. Recuperado de https://revistaingenieriaaldia.uccentral.cl/rev_10/hernan_olmi.pdf
- [3] Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90.
<https://doi.org/10.1016/j.compag.2018.02.016>
- [4] Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M. J. (2017). Big Data in Smart Farming – A review. *Agricultural Systems*, 153, 69–80.
<https://doi.org/10.1016/j.agry.2017.01.023>
- [5] Bentivoglio, Deborah; Bucci Giorgia; Belletti Matteo; Finco, Adele (2022). A theoretical framework on network's dynamics for precision agriculture technologies adoption. *Revista de Economía e Sociología Rural*, 60(4), e245721.
<https://doi.org/10.1590/1806-9479.2021.245721>
- [6] Rocha Jácome, Cristian; González, Ramón; Muñoz, Fernando; Guevara-Cabezas, Esteban; Hidalgo, Eduardo (2021). Industry 4.0: A Proposal of Paradigm Organization Schemes from a Systematic Literature Review. *Sensors*, 22(1), 66.
<https://doi.org/10.3390/s22010066>
- [7] Mühl, Diego; de Oliveira, Leticia (2022). A bibliometric and thematic approach to agriculture 4.0. *Heliyon*, 8(5), e09369.
<https://doi.org/10.1016/j.heliyon.2022.e09369>
- [8] IBM. (2025). La IA y el futuro de la agricultura. IBM Think. <https://www.ibm.com/es-es/think/topics/ai-in-agriculture>
- [9] Sharma, Abhinav; Jain, Arpit; Gupta, Prateek; Chowdary, Vinay (2021). Machine Learning Applications for Precision Agriculture: A Comprehensive Review. *IEEE Access*, 9, 4843-4873.
<https://doi.org/10.1109/ACCESS.2020.3048415>
- [10] Chen, Qianyu; Li, Lanyu; Chong, Clive; Wang, Xionan (2022). AI-enhanced soil management and smart farming. *Soil Use and Management*, 38, 7-13.
<https://doi.org/10.1111/sum.12771>
- [11] Maffezzoli, Federico; Ardolino, Marco; Bacchetti, Andrea; Perona, Marco; Renga, Filippo (2022). Agriculture 4.0: A systematic literature review on the paradigm, technologies and benefits. *Futures*, 142, 102998.
<https://doi.org/10.1016/j.futures.2022.102998>
- [12] Indu, Malik; Baghel, Anurag; Bhardwaj, Arpit; Ibrahim, Wubshet (2022). Optimization of Pesticides Spray on Crops in Agriculture using Machine Learning. *Computational Intelligence and Neuroscience*, 2022, 9408535.
<https://doi.org/10.1155/2022/9408535>
- [13] Helfer, Gilson; Victória, Jorge; dos Santos, Ronaldo; da Costa, Adilson (2020). A computational model for soil fertility prediction in ubiquitous agriculture. *Computers and Electronics in Agriculture*, 175, 105602.
<https://doi.org/10.1016/j.compag.2020.105602>
- [14] Shi, Xiaojie; An, Xingshuan; Zhao, Qingxue; Liu, Huimin; Xia, Lianming; Sun, Xia; Guo, Yemin (2019). State-of-the-Art Internet of Things in Protected Agriculture. *Sensors*, 19(8), 1833.
<https://doi.org/10.3390/s19081833>
- [15] Ayaz, M., Ammad-Uddin, M., Sharif, Z., Mansour, A., & Aggoune, E. H. M. (2019). Internet-of-Things (IoT)-based smart agriculture: Toward making the fields talk. *IEEE Access*, 7, 129551–129583.
<https://doi.org/10.1109/ACCESS.2019.2932609>
- [16] Lee, H. C., & Ke, K. H. (2018). Monitoring of Large-Area IoT Sensors Using a LoRa Wireless Mesh Network System: Design and Evaluation. *IEEE Transactions on Instrumentation and Measurement*, 67(9), 2177–2187.
<https://doi.org/10.1109/TIM.2018.2814082>
- [17] Luis García, L. C. y Torres Gómez, L. A. (2024). Desarrollo de Aplicaciones IoT: Metodologías y Estrategias [IoT Application Development: Methodologies and Strategies]. *European Public & Social Innovation Review*, 9, 1-18.
<https://doi.org/10.31637/epsir-2024-1375>
- [18] Toledo, F. D. (2024). Aplicación de sensores IoT e inteligencia artificial para la optimización del riego en cultivos agroecológicos. *Revista Internacional de Investigación y Desarrollo Global*, 3(2).
<https://doi.org/10.64041/riidg.v3i2.23>
- [19] Hernández Hernández, S. S., Díaz-Manríquez, A., & Elizondo-Leal, J. C. (2025). Inteligencia Artificial e IoT para el monitoreo agrícola: una revisión de tendencias actuales. *Revista Mexicana de Ingeniería y Ciencias*, 1(1).
<https://rmic.uat.edu.mx/index.php/MI/article/view/4>
- [20] León León, R. A., Aguirre vasquez. H. & Cruz Galdos, I. (2025). Desarrollo de un Sistema de Visión Artificial mediante Yolov8 para la Detección del Hongo Sphaceloma Perseae en Aguacate. *Memorias de la Décima Quinta Conferencia Iberoamericana de Complejidad, Informática y Cibernética (CICIC)* (2025).
<https://doi.org/10.54808/CICIC2025.01.357>

Tabla de Roles de Contribución

Rol	Autor (es)
Conceptualización	Livi Deysi Alor Salaya
Curación de datos	Raúl Rosique de Dios
Metodología	Ana Ruth Ulloa Pimienta
Administración del	Raúl Rosique de Dios

proyecto	
Recursos	Nicolas Galindo Cruz
Software	Raúl Rosique de Dios
Supervisión	Karina Almeyda Vázquez
Validación	Raúl Rosique de Dios
Visualización	Ana Ruth Ulloa Pimienta
Redacción	Ana Ruth Ulloa Pimienta
Redacción	Ana Ruth Ulloa Pimienta

Esta obra está bajo
una licencia internacional
Creative Commons Atribución 4.0.

