



UNIVERSIDAD AUTÓNOMA CHAPINGO

Posgrado en Ingeniería Agrícola y Uso Integral del Agua

SISTEMA DE ADQUISICIÓN DE DATOS Y MONITOREO IOT PARA UNA MINIFÁBRICA DE PLANTAS CON ILUMINACIÓN ARTIFICIAL

TESIS

Que como requisito parcial para obtener el grado de:

Maestro en Ingeniería Agrícola y Uso Integral del Agua


Presenta:

JOSÉ FRANCISCO ARTEAGA ALARCÓN

Bajo la supervisión de:

DR. AGUSTÍN RUIZ GARCÍA

Chapingo, Estado de México, noviembre de 2025.



SISTEMA DE ADQUISICIÓN DE DATOS Y MONITOREO IOT PARA UNA MINIFÁBRICA DE PLANTAS CON ILUMINACIÓN ARTIFICIAL

Tesis realizada por el **C. José Francisco Arteaga Alarcón** bajo la supervisión del Comité Asesor indicado, aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

MAESTRO EN INGENIERÍA AGRÍCOLA Y USO INTEGRAL DEL AGUA

DIRECTOR

DR. AGUSTÍN RUIZ GARCÍA

ASESOR

DR. LUIS ARTURO SORIANO AVENDAÑO

ASESOR

DR. EFRÉN FITZ RODRÍGUEZ

CONTENIDO

CONTENIDO	iii
LISTA DE CUADROS	vi
LISTA DE FIGURAS	vii
AGRADECIMIENTOS	ix
DEDICATORIAS	x
DATOS BIOGRÁFICOS	xi
RESUMEN GENERAL	12
GENERAL <i>ABSTRACT</i>	13
1. INTRODUCCIÓN GENERAL	14
1.1 Importancia del problema	14
1.2 Antecedentes	16
1.2.1 El ecosistema PFAL	16
1.2.2 La implementación del Internet de las Cosas (IoT) en la Agricultura	
4.0	17
1.3 Justificación	17
1.3.1 La necesidad de un marco de validación operativa y metrológica	18
1.3.2 Justificación de la arquitectura y el flujo de datos	18
1.4 Hipótesis	19
1.4.1 Objetivo general:	19
1.4.2 Objetivos específicos	19
1.5 Estructura del documento de tesis	20
Literatura citada	20

2. REVISIÓN DE LITERATURA.....	22
2.1 Fundamentos agricultura vertical y PFAL	22
2.1.1 Agricultura vertical	23
2.1.2 Definición de PFAL y su importancia	24
2.2 Fotometría y radiometría hortícola.....	26
2.2.1 La luz en las plantas.....	26
2.2.2 La radiación fotosintéticamente activa (PAR)	27
2.2.3 Espectros de radiación y calidad lumínica.....	28
2.2.4 La iluminación en las PFAL	30
2.2.5 Instrumentación y calibración metrológica.....	31
2.3 Fundamentos del monitoreo ambiental en PFAL	32
2.3.1 Alcance del monitoreo y variables críticas.....	32
2.3.2 Estrategia de muestreo espacial y redundancia	34
2.3.3 Metrología y aseguramiento de Calidad (QA/QC)	37
2.4 Arquitecturas IoT y pipelines de datos en PFAL	38
2.4.1 Fundamentos y objetivos del IoT agrícola en PFAL	39
2.5 Captura de imágenes y fenotipado de alto rendimiento	41
2.5.1 Tecnología de visión 3D y rasgos fenotípicos.....	41
2.5.2 Desafíos metrológicos y sincronización de datos	42
2.6 Cultivo de espinaca en PFAL.....	42
2.6.1 Requerimientos ambientales	43
Literatura citada.....	44

3. Sistema IoT para una mini-PFAL: diseño, disponibilidad de datos y validación de calidad de medición ²	52
Resumen.....	52
Abstract	53
3.1 Introducción	54
3.2 Materiales y métodos.....	55
3.2.1 Sistema mini-PFAL	56
3.2.2 Configuración de hardware	58
3.2.3 Diseño de base de datos	63
3.2.4 Dashboard y visualización	64
3.2.5 Validación del sistema y métricas de integridad de datos	64
3.2.6 Cultivo experimental y condiciones de crecimiento	65
3.3 Resultados y discusión	67
3.3.1 Métricas generales de integridad y continuidad temporal del sistema	67
3.3.2 Desempeño de cada sensor.....	70
3.3.3 Desempeño del dashboard IoT y trazabilidad de datos.....	72
3.3.4 Captura y gestión de imágenes	74
3.3.5 Solución nutritiva, parámetros ambientales y del cultivo	75
3.3.6 Desempeño de la mini-PFAL y acumulación de biomasa.....	81
3.4 Conclusiones	83
Literatura citada.....	84

LISTA DE CUADROS

Cuadro 3.1. Uniformidad e intensidad de la luz a diferentes alturas e integral de luz diaria para un fotoperiodo de 13 h.....	58
Cuadro 3.2. Especificaciones técnicas de los sensores.	60
Cuadro 3.3 Límite máximo, mínimo y salto máximo para la limpieza de datos.	65
Cuadro 3.4. Registro de brechas de adquisición de datos: duración, cadencia y causa	68
Cuadro 3.5. Indicadores de disponibilidad, completitud y brechas de datos (MTTR/MTBF).....	69
Cuadro 3.6. Calidad de datos por variable almacenada.	70
Cuadro 3.7. Completitud global del sistema: conteo de registros válidos, inválidos y faltantes (21 días, 30 variables).	71
Cuadro 3.8. Temperaturas promedio por sensor MLX90614: planta vs. ambiente, agrupadas por piso.	79
Cuadro 3.9. Crecimiento y biomasa: comparación inicial vs. final.	82

LISTA DE FIGURAS

Figura 2.1. Curvas de eficiencia fotosintética relativa según Hoover (1937), McCree (1972) e Inada (1976). Los puntos negros indican las longitudes de onda medidas; las curvas de McCree e Inada representan rendimiento cuántico por fotón absorbido, y la de Hoover, por fotón incidente. Adaptada de Bugbee (2016).	29
Figura 3.1. Esquema de la mini-PFAL construida donde se observa la distribución de sus componentes.....	56
Figura 3.2. Espectro promedio de emisión de las lámparas LED instaladas en la mini fábrica de plantas.	57
Figura 3.3. Mapa de la densidad de flujo de fotones fotosintéticos medidos a diferentes alturas en la mini fábrica de plantas.	57
Figura 3.4. Arquitectura general del sistema IoT.....	59
Figura 3.5. Distribución espacial de la red de sensores vista frontal (a) y lateral (b) (1: solución nutritiva; 2: ambientales; 3: fisiológicos; D405: cámara RGB-D).	60
Figura 3.6. Distribución del hardware del módulo de adquisición de datos, con rutas por piso y por la solución nutritiva hasta la Raspberry Pi 5.....	62
Figura 3.7. Flujo de datos del módulo central de procesamiento y almacenamiento.....	63
Figura 3.8. Robot cartesiano para la captura de imágenes.	63
Figura 3.9. Panel principal del Dashboard: se muestran las variables medidas en cada piso y las variables correspondientes a la solución nutritiva.	73
Figura 3.10. Panel de sensores infrarrojos: se presentan las lecturas de temperatura de planta y de temperatura ambiental de cada sensor MLX90614.	73

Figura 3.11. Imagen RGB (a) e imagen de profundidad (b) de plantas a 5 días del trasplante.	74
Figura 3.12. Imagen RGB (a) e imagen de profundidad (b) de plantas a 21 días del trasplante	74
Figura 3.13. Dinámica de la temperatura en la solución nutritiva.....	75
Figura 3.14. Comportamiento del pH de la solución nutritiva durante el experimento (a: se agregó agua al sistema; b: error humano al agregar más ácido del necesario; c: adaptación radicular; d: falla del sensor por sulfatación en las terminales eléctricas).	76
Figura 3.15. Comportamiento de la CE de la solución nutritiva durante el experimento (a: se agregó agua al sistema; b: se compensó el descenso brusco del pH agregando agua; c: aumento de la CE tras 8 días del trasplante).	76
Figura 3.16. Comportamiento de la temperatura por nivel durante el experimento.	77
Figura 3.17. Comportamiento de la humedad por piso durante el experimento.	78
Figura 3.18. Comportamiento del CO ₂ durante el experimento.	78
Figura 3.19. Presencia o ausencia de luz en cada piso de la mini-PFAL.....	79
Figura 3.20. Comportamiento de la temperatura de la planta durante el experimento.	80
Figura 3.21. Comportamiento de la temperatura ambiente durante el experimento.	80
Figura 3.22. Estructura de la mini-PFAL con sistema hidropónico tipo NFT y arreglo de luminarias LED (vista frontal).	81
Figura 3.23. Planta representativa del cultivo tras 15 días de trasplante.	82

AGRADECIMIENTOS

A la Universidad Autónoma Chapingo, al Posgrado en Ingeniería Agrícola y Uso Integral del Agua, al Departamento de Ingeniería Mecánica Agrícola y a la Secretaría de Ciencia, Humanidades, Tecnología e Innovación, por el financiamiento y las facilidades brindadas para la elaboración de esta tesis.

A mis asesores, quienes, con su tiempo, su guía y su conocimiento, me orientaron en el desarrollo de esta investigación.

A mis amigos y compañeros del posgrado, por hacer de mi paso por la maestría una gran experiencia.

Finalmente, quiero ofrecer mi profunda gratitud a mi mamá Reyna Alarcón, a mi hermana Aranzazu Arteaga, a mi tío Arturo y a mi novia Alejandra, quienes, gracias a su apoyo, me llenan de motivación para seguir avanzando.

DEDICATORIAS

Dedico esta tesis a mi alma máter, la Universidad Autónoma Chapingo, por ofrecerme una educación extraordinaria y contribuir a mi formación como ingeniero y, ahora, como maestro.

También quiero dedicar este trabajo a mi familia, que es el pilar de mi vida, y a mi novia, por acompañarme en todo momento. Pero, sobre todo, dedico esta tesis a mi esfuerzo, pasión, dedicación y constancia, ya que, a pesar de las dificultades y obstáculos, no permitieron que me detuviera.

DATOS BIOGRÁFICOS



Datos personales

Nombre:	José Francisco Arteaga Alarcón.
Fecha de nacimiento:	02 de agosto de 1999.
Lugar de nacimiento:	Ciudad de México.
CURP:	AEAF990802HDFRLR03
Profesión:	Ingeniero mecatrónico agrícola
Cedula profesional:	13773847

Desarrollo académico

Preparatoria:	Preparatoria Agrícola, Universidad Autónoma Chapingo
Licenciatura	Ingeniería Mecatrónica Agrícola, Universidad Autónoma Chapingo

RESUMEN GENERAL¹

SISTEMA DE ADQUISICIÓN DE DATOS Y MONITOREO IOT PARA UNA MINIFÁBRICA DE PLANTAS CON ILUMINACIÓN ARTIFICIAL

Se diseñó e implementó un sistema con Internet de las Cosas (IoT) para una mini fábrica de plantas con iluminación artificial (mini-PFAL) para producción de hortalizas de hoja. El sistema integró monitoreo ambiental, de cultivo y solución nutritiva, además de una adquisición de datos mediante microcontroladores ESP32, una Raspberry Pi 5 para almacenar los datos en MariaDB, visualización en Node-RED y captura programada de imágenes RGB-D con un robot cartesiano. La validación operativa se realizó durante 21 días en un cultivo de espinaca (*Spinacia oleracea* L.) en sistema hidropónico NFT. Las mediciones de los sensores se realizaron cada minuto y fueron usadas para evaluar la continuidad, la disponibilidad (completitud y brechas), el tiempo medio entre fallas, el tiempo medio de recuperación y la caracterización de la iluminación mediante el mapeo del densidad de flujo fotónico fotosintético (PPFD) y el cálculo del integral de luz diaria (DLI) a 13 h. Se esperaron 30,240 registros por variable, se documentaron brechas discretas y se alcanzó una completitud global superior al 93 %, suficiente para análisis agronómicos y para la trazabilidad temporal entre sensores. El robot cartesiano fue capaz de capturar el 96.82 % del total de imágenes esperadas, con las únicas imágenes faltantes correspondientes a períodos en los que se registró una falla eléctrica en las instalaciones. Dicho conjunto de imágenes se empleará en futuros trabajos de fenotipado y estimación de parámetros del crecimiento vegetal. Se concluye que la arquitectura propuesta es operativamente sólida y escalable, ya que integra la adquisición de datos, el almacenamiento, la visualización y la captura automatizada de imágenes en un flujo unificado. La mini-PFAL funciona como una plataforma reproducible para verificar sensores, optimizar la gestión de cultivos y desarrollar bases de datos dirigidas a estudios avanzados de fenotipado y optimización de una mini-PFAL.

Palabras clave: Adquisición de datos, canalización de datos, ESP32, Raspberry Pi, validación metrológica.

¹ Tesis de Maestría en Ingeniería, Universidad Autónoma Chapingo.
Autor: José Francisco Arteaga Alarcón.
Director de tesis: Agustín Ruiz García.

GENERAL ABSTRACT

IoT-Based Data Acquisition and Monitoring System for a Mini Plant Factory with Artificial Lighting

An Internet of Things (IoT)-based system was designed and implemented for a mini plant factory with artificial lighting (mini-PFAL) dedicated to leafy vegetable production. The system integrated monitoring of environmental conditions, the crop, and the nutrient solution, as well as data acquisition using ESP32 microcontrollers, a Raspberry Pi 5 for data storage in MariaDB, data visualization in Node-RED, and scheduled RGB-D image capture with a Cartesian robot. Operational validation was carried out over 21 days on a spinach (*Spinacia oleracea* L.) crop grown in a hydroponic NFT system. Sensor measurements were taken every minute and used to evaluate continuity, availability (completeness and gaps), mean time between failures, mean recovery time, and lighting characterization through mapping of photosynthetic photon flux density (PPFD) and calculation of the daily light integral (DLI) for a 13 h photoperiod. A total of 30,240 records per variable were expected; discrete gaps were documented, and overall completeness exceeded 93%, which was sufficient for agronomic analyses and temporal traceability between sensors. The Cartesian robot was able to capture 96.82% of the expected images, with the only missing images corresponding to periods when an electrical failure occurred in the facilities. This image set will be used in future phenotyping studies and for estimating plant growth parameters. It is concluded that the proposed architecture is operationally robust and scalable, as it integrates data acquisition, storage, visualization, and automated image capture in a unified workflow. The mini-PFAL functions as a reproducible platform to verify sensors, optimize crop management, and develop databases for advanced phenotyping studies and for the optimization of a mini-PFAL.

Keywords: Data acquisition, data pipeline, ESP32, Raspberry Pi, metrological validation.

¹ Master's Thesis in Engineering, Universidad Autónoma Chapingo.
Author: José Francisco Arteaga Alarcón.
Advisor: Agustín Ruiz García.

1. INTRODUCCIÓN GENERAL

1.1 Importancia del problema

El desarrollo de sistemas alimentarios sustentables se ha convertido en una prioridad mundial debido a los desafíos sin precedentes que enfrenta la agricultura en el siglo XXI. Esta investigación explora soluciones tecnológicas avanzadas, en especial las Fábricas de Plantas con Iluminación Artificial (Plant Factories with Artificial Lighting, PFAL), como alternativa viable ante las presiones demográficas, urbanas y ambientales.

El crecimiento exponencial de la población mundial, proyectado para superar los 9,700 millones de habitantes para el año 2050, ejerce una presión crítica sobre los recursos naturales y los sistemas agroalimentarios existentes. Este desafío se incrementa debido a la concentración de la población en áreas urbanas, donde se estima que más del 68 % de la población global residirá en entornos urbanos (Diego Da Luz & Diógenes, 2025). La expansión de las ciudades ha provocado un alejamiento progresivo entre las zonas de producción y los centros de consumo, generando un notable desequilibrio entre la demanda de alimentos frescos y la capacidad de producción cercana a los centros urbanos (Diego Da Luz & Diógenes, 2025).

A esta problemática demográfica se suman los efectos adversos del cambio climático, la contaminación y la escasez hídrica, que amenazan la estabilidad y la previsibilidad del suministro alimentario. La vulnerabilidad de los sistemas agrícolas tradicionales frente a eventos climáticos extremos, crisis sanitarias y disrupciones en la logística y el transporte de alimentos ha quedado en evidencia, particularmente durante las crisis sanitarias recientes. Por ejemplo, las restricciones de movilidad y las interrupciones en las cadenas de suministro incrementaron la inseguridad alimentaria en grandes concentraciones urbanas y

subrayaron la urgencia de adoptar modelos de producción localizados (ONU, s. f.).

El esfuerzo por lograr la sostenibilidad alimentaria, alineado con los Objetivos de Desarrollo Sostenible (ODS), exige reformar los procesos de producción, distribución y consumo de alimentos. En este contexto, se impulsan estrategias que reduzcan la huella ambiental de la producción agrícola, disminuyan la dependencia de factores climáticos externos y acorten las cadenas de suministro mediante redes de distribución cortas y eficientes (Diego Da Luz & Diógenes, 2025).

Ante estos desafíos, los sistemas de cultivo en ambiente controlado (Controlled Environment Agriculture, CEA) y la agricultura vertical (AV) emergen como soluciones tecnológicas fundamentales para el futuro de la seguridad alimentaria (Dohlman *et al.*, 2024). La agricultura vertical aprovecha estructuras de producción en múltiples niveles para maximizar el rendimiento por unidad de superficie (Jeff, 2015). Las PFAL, que son un tipo de AV, se caracterizan por ser sistemas cerrados que dependen exclusivamente de la iluminación artificial.

Las ventajas productivas de las PFAL son significativas. Una instalación bien operada puede alcanzar rendimientos 100–200 veces superiores a los de campo abierto y 10–20 veces mayores que los de un invernadero hidropónico, principalmente por su operación en múltiples niveles, el control ambiental preciso y la alta densidad de plantación (Kozai *et al.*, 2016). Además, estas tecnologías contribuyen sustancialmente a la sostenibilidad, ya que las técnicas hidropónicas de recirculación empleadas en granjas verticales pueden reducir el uso de agua hasta en 90–95 % respecto a la agricultura convencional (Kozai *et al.*, 2016).

El alto grado de aislamiento y control ambiental en una PFAL permite desacoplar la producción de las condiciones meteorológicas externas, regulando con precisión la luz, la temperatura, la humedad relativa, el déficit de presión de vapor (VPD) y la concentración de CO₂. La integración sistemática de sensores, sistemas de internet de las cosas (IoT) y plataformas en la nube convierte al módulo de cultivo en un sistema de adquisición de datos que sirve tanto a la producción como a la experimentación (Kozai & Niu, 2020).

Este entorno controlado facilita el diseño, la aceleración y la reproducción de estudios sobre variables agronómicas clave, por ejemplo, combinaciones de intensidad y espectro de luz, concentración de CO₂, velocidad del aire y condiciones de humedad/VPD, con una estabilidad que difícilmente se logra a cielo abierto e incluso en muchos invernaderos convencionales (Islam *et al.*, 2021).

En el contexto nacional, el desarrollo y la implementación de PFAL son prácticamente inexistentes. Esta brecha tecnológica evidencia la necesidad urgente de impulsar la investigación, el desarrollo tecnológico y la transferencia de conocimiento desde los centros universitarios. La investigación descrita en esta tesis, mediante el diseño y la validación de una mini-PFAL experimental, aborda directamente esta necesidad al establecer la infraestructura tecnológica, reproducible y robusta, necesaria para la investigación agronómica de alta precisión en ambientes controlados.

1.2 Antecedentes

El éxito en las operaciones y la reproducibilidad científica en una PFAL dependen fundamentalmente de un sistema de monitoreo y control continuo, capaz de integrar variables ambientales, de la solución nutritiva y del cultivo en una única plataforma coherente. Los sistemas de cultivo en ambientes controlados han evolucionado desde esquemas de control de temperatura básicos hasta sofisticadas arquitecturas de IoT que integran diversas fuentes de datos.

1.2.1 El ecosistema PFAL

Un sistema de cultivo común en PFAL es del tipo técnica de película nutritiva (Nutrient Film Technique, NFT), en el cual los requerimientos nutricionales del cultivo de espinaca (*Spinacia oleracea* L.) se satisfacen mediante la recirculación de una fina película de solución nutritiva. En este contexto, el pH es un parámetro crítico que modula la disponibilidad de iones y la absorción de nutrientes, mientras que la conductividad eléctrica (CE) indica la concentración total de sales

disueltas en la solución. La estabilidad del sistema hidropónico depende de la regulación continua de dichos parámetros.

1.2.2 La implementación del Internet de las Cosas (IoT) en la Agricultura 4.0

En el diseño de plataformas experimentales, se prefieren arquitecturas de bajo costo basadas en hardware abierto, como el microcontrolador ESP32 y la Raspberry Pi 5, debido a su flexibilidad y a su capacidad de prototipado rápido (Tovar Soto *et al.*, 2022). Sin embargo, a pesar de sus ventajas, la literatura académica suele centrarse en describir la funcionalidad de los sistemas sin documentar rigurosamente información crítica sobre su fiabilidad y gobernanza de datos. Esto implica que la robustez de un sistema IoT en una PFAL no solo depende de la cantidad de sensores integrados, sino también de la calidad, la precisión y la trazabilidad metrológica de los instrumentos.

La presente tesis aborda el requisito de trazabilidad de forma integral, integrando la telemetría ambiental con el fenotipado de alto rendimiento (High-Throughput Plant Phenotyping, HTPP). Las imágenes RGB-D, capturadas mediante un robot cartesiano equipado con una cámara Intel RealSense D405, son esenciales para cuantificar la evolución del dosel y el vigor del cultivo de espinaca en condiciones controladas. Esta integración entre sensores ambientales, solución nutritiva y fenotipado automatizado es particularmente relevante en un cultivo altamente termorreactivo y fotosensible como la espinaca.

1.3 Justificación

La justificación de la investigación se basa en la necesidad de contar con una arquitectura integral de IoT que vaya más allá de solamente la conectividad de sensores e incorpore criterios de validación operativa y metrológica. Dicha arquitectura, aplicada a una mini-PFAL, proporciona un marco reproducible para la investigación de PFAL a pequeña escala en el ámbito académico.

1.3.1 La necesidad de un marco de validación operativa y metrológica

El desarrollo tecnológico en Agricultura 4.0 requiere que las plataformas de monitoreo y control demuestren no solo su capacidad para recopilar datos, sino también su fiabilidad y continuidad. Existe una brecha en la literatura académica donde el enfoque se centra predominantemente en la descripción funcional del software y el hardware, como en el diseño propuesto por Serrano *et al.* (2022), sin documentar rigurosamente la fiabilidad operativa o la brecha de datos en diferentes etapas de la cadena de medición, que abarca desde la lectura en el sensor hasta su almacenamiento.

Para garantizar la validez científica y la reproducibilidad de los experimentos en la mini-PFAL, es indispensable cuantificar y documentar la continuidad operativa, la completitud de los datos y la calidad de los registros generados. Esto exige un aseguramiento de la calidad de los datos que vaya más allá del monitoreo funcional, incorporando principios de metrología y métricas de fiabilidad comúnmente utilizadas en la gestión de mantenimiento industrial, como la completitud, el tiempo medio entre fallas (MTBF por sus siglas en ingles) y el tiempo medio de recuperación (MTTR por sus siglas en ingles). La evaluación del sistema de monitoreo y control durante un ciclo de cultivo (21 días) permite caracterizar la robustez del sistema en condiciones reales de operación e identificar fallas.

1.3.2 Justificación de la arquitectura y el flujo de datos

La arquitectura propuesta utiliza ESP32 para la adquisición, Raspberry Pi 5 para la orquestación y MariaDB para el almacenamiento , y Node-RED para la visualización en tiempo casi real y el acceso remoto (vía ngrok). Esta arquitectura se justifica por su capacidad para mantener una alta continuidad operativa e identificar la fuente de las interrupciones.

La técnica de clonación del puerto serial mediante la instrucción socat permitió ejecutar simultáneamente los procesos de almacenamiento (que calculan promedios por minuto) y de visualización (que requieren datos cuasi en tiempo

real), optimizando la gestión de datos de alta frecuencia (cada 2 s) sin sacrificar la integridad de la serie temporal.

El sistema de fenotipado automatizado complementa la justificación de la arquitectura al permitir la captura sistemática de imágenes RGB-D del cultivo. Este resultado asegura la creación de un dataset indispensable para futuros estudios de fenotipado de alto rendimiento (HTPP) basados en inteligencia artificial y visión por computadora.

1.4 Hipótesis

La hipótesis de trabajo se centra en la contribución de la ingeniería de sistemas IoT al fortalecimiento de la trazabilidad y la reproducibilidad científica en entornos de agricultura de precisión:

La arquitectura IoT diseñada e implementada para el monitoreo de la mini-PFAL alcanzará suficiente robustez operativa y calidad de los datos (completitud $\geq 90\%$) para establecer una plataforma reproducible, y será capaz de tomar imágenes RGB-D para el desarrollo de un dataset en el cultivo de espinaca..

1.4.1 Objetivo general:

Diseñar, implementar y validar operativamente una arquitectura integral de IoT para el monitoreo continuo y la adquisición de datos en una mini-PFAL, integrando variables ambientales, de la solución nutritiva y del cultivo, así como la captura automatizada de imágenes RGB-D del cultivo de espinaca.

1.4.2 Objetivos específicos

- Desarrollar e integrar una red de sensores ambientales, de solución nutritiva y de cultivo en una arquitectura modular de IoT.
- Implementar un sistema de adquisición, preprocesamiento, almacenamiento (MariaDB) y visualización (dashboard en Node-RED) que garantice la persistencia, la consulta y la trazabilidad de los datos.

- Integrar un robot cartesiano y una cámara Intel RealSense D405 para automatizar la captura de imágenes RGB-D del cultivo de espinaca a intervalos programados.
- Cuantificar la fiabilidad del sistema durante un ciclo de cultivo mediante métricas de ingeniería, como la completitud, el MTBF y el MTTR, para evaluar el desempeño operativo.
- Aplicar y evaluar un protocolo de limpieza y validación (Min, Max, $\Delta_{\text{máx}}$) para caracterizar la calidad metrológica de los datos y la utilidad de los registros para futuros análisis agronómicos y modelos predictivos.

1.5 Estructura del documento de tesis

El presente documento de tesis se estructura de la siguiente manera.

En el capítulo 2 se presenta una revisión de la literatura, incluye un análisis del estado del conocimiento sobre la agricultura vertical y las PFAL, el Internet de las Cosas (IoT) aplicado a sistemas agrícolas, así como los requerimientos ambientales específicos de la espinaca.

En el Capítulo 3 se presenta el artículo científico derivado de la investigación, y constituye el contenido sustancial del documento.

Literatura citada

- Diego Da Luz, C., & Diógenes, A. N. (2025). Plant factories with artificial lighting: Prospects for achieving sustainable development goals. *MOJ Ecology & Environmental Sciences*, 10(1), 8-13. <https://doi.org/10.15406/mojes.2025.10.00340>
- Dohlman, E. N., Maguire, K., Davis, W. V., Husby, M., Bovay, J., Weber, C. E., & Lee, Y. (2024). Trends, insights, and future prospects for production in controlled environment agriculture and agrivoltaics systems. *Economic Research Service, U.S. Department of Agriculture*. <https://doi.org/10.32747/2024.8254671.ers>
- Islam, S., Reza, M. N., Chowdhury, M., Chung, S.-O., & Choi, I.-S. (2021). A review on effect of ambient environment factors and monitoring technology for plant factory. *Precision Agriculture Science and Technology*, 3(3), 83-98. <https://doi.org/10.22765/PASTJ.20210010>

- Jeff, B. (2015). Agricultura vertical. <https://attra.ncat.org/es/publication/agricultura-vertical/>
- Kozai, T., & Niu, G. (2020). Chapter 5—Plant factory as a resource-efficient closed plant production system. En T. Kozai, G. Niu, & M. Takagaki (Eds.), *Plant Factory (Second Edition)* (pp. 93-115). Academic Press. <https://doi.org/10.1016/B978-0-12-816691-8.00005-4>
- Kozai, T., Niu, G., & Takagaki, M. (2016). *Plant factory: An indoor vertical farming system for efficient quality food production*. Elsevier/AP, Academic Press is an imprint of Elsevier.
- ONU. (s. f.). Alimentación | Naciones Unidas. United Nations; United Nations. Recuperado 16 de noviembre de 2025, de <https://www.un.org/es/global-issues/food>
- Serrano, L. T. C., Gómez-Águila, M. V., Paniagua, F. S., Suárez, J. A. C., & Rodríguez, A. M. (2022). Software Engineering for a Mini-PFAL (Plant Factory with Artificial Lighting) with IoT Interconnectivity. *Revista Ciencias Técnicas Agropecuarias*, 31(3). <https://revistas.unah.edu.cu/index.php/rcta/article/view/1642>
- Tovar Soto, J. P., Pareja Figueredo, C. F., & Gutiérrez Martínez, L. C. (2022). Tecnologías de IoT eficaces para una plataforma de agricultura 4.0. *Ingeniare*, 31. <https://doi.org/10.18041/1909-2458/ingeniare.31.8936>

2. REVISIÓN DE LITERATURA

2.1 Fundamentos agricultura vertical y PFAL

La agricultura, practicada desde hace unos 10 000 años, permitió a las sociedades humanas organizarse y prosperar al garantizar el suministro de alimentos mediante el manejo cooperativo de tierras fértiles. Sin embargo, el crecimiento poblacional y la expansión urbana han reducido la disponibilidad de tierra cultivable por persona, generando desequilibrios en la producción alimentaria. Se estima que para 2050 la población mundial superará los 9 000 millones, con un 70 % viviendo en ciudades, lo que incrementará la demanda de alimentos, la generación de residuos y las emisiones de gases de efecto invernadero (Chaudhry & Mishra, 2019; Vatistas *et al.*, 2022).

El cambio climático, la contaminación y la escasez de recursos amenazan la estabilidad del suministro alimentario; además, la pandemia de COVID-19 evidenció la vulnerabilidad de las grandes ciudades ante crisis globales, al interrumpir las cadenas de suministro y aumentar la inseguridad alimentaria (Pulighe & Lupia, 2020). En las hortalizas de hoja, el cultivo a cielo abierto presenta variaciones en calidad y rendimiento, mientras que los invernaderos, aunque más productivos, generan emisiones por el uso intensivo de agroquímicos y combustibles fósiles. Por ello, los sistemas de cultivo en ambiente controlado, especialmente en zonas urbanas, surgen como una alternativa sostenible que reduce pérdidas, costos y distancia entre producción y consumo, sentando las bases para el desarrollo de la agricultura vertical y urbana (Kozai, 2013).

En la década de 1930, William Gericke estableció las bases de la hidroponía moderna. Décadas después, en los años 1960, Othmar Ruthner diseñó los primeros invernaderos verticales basados en sistemas hidropónicos, aunque su adopción fue limitada debido al alto consumo energético y los costos de mantenimiento. A comienzos del siglo XXI, Dickson Despommier retomó y modernizó este concepto, presentándolo como una estrategia para fortalecer la seguridad alimentaria ante el crecimiento urbano global. En paralelo, en Japón, Toyoki Kozai y su equipo avanzaron en la creación de sistemas cerrados de

producción vegetal multicapa con iluminación artificial, sentando las bases tecnológicas de las actuales fábricas de plantas (PFAL) (Van Gerrewey *et al.*, 2022).

2.1.1 Agricultura vertical

En su forma más básica, la agricultura vertical consiste en cultivar plantas en múltiples niveles con el objetivo de maximizar el rendimiento por unidad de superficie. De acuerdo con Sharath Kumar *et al.* (2020), una agricultura vertical es un sistema de producción interior de múltiples capas donde todos los factores de crecimiento como: luz, temperatura, humedad, concentración de CO₂, agua y nutrientes, se controlan de manera precisa para generar, durante todo el año, grandes volúmenes de productos frescos y de alta calidad, sin depender de la luz solar ni de las condiciones externas (Van Gerrewey *et al.*, 2022).

Estas granjas pueden clasificarse según su escala y finalidad productiva (Butturini & Marcelis, 2020; Chaudhry & Mishra, 2019; Van Gerrewey *et al.*, 2022).

- a) Edificios reutilizables adaptativos: antiguos edificios, fábricas, almacenes o estacionamientos que se reacondicionan con equipamiento especializado para albergar sistemas de cultivo interior.
- b) Fábricas de plantas con iluminación artificial (PFAL): instalaciones diseñadas específicamente para la producción a gran escala, con control total de las condiciones ambientales y energéticas.
- c) Contenedores modulares: unidades marítimas adaptadas con estanterías verticales, iluminación LED y sistemas de monitoreo digital, destacadas por su movilidad y capacidad de apilamiento.
- d) Granjas en tienda: sistemas compactos ubicados en puntos de venta o consumo (restaurantes, supermercados, cafeterías) que permiten ofrecer productos frescos de manera local.
- e) Granjas domésticas: versiones a pequeña escala para uso residencial u oficinas, orientadas al autoconsumo.

- f) Granjas subterráneas: infraestructuras instaladas en túneles, estaciones o minas en desuso, que aprovechan espacios subterráneos con control artificial de las condiciones de cultivo.
- g) Balcones y azoteas: superficies planas o abiertas de edificios destinadas a sistemas verticales simplificados o modulares, promoviendo la producción urbana y el aprovechamiento del espacio aéreo disponible.

2.1.2 Definición de PFAL y su importancia

Kozai (2019) define a las plant factories with artificial light (PFAL) como sistemas cerrados de producción vegetal que operan bajo condiciones ambientales totalmente controladas. A diferencia de otros sistemas de agricultura interior o vertical, las PFAL dependen exclusivamente de la iluminación artificial. Este tipo de instalación, ampliamente utilizada en Japón para la producción comercial de hortalizas de hoja, cumple con seis criterios fundamentales: (1) las paredes y techos son completamente opacos, utilizando exclusivamente luz artificial como fuente de iluminación; (2) la sala de cultivo mantiene una hermeticidad casi total; (3) las superficies cuentan con aislamiento térmico; (4) el cultivo se realiza mediante sistemas hidropónicos; (5) el acceso está restringido a personal desinfectado que ingresa por una ducha de aire; y (6) se lleva un control estricto y documentado de patógenos, insectos y pequeños animales.

Los sistemas PFAL tienen como objetivo maximizar la eficiencia en el uso de la radiación, la productividad de los cultivos y la estabilidad en el rendimiento y calidad, reduciendo al mismo tiempo la emisión de contaminantes ambientales y el manejo cuidadoso de la solución nutritiva para prevenir la proliferación de algas y el exceso de humedad en la sala de cultivo. Además de las PFAL comerciales convencionales, existen variantes como las PFAL ventiladas y las mini- o micro-PFAL (m-PFAL), empleadas principalmente con fines educativos, de investigación o demostración (Kozai & Niu, 2016).

En términos de productividad anual por unidad de superficie, una PFAL bien operada puede alcanzar rendimientos 100–200 veces superiores a los de campo abierto y 10–20 veces mayores que los de un invernadero hidropónico. En instalaciones con diez niveles de cultivo, se logran aproximadamente 2500 lechugas/m² por año (unos 200 kg/m² de peso fresco). Esta alta productividad se debe a factores como: (1) el uso de múltiples niveles de cultivo (10–15); (2) control ambiental preciso que estimula el crecimiento; (3) ausencia de daños por plagas o clima; (4) alta densidad de plantación; y (5) ciclos continuos de producción, donde la siembra y la cosecha se realizan el mismo día, permitiendo un uso ininterrumpido del espacio durante todo el año. Además, el precio mayorista por kilogramo suele ser un 30 % superior al de los productos de invernadero, debido a la limpieza, homogeneidad y calidad sanitaria del producto. El sistema también permite ajustar la velocidad de crecimiento de las plantas para responder a la demanda del mercado o a los costos de operación (Kozai, 2016). La agricultura vertical se está convirtiendo cada vez más en una necesidad para la agricultura, debido al crecimiento demográfico, la escasez de espacio agrícola y la disminución de los recursos naturales. Esta tecnología también ha demostrado su capacidad para aumentar los rendimientos y garantizar la producción durante todo el año (Nájera *et al.*, 2023).

Aunque las PFAL aún se encuentran en desarrollo, presentan un gran potencial para lograr una producción agrícola intensiva y sostenible en entornos urbanos. Su principal ventaja científica es la posibilidad de realizar múltiples ciclos de cultivo anuales en condiciones totalmente controladas, lo que acelera la investigación y mejora las prácticas agronómicas en comparación con los sistemas tradicionales dependientes del clima (Kozai & Niu, 2016).

Según Flores *et al.* (2022), en México el desarrollo e implementación de PFAL es prácticamente inexistente. Esta situación evidencia la urgente necesidad de impulsar la investigación, el desarrollo tecnológico y la transferencia de conocimiento desde los centros de investigación, universidades, dependencias gubernamentales y el sector productivo. El objetivo es que, en el corto plazo, la producción de cultivos en sistemas PFAL se consolide como una alternativa

viable y sostenible dentro del contexto agrícola nacional (Herrera & Velazquez, 2024).

2.2 Fotometría y radiometría hortícola

2.2.1 La luz en las plantas

La percepción de la luz permite a los organismos vegetales adaptarse a las variaciones en la iluminación ambiental, influyendo de manera directa en procesos fisiológicos como la morfogénesis, la fotosíntesis y los mecanismos de protección ante radiaciones dañinas. La mayoría de las especies vegetales presentan respuestas diferenciadas ante la calidad espectral de la luz (color o longitud de onda), su intensidad (densidad de flujo fotónico o irradiancia) y la interacción entre ambos factores. La luz regula múltiples características estructurales de las plantas, como la arquitectura general, la forma de las hojas, la altura, la floración y la producción de semillas (Blanco-Valdés, 2019; Duarte & Maldonado, 2022).

El Sol emite un espectro amplio de radiación que incluye fotones de luz ultravioleta (UV; 280–399 nm), azul (B; 400–499 nm), verde (G; 500–599 nm), roja (R; 600–699 nm) y rojo lejano (FR; 700–750 nm). Cada una de estas bandas espectrales ejerce efectos específicos e interactivos sobre el crecimiento y desarrollo de las plantas (Stallknecht & Runkle, 2025).

Los pigmentos vegetales poseen una absorbancia específica para ciertas longitudes de onda, conocida como su espectro de absorción. En particular, las clorofilas a y b presentan una alta absorción en las regiones roja y azul del espectro visible, mientras que absorben menos en la región verde, razón por la cual las hojas reflejan ese color característico. Además, la longitud de onda de la luz incidente influye directamente en la eficiencia fotosintética: el Fotosistema I (PSI) muestra una absorción máxima cercana a los 700 nm, y el Fotosistema II (PSII) a alrededor de 680 nm. La mayor energía asociada a estas longitudes de onda favorece una tasa fotosintética más elevada, optimizando la conversión de energía luminosa en energía química durante la fotosíntesis (Ouzounis *et al.*, 2015).

La luz roja (600-700 nm) favorece una mayor actividad fotosintética, incrementando la biomasa y acelerando la floración; además, las plantas bajo este tipo de iluminación tienden a ser más altas, con tallos flexibles y numerosas hojas. En cultivos como la lechuga, se ha observado que la luz roja monocromática puede satisfacer parcialmente los requerimientos de crecimiento, rendimiento y calidad, aunque diversas investigaciones demuestran que la combinación de luz roja y azul (R/B) resulta más efectiva para incrementar la tasa fotosintética neta.

La luz verde (500-600 nm) puede penetrar las capas inferiores del dosel vegetal, aumentando la asimilación de carbono, el contenido de clorofila y los niveles de ácido ascórbico. Por su parte, la luz rojo lejano (>700 nm) modifica la morfología del dosel, incrementando la distribución interna de la luz y favoreciendo el crecimiento estructural. Por otro lado, la luz azul (400-500 nm) estimula principalmente el crecimiento vegetativo, aunque suele reducir la altura y el número de hojas, presentando también menores tasas de germinación en comparación con la exposición al rojo (Chen *et al.*, 2021; Duarte & Maldonado, 2022; Orsini *et al.*, 2020).

2.2.2 La radiación fotosintéticamente activa (PAR)

La radiación fotosintéticamente activa (PAR, por sus siglas en inglés) corresponde al rango del espectro lumínico entre 400 y 700 nm, considerado esencial para el proceso fotosintético (McCree, 1971, 1972). Dentro de este intervalo, las regiones roja y azul son las que estimulan con mayor eficiencia la fotosíntesis.

La medición de la luz en sistemas hortícolas de ambiente controlado se apoya en dos magnitudes cuánticas principales: el flujo de fotones fotosintéticos (PPF, Photosynthetic Photon Flux) y la densidad de flujo de fotones fotosintéticos (PPFD, Photosynthetic Photon Flux Density). El PPF describe la cantidad total de fotones emitidos por una fuente de luz en el rango PAR (400–700 nm) por unidad de tiempo ($\mu\text{mol s}^{-1}$), por lo que constituye una propiedad intrínseca de la luminaria (ANSI/ASABE, 2017). En contraste, la PPFD cuantifica el número de

fotones fotosintéticamente activos que inciden sobre una superficie determinada, por ejemplo, el dosel del cultivo, por unidad de área y de tiempo ($\mu\text{mol m}^{-2} \text{s}^{-1}$), y se reconoce como la métrica operativa clave para relacionar la intensidad de luz con el crecimiento y el rendimiento de los cultivos (Bugbee, 2016; Liu & van Iersel, 2021; Ouzounis *et al.*, 2015; Thakur & Kumar, 2021).

2.2.3 Espectros de radiación y calidad lumínica

La calidad espectral describe la distribución relativa de las longitudes de onda dentro del flujo de radiación incidente. En agricultura vertical no solo importa cuánta luz recibe el cultivo (por ejemplo, PPFD), sino también de qué colores está compuesta, porque cada banda espectral activa de manera diferencial los fotorreceptores y, en consecuencia, los procesos de fotomorfogénesis (arquitectura del dosel, elongación, ángulo y tamaño de hojas) y la síntesis de metabolitos secundarios como fenoles, flavonoides o antocianinas (Bantis *et al.*, 2018; Folta & Maruhnich, 2007; Ouzounis *et al.*, 2015). En este contexto, la calidad espectral se vuelve una herramienta de manejo tanto para el rendimiento como para la calidad nutricional y funcional del producto cosechado.

La base fisiológica clásica para entender qué longitudes de onda son más eficientes en términos fotosintéticos es la curva de acción fotosintética de McCree. A partir de experimentos con 22 especies de cultivos bajo radiación casi monocromática, McCree (1972) cuantificó la eficiencia cuántica relativa de la fotosíntesis en el intervalo de 400 a 700 nm, definiendo lo que hoy se conoce como radiación fotosintéticamente activa (PAR). Su curva muestra dos picos de eficiencia bien marcados: uno en la región azul (440-460 nm) y otro en la región roja (640-680 nm), mientras que la eficiencia relativa disminuye de forma notable en la zona verde (510-570 nm) (Bugbee, 2016; McCree, 1972). Esto explica por qué las hojas, que reflejan y transmiten buena parte de la luz verde, se perciben de ese color, aunque estudios más recientes matizan que el verde también contribuye a la fotosíntesis en capas profundas del dosel (Folta & Maruhnich, 2007; Johkan *et al.*, 2012).

La interpretación moderna de la curva de McCree, retomada por Bugbee (2016) y otros autores (Figura 2.1), subraya que la forma del espectro no solo afecta la tasa fotosintética instantánea, sino también la captura de radiación a nivel de dosel completo, la distribución de biomasa entre órganos y la eficiencia en el uso de la luz.




Figura 2.1. Curvas de eficiencia fotosintética relativa según Hoover (1937), McCree (1972) e Inada (1976). Los puntos negros indican las longitudes de onda medidas; las curvas de McCree e Inada representan rendimiento cuántico por fotón absorbido, y la de Hoover, por fotón incidente. Adaptada de Bugbee (2016).

En consecuencia, el diseño de la iluminación hortícola basada en LED se apoya en esta información para concentrar la potencia eléctrica en las bandas espectrales más efectivas (azul y rojo), al tiempo que ajusta porciones de verde o rojo lejano cuando se busca modular arquitectura, compactación de plantas o

respuestas de sombreado (Bantis *et al.*, 2018; Massa *et al.*, 2008; Ouzounis *et al.*, 2015).

Así, la curva de McCree deja de ser solo una descripción fisiológica y se convierte en un marco de diseño ingenieril: permite traducir la energía eléctrica consumida por una luminaria en flujo de fotones útiles para la fotosíntesis, maximizando la conversión de electricidad en biomasa y, al mismo tiempo, aprovechando la calidad espectral como una “señal” para dirigir el desarrollo estructural y metabólico de las plantas (Bugbee, 2016; Sena *et al.*, 2024).

2.2.4 La iluminación en las PFAL

Las tecnologías sostenibles aplicadas a los sistemas PFAL, como la iluminación LED, constituyen una innovación clave en la agricultura moderna, al garantizar una provisión controlada y suficiente de luz para el crecimiento y desarrollo óptimo de las plantas. De acuerdo con Kikuchi *et al.* (2018), los sistemas de agricultura vertical se clasifican en dos tipos principales según la fuente de luz empleada para satisfacer los requerimientos de fotosíntesis y fotoperiodo: las Fábricas de Plantas con Luz Solar (PFSL) y las Fábricas de Plantas con Luz Artificial (PFAL) (Orsini *et al.*, 2020).

Las variaciones espaciales en la intensidad y la distribución espectral de la luz provocan diferencias en el desarrollo morfológico y fisiológico de las plantas dentro de un mismo cultivo. Esta heterogeneidad en el crecimiento genera desbalances en el rendimiento y la productividad, lo que disminuye la eficiencia y rentabilidad de los sistemas de cultivo en interiores. La uniformidad lumínica depende principalmente de tres factores técnicos: el diseño óptico de la luminaria, la altura de instalación respecto al dosel del cultivo y la disposición horizontal de las fuentes de luz. Una correcta configuración de estos parámetros es esencial para garantizar una distribución homogénea del flujo fotónico, optimizando así el aprovechamiento de la radiación fotosintéticamente activa en todo el sistema (Boros *et al.*, 2023).

La manipulación del espectro lumínico constituye una estrategia con alto potencial para mejorar el crecimiento vegetal. En los sistemas PFAL, las lámparas

deben reproducir el fotoperiodo natural de cada especie, es decir, el número de horas continuas de luz necesarias para su desarrollo. Este parámetro varía según el cultivo y las condiciones ambientales, por lo que su control preciso es esencial para mantener los ritmos fisiológicos y optimizar el crecimiento vegetal (Duarte & Maldonado, 2022).

Los LED son fuentes de luz de estado sólido, altamente duraderas y estables, capaces de emitir radiación dentro de un espectro estrecho y controlable, que abarca desde el ultravioleta hasta el infrarrojo. Además, su vida útil puede alcanzar hasta 100 000 horas. Con el creciente uso de LED en invernaderos, se prevé una reducción progresiva de los costos y un mayor interés en su aplicación científica, especialmente como herramienta experimental para el control preciso de la luz en estudios de fisiología y productividad vegetal (Ouzounis *et al.*, 2015). En los sistemas de cultivo de interior, las luminarias LED suelen combinar diferentes colores para equilibrar el crecimiento estructural y la eficiencia fotosintética. Las lámparas con proporciones altas de luz roja y azul tienden a producir plantas compactas, con tallos robustos y alta densidad foliar (Duarte & Maldonado, 2022).

2.2.5 Instrumentación y calibración metrológica

La gestión de la iluminación en sistemas PFAL requiere una metrología óptica precisa y reproducible, con el fin de garantizar la uniformidad espacial del PPFD, la exactitud de la dosis diaria de luz (DLI) y la repetibilidad experimental (Bugbee, 2016; Kozai *et al.*, 2019; Mitchell & Sheibani, 2020). Los sensores utilizados se clasifican según el tipo de medición que realizan: aquellos que registran la cantidad total de fotones fotosintéticamente activos, como los cuantómetros o sensores PAR, y los que determinan la distribución espectral de la radiación, como los espectrorradiómetros (ANSI/ASABE, 2017; Sager *et al.*, 1988).

Los sensores PAR cuánticos miden la densidad de PPFD mediante fotodiodos filtrados que reproducen la respuesta promedio del rango PAR (400–700 nm) (Kusuma *et al.*, 2020). Son instrumentos económicos y robustos, adecuados para invernaderos o monitoreos extensivos; sin embargo, su precisión espectral

disminuye cuando el espectro de la fuente difiere del espectro de calibración, como ocurre en luminarias LED monocromáticas rojo-azul (Zhen & Bugbee, 2020). En cambio, los espectrorradiómetros registran la densidad de flujo radiante en función de la longitud de onda y permiten una caracterización precisa de fuentes complejas (300–1100 nm), siendo esenciales para la investigación y calibración de sistemas LED hortícolas (Nelson & Bugbee, 2015; Sager *et al.*, 1988). Finalmente, los sensores fotométricos o luxómetros, que miden iluminancia ponderada por la sensibilidad visual humana, carecen de valor agronómico, pues no representan la eficiencia fotosintética real de la radiación incidente (Zavafer *et al.*, 2023).

En los últimos años se han desarrollado sensores cuánticos extendidos (ePAR) que cuantifican el flujo de fotones en rangos ampliados, típicamente de 400 a 750 nm, con el fin de incorporar explícitamente la contribución del rojo lejano a los procesos fotosintéticos y fotomorfogénicos. Un ejemplo es el MQ-610 (Apogee Instruments), un medidor ePAR diseñado para aplicaciones de investigación en fisiología de cultivos, que integra el flujo fotónico incidente en dicho intervalo espectral y lo reporta en unidades de densidad de flujo de fotones ($\mu\text{mol m}^{-2} \text{s}^{-1}$).

2.3 Fundamentos del monitoreo ambiental en PFAL

El monitoreo ambiental en los sistemas de PFAL constituye el pilar fundamental que asegura la reproducibilidad de las condiciones de crecimiento, la estabilidad fisiológica del cultivo y la eficiencia en el uso de los recursos (Graamans *et al.*, 2018; Kozai *et al.*, 2019). Su objetivo principal es establecer un control automatizado en lazo cerrado, capaz de reducir la variabilidad espacial y temporal de los factores ambientales, garantizando que cada planta reciba la dosis óptima de radiación, agua y nutrientes (Wheeler, 2024).

2.3.1 Alcance del monitoreo y variables críticas

El monitoreo ambiental en sistemas PFAL abarca el registro continuo de los factores físicos, químicos y biológicos que determinan la fotosíntesis, la morfología vegetal y la sanidad del cultivo (Kozai *et al.*, 2019; Morella *et al.*, 2023).

Las variables se agrupan en tres categorías principales: ambientales, nutricionales e infraestructurales, todas ellas interconectadas dentro del control en lazo cerrado del sistema (Herrera & Velazquez, 2024).

Luz

La radiación fotosintéticamente activa (PAR) es el motor primario del crecimiento vegetal. Su monitoreo debe incluir la densidad de flujo de fotones fotosintéticamente activos (PPFD), la integral diaria de luz (DLI), el espectro extendido (ePAR, 380–760 nm) y la uniformidad espacial del campo lumínico (Bugbee, 2016; Kusuma *et al.*, 2020). El DLI representa la energía total recibida en 24 h, y se considera un indicador clave de desempeño (KPI) para estimar la tasa de fotosíntesis y la acumulación de biomasa (Nelson & Bugbee, 2015). En PFAL, la precisión de estas mediciones es esencial para ajustar la intensidad de los LED, la altura de montaje y la fotoperiodicidad (Kozai, 2018).

Clima

El microclima de la cámara de cultivo influye directamente en la transpiración, la absorción de nutrientes y la eficiencia fotosintética. Las variables críticas incluyen la temperatura del aire (T_a), la humedad relativa (RH) y la concentración de CO_2 , complementadas con la temperatura de la hoja (T_l), la velocidad/dirección del aire y el cálculo del déficit de presión de vapor (VPD) (Graamans *et al.*, 2018; Park & Runkle, 2018). Un control preciso del VPD permite mantener el balance hídrico y evitar el estrés fisiológico, optimizando tanto la fotosíntesis como la transpiración (Gruda, 2019).

Solución nutritiva

El pH y la conductividad eléctrica (CE) son parámetros esenciales del manejo nutrimental en hidroponía. El pH regula la disponibilidad iónica de los nutrientes esenciales, afectando la absorción de macro y micronutrientes, mientras que la CE indica la concentración total de sales disueltas, reflejando la fuerza iónica y osmótica de la solución (González *et al.*, 2016).

Sanidad y energía

El alcance del monitoreo también comprende variables de infraestructura y bioseguridad. La medición del consumo energético por subsistema (LED, HVAC,

bombas, ventiladores) es clave para evaluar la eficiencia energética global del sistema (Kozai *et al.*, 2019). Asimismo, parámetros opcionales como el conteo de partículas (PM) o esporas en aire permiten estimar el riesgo de contaminación en sistemas cerrados (Boros *et al.*, 2023). El ORP y la turbidez del agua actúan como indicadores indirectos de sanidad del sistema hidráulico y de la efectividad de los procesos de desinfección (Fuentes-Peñailillo *et al.*, 2024).

En conjunto, estas variables conforman la base metrológica del control ambiental inteligente en PFAL, integrando información cuantitativa para la optimización de crecimiento vegetal, el uso eficiente de recursos y la trazabilidad experimental.

2.3.2 Estrategia de muestreo espacial y redundancia

La calidad del control ambiental y la seguridad operativa en sistemas PFAL dependen directamente de la distribución, densidad y confiabilidad de los sensores instalados (Kozai *et al.*, 2019; Padhiary *et al.*, 2025). Un sistema de monitoreo mal distribuido puede producir sesgos en las lecturas de temperatura, humedad o PPFD, comprometiendo el control en lazo cerrado y la reproducibilidad de los ensayos.

Muestreo vertical

La ubicación de sensores en el eje vertical debe considerar dos alturas críticas. A nivel del dosel, donde se concentra el intercambio gaseoso y se evalúan los gradientes reales de temperatura foliar y transpiración (Park & Runkle, 2018). El siguiente, entre 5 y 10 cm por encima del dosel, para registrar el gradiente vertical de temperatura, humedad relativa y CO₂, parámetro esencial para diagnosticar la eficiencia del flujo de aire y la ventilación horizontal (Graamans *et al.*, 2018). El análisis de este gradiente permite comprender la dinámica de la capa límite de la hoja, donde ocurren la difusión de vapor y el enfriamiento evaporativo, indicadores directos del estrés térmico (Katul *et al.*, 2012).

Muestreo horizontal

La uniformidad espacial de la luz es tan determinante como su intensidad media. Para caracterizarla, se emplean cuadrículas de muestreo de entre 9 y 25 puntos por módulo o bandeja, según la superficie iluminada (Bugbee, 2016; Kusuma *et*

al., 2020). La disposición de los elementos debe cubrir las zonas directamente bajo las luminarias y las intermedias, donde se producen los valles de irradiancia causados por interferencia óptica. Un mapeo denso del PPFD permite calcular la desviación estándar relativa ($<10\%$), criterio aceptado de uniformidad luminosa en investigación hortícola (Nelson & Bugbee, 2015).

Redundancia y tolerancia a fallas

La redundancia instrumental constituye la base del aseguramiento metrológico en PFAL. Se recomienda disponer de al menos un sensor patrón o calibrado por sala, y múltiples sensores operativos por nivel o piso, de modo que la pérdida de un sensor no interrumpa la observabilidad del proceso (ANSI/ASABE, 2017). Esta estrategia sigue la filosofía de la tolerancia a fallas, donde el sistema mantiene su funcionalidad mediante fuentes de datos alternativas. La selección óptima de emplazamientos y el número mínimo de sensores son el resultado de un problema de optimización multicriterio, que busca un grado de redundancia aceptable al menor costo operativo posible (Kozai *et al.*, 2019; Mitchell & Sheibani, 2020; Wheeler, 2024).

Instrumentación por variable

La selección de la instrumentación debe equilibrar el costo con la precisión requerida para mantener la trazabilidad y la reproducibilidad agronómica. En contextos de agricultura protegida y sistemas PFAL, los sensores de grado metrológico permiten garantizar la validez de los datos y su comparabilidad en el tiempo (Llewellyn *et al.*, 2022). Por el contrario, el uso de instrumentos de baja calidad puede introducir sesgos sistemáticos que comprometen la interpretación fisiológica y energética del sistema.

Luz (PPFD, DLI, Espectro)

La medición de la densidad de PPFD y de la dosis diaria de luz (DLI) requiere cuantómetros ePAR/PAR de grado metrológico o de investigación, como los modelos Apogee SQ-500 o LI-COR LI-190R (Llewellyn *et al.*, 2022). Estos dispositivos están diseñados para minimizar dos fuentes críticas de error: el error espectral, especialmente relevante bajo iluminación LED de espectro estrecho, y

el error direccional asociado a la Ley del Coseno (Eo *et al.*, 2022). Ambos errores afectan la cuantificación absoluta de la radiación incidente y, por ende, la estimación del DLI efectivo en el dosel. Los sensores de baja calidad sólo ofrecen mediciones relativas, y un error elevado de Ley del Coseno puede subestimar la radiación en ángulos oblicuos, distorsionando los mapas de uniformidad lumínica y reduciendo la dosis fotosintéticamente útil en los bordes del cultivo (Barnes *et al.*, 1993). La caracterización espectral debe realizarse mediante un espectrorradiómetro de laboratorio para auditoría y verificación de setpoints; para control en tiempo real —por ejemplo, ajuste de proporciones Rojo/Azul o R/FR— pueden emplearse fotodiodos de banda estrecha (Eo *et al.*, 2022).

Clima

La medición microclimática requiere sensores con trazabilidad metrológica. Para temperatura (T) y humedad relativa (RH) se recomiendan sensores tipo Vaisala HMP110, y para CO₂, sensores NDIR como GMP252 que incluyan autocalibración o protocolos de calibración periódica externa para compensar la deriva a largo plazo (Dubey *et al.*, 2024; Martin *et al.*, 2017). La tecnología NDIR es considerada estándar por su estabilidad y linealidad, aunque la deriva térmica y la contaminación de la celda óptica pueden introducir errores si no se corrigen regularmente.

La velocidad del aire a nivel de dosel suele mantenerse en el rango 0.2-0.5 m s⁻¹; para dichos valores, los anemómetros térmicos o de hilo caliente son los más adecuados por su alta sensibilidad en flujos laminares bajos (López *et al.*, 2012).

Por su parte, la temperatura de la hoja constituye un indicador sensible de estrés fisiológico y de eficiencia evaporativa. Su medición mediante termometría infrarroja o termografía térmica requiere corregir la emisividad foliar (ϵ) y considerar los reflejos de radiación IR provenientes de las luminarias LED (Chen, 2015; Khorsandi *et al.*, 2018). Las diferencias en emisividad entre especies pueden generar errores mayores a 1 °C, lo que justifica calibraciones específicas por tipo de follaje (Chen, 2015).

Solución nutritiva y energía

En sistemas hidropónicos, los sensores de pH y conductividad eléctrica (CE) deben incorporar compensación automática por temperatura, ya que la CE varía aproximadamente 2 % por °C (GetGrowee, 2024). Se recomiendan electrodos de vidrio aislados para minimizar el ruido eléctrico y celdas de CE con constante 1.0-2.0 cm⁻¹, calibradas con soluciones patrón. El caudal y el nivel de solución pueden determinarse mediante sensores ultrasónicos, magnéticos o de presión.. En la gestión energética, la medición de potencia activa (kW), factor de potencia (PF) y consumo (kWh) en cada subsistema se realiza mediante pinzas RMS o medidores industriales con protocolo Modbus, permitiendo calcular el indicador clave de eficiencia energética (kWh kg⁻¹) (Duffy, 2019; Younesi-Alamouti *et al.*, 2021). Dichos indicadores son esenciales para evaluar la sostenibilidad operativa y la huella energética de las instalaciones de producción intensiva.

En conjunto, este sistema de instrumentación calibrado y trazable constituye la base de un monitoreo robusto, garantizando la reproducibilidad experimental y la gestión eficiente de los recursos energéticos y nutricionales en entornos controlados (Llewellyn *et al.*, 2022).

2.3.3 Metrología y aseguramiento de Calidad (QA/QC)

El rigor metrológico es lo que diferencia una PFAL de un invernadero tradicional, permitiendo una trazabilidad científica de los resultados.

Trazabilidad y deriva

La trazabilidad metrológica de los instrumentos se establece mediante certificados de calibración emitidos por organismos acreditados bajo normas internacionales, como la ISO 17025, que garantizan la conexión de las mediciones con patrones nacionales o internacionales (OIML, 2021). Dichos certificados aseguran que la incertidumbre de la medición esté cuantificada y documentada, y permiten mantener la comparabilidad de los datos entre diferentes instalaciones o periodos de medición (NIST, 2025).

La deriva es un cambio gradual en la respuesta del sensor a lo largo del tiempo debido a envejecimiento de componentes, contaminación óptica o variaciones

termoeléctricas (Dubey *et al.*, 2024; Martin *et al.*, 2017). En sensores ópticos o de gases, esta deriva puede alcanzar entre 1 y 5 % mensual si no se gestiona mediante recalibraciones o procedimientos de ajuste con referencia externa. Su manejo adecuado es crítico para garantizar la validez de los datos y la estabilidad de los modelos de control ambiental (NIST, 2025).

Por ello, se deben establecer intervalos estrictos de recalibración, definidos según la estabilidad del instrumento y su entorno operativo: para sensores PAR/ePAR, la recalibración se recomienda cada 12-24 meses, mientras que para sensores de CO₂ (NDIR) debe realizarse cada 6-12 meses (Llewellyn *et al.*, 2022). En entornos de producción intensiva, estos intervalos pueden acortarse debido a la exposición a alta humedad, polvo o radiación prolongada. La documentación de cada calibración, incluyendo fecha, patrón de referencia, incertidumbre y ajustes aplicados, forma parte esencial del aseguramiento metrológico del sistema (OIML, 2021).

2.4 Arquitecturas IoT y pipelines de datos en PFAL

La PFAL representa el estadio más avanzado dentro del marco de la agricultura en ambientes controlados (CEA por sus siglas en inglés). Se caracteriza por ser una instalación completamente cerrada, ópticamente opaca y aislada del ambiente externo, diseñada para eliminar las variaciones meteorológicas y mantener condiciones estables de producción (Graamans *et al.*, 2018; Kozai, 2013). Este nivel de aislamiento convierte a la PFAL en un entorno donde todos los factores de crecimiento: radiación, temperatura, humedad, CO₂ y nutrientes, pueden ser controlados con precisión.

El éxito operativo de la PFAL depende de su evolución hacia un Sistema Ciberfísico (CPS), donde los procesos físicos (crecimiento vegetal, intercambio de energía y masa) están estrechamente acoplados con los procesos computacionales (sensado, control y analítica de datos). En este contexto, el Internet de las Cosas (IoT) actúa como habilitador esencial de la Agricultura 4.0, proporcionando tanto la observabilidad (medición continua de alta resolución)

como la controlabilidad (ejecución de comandos precisos) necesarias para la optimización adaptativa de los sistemas productivos (Wolfert *et al.*, 2017).

El objetivo fundamental de esta arquitectura es garantizar la trazabilidad completa de los datos, maximizar la eficiencia energética y mantener el control preciso de variables críticas en entornos totalmente cerrados. Entre las variables de monitoreo más relevantes se incluyen la temperatura (T), la humedad relativa (HR), la concentración de CO₂, la radiación fotosintéticamente activa (PAR), el déficit de presión de vapor (VPD), así como el pH y la conductividad eléctrica (CE) de la solución nutritiva (Kozai & Niu, 2016). La reproducibilidad de las condiciones de crecimiento es el factor determinante para lograr productos homogéneos y predecibles. La literatura reciente sobre PFAL enfatiza que la trazabilidad y la previsibilidad dependen directamente de la fiabilidad metrológica del sistema de sensado y control (Llewellyn *et al.*, 2022).

2.4.1 Fundamentos y objetivos del IoT agrícola en PFAL

Definición y aplicación específica

El Internet de las Cosas aplicado a la agricultura (IoT agrícola) se define como una red de objetos físicos interconectados que integran sensores, actuadores y módulos de comunicación digital capaces de recopilar, transmitir y procesar datos en tiempo real (Alahmad *et al.*, 2023). En las PFAL, la implementación del IoT permite un control ambiental de alta resolución en entornos completamente cerrados, caracterizados por la disposición vertical de múltiples niveles de cultivo (Rathor *et al.*, 2024). La complejidad estructural de estos sistemas exige arquitecturas modulares y escalables que garanticen la uniformidad de las condiciones microclimáticas entre capas, dado que incluso pequeñas desviaciones en la temperatura, humedad o radiación fotosintéticamente activa pueden comprometer la uniformidad del crecimiento y la productividad final (Kozai, 2016; Panotra *et al.*, 2024).

Objetivos estratégicos y ventajas

La implementación del IoT en las PFAL persigue una serie de objetivos operacionales y estratégicos orientados a optimizar la eficiencia y

reproducibilidad del sistema de cultivo. En primer lugar, el monitoreo continuo de variables críticas como: temperatura, humedad relativa, concentración de CO₂, pH, conductividad eléctrica y radiación fotosintéticamente activa, permite mantener el ambiente dentro de rangos óptimos para la fisiología vegetal (Alahmad *et al.*, 2023; Rathor *et al.*, 2024). En segundo lugar, el control automatizado en lazo cerrado traduce los datos capturados en tiempo real en acciones inmediatas sobre iluminación LED, ventilación, fertirrigación y dosificación de CO₂, reduciendo la variabilidad ambiental y la intervención humana (bin Ismail & Thamrin, 2017). Este tipo de retroalimentación continua mejora la estabilidad microclimática y contribuye a mantener un rendimiento predecible y homogéneo entre ciclos productivos.

Finalmente, la trazabilidad y el análisis predictivo emergen como componentes estratégicos de la arquitectura IoT en PFAL. La acumulación de series temporales de alta resolución permite desarrollar modelos de predicción de biomasa, evaluar la eficiencia energética y detectar tempranamente anomalías en los patrones ambientales o fisiológicos (Chamara *et al.*, 2022; Panotra *et al.*, 2024). Estas capacidades analíticas fortalecen la toma de decisiones basada en evidencia y convierten a las PFAL en plataformas experimentales de alta precisión para la optimización del crecimiento vegetal. En conjunto, las ventajas directas de la integración IoT incluyen la reducción de la dependencia de la mano de obra, la mejora de la consistencia y calidad de los cultivos, y la detección oportuna de desviaciones ambientales que podrían comprometer la productividad (Rathor *et al.*, 2024).

Desafíos críticos

El entorno de las PFAL impone exigencias técnicas de alta complejidad al diseño e implementación de sistemas IoT. En primer lugar, la latencia constituye un factor limitante en la estabilidad del microclima: retrasos superiores a cinco segundos en la comunicación entre sensores, controladores y actuadores pueden alterar los gradientes de temperatura o CO₂, afectando directamente los procesos fisiológicos de la fotosíntesis y la transpiración (Chamara *et al.*, 2022). La robustez de una arquitectura IoT en PFAL no depende de la cantidad de datos

recopilados, sino de su calidad, precisión y trazabilidad metrológica. Un sistema verdaderamente científico y reproducible debe registrar no solo el valor medido, sino también la metadata asociada (fecha de calibración, incertidumbre, deriva estimada, ubicación y protocolo de comunicación). Ignorar estos parámetros convierte la trazabilidad en un ejercicio incompleto desde una perspectiva científica y regulatoria. Por ello, las arquitecturas de nueva generación deberían integrar de forma nativa la gestión activa de metadatos de sensores, alineadas con estándares abiertos como SensorML y OGC SensorThings, para asegurar interoperabilidad, validación cruzada y auditoría completa del flujo de datos (Panotra *et al.*, 2024).

2.5 Captura de imágenes y fenotipado de alto rendimiento

El éxito operativo y la reproducibilidad científica en las fábricas de plantas con iluminación artificial dependen de la medición precisa de las respuestas biológicas del cultivo. El Fenotipado de Alto Rendimiento (HTPP) es un conjunto de metodologías que permite medir de forma rápida, no destructiva y objetiva los rasgos morfológicos de las plantas, superando las limitaciones de los métodos manuales y destructivos (Singh *et al.*, 2024; Jiménez Berni, 2024). En el contexto de las PFAL, el HTPP es un componente clave del Sistema Ciberfísico (CPS), ya que permite auditar la eficiencia de uso de la luz (LUE) al medir la biomasa acumulada (salida) y correlacionarla con la dosis de luz (DLI, entrada).

2.5.1 Tecnología de visión 3D y rasgos fenotípicos

Para la fenotipificación en PFAL de alta densidad los sistemas de visión 2D (RGB) son limitados, ya que la superposición foliar (oclusión) provoca una subestimación del área real de la hoja (Kazhdan *et al.*, 2006). Por ello, se justifica el uso de sensores de profundidad 3D, como las cámaras RGB-D (color y profundidad), que son más rentables que el LiDAR (Condotta *et al.*, 2020). Estos sensores capturan la geometría tridimensional, generando una nube de puntos que permite calcular rasgos morfológicos robustos, como la biomasa volumétrica, el índice de área foliar (LAI) y la altura de planta (Powerkh, 2025; Li *et al.*, 2025).

La nube de puntos cruda requiere procesamiento (filtrado, segmentación) y reconstrucción 3D para la extracción precisa de estos rasgos. Este proceso genera datos morfológicos esenciales para la trazabilidad fenotípica y la alimentación de los modelos de inteligencia artificial (Singh *et al.*, 2024).

2.5.2 Desafíos metrológicos y sincronización de datos

A pesar de su bajo costo y funcionalidad, los sensores RGB-D son sensibles a la alta iluminancia generada por los potentes LED hortícolas, lo que puede degradar la precisión de la profundidad (Zavafer *et al.*, 2023). Para mitigar este riesgo, es imprescindible realizar una calibración rigurosa (intrínseca y extrínseca) y mantener una distancia de captura mínima controlada por el robot (Schunck *et al.*, 2021).

El valor científico final de la plataforma reside en la sincronización temporal crítica entre los datos HTPP (imágenes 3D) y la telemetría ambiental (IoT). La arquitectura debe generar un dataset multimodal unificado y trazable, donde la completitud del registro ambiental acompaña la validez del fenotipo visual, sentando las bases para el análisis avanzado de las interacciones ambiente-fenotipo (Song *et al.*, 2023).

2.6 Cultivo de espinaca en PFAL

La espinaca (*Spinacia oleracea* L.) es reconocida mundialmente como una de las hortalizas de hoja más relevantes por su alta productividad y valor nutricional. De acuerdo con la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO, 2021) la producción global alcanzó los 31 millones de toneladas en 2020, mientras que estimaciones más recientes sitúan el volumen en cerca de 59.5 millones de toneladas anuales, consolidando su posición entre las principales hortalizas de hoja cultivadas a nivel mundial (FAOSTAT, 2025). Su importancia en entornos de agricultura en ambientes controlados (CEA) se explica por una combinación de características fisiológicas y morfológicas que la convierten en un modelo ideal para la experimentación en sistemas de cultivo vertical o PFAL (Kozai *et al.*, 2019).

Desde el punto de vista fisiológico, *S. oleracea* presenta una alta tasa fotosintética y un rápido crecimiento, con ciclos de cosecha que varían entre 25 y 35 días, dependiendo del régimen lumínico y del manejo nutrimental (Pandey *et al.*, 2025). Su arquitectura foliar compacta y su relación raíz/parte aérea equilibrada permiten una alta densidad de plantación y una eficiente distribución del flujo de aire y radiación dentro del dosel, lo que facilita su adaptación a técnicas hidropónicas de recirculación como la *Nutrient Film Technique* (NFT) o la *Deep Flow Technique* (DFT).

Además de su eficiencia productiva, la espinaca se ha consolidado como especie modelo para estudiar la eficiencia en el uso de la luz, la dinámica del metabolismo antioxidante, la acumulación de nitratos y el balance carbono/nitrógeno bajo condiciones de iluminación artificial, aspectos esenciales para comprender la respuesta de las plantas C₃ al entorno PFAL (Bantis *et al.*, 2020). La espinaca es un contribuyente esencial a una dieta saludable, ofreciendo alta concentración de vitaminas y minerales como folatos, hierro, magnesio, potasio y calcio, así como compuestos bioactivos, incluyendo fenoles y flavonoides, cuya ingesta se asocia con la reducción de riesgos de enfermedades crónicas (Martínez-Moreno *et al.*, 2024).

2.6.1 Requerimientos ambientales

Los rangos de temperatura diurna óptimos para la espinaca se sitúan entre 18 y 22 °C, con temperaturas nocturnas de 15 a 18 °C para regular eficientemente la tasa de crecimiento y la morfología foliar. No obstante, la temperatura óptima para la tasa fotosintética neta puede ser más alta, variando entre 22.9 °C y 28.5 °C, dependiendo de la temperatura a la que la planta haya sido aclimatada previamente (Yamori *et al.*, 2006).

La espinaca, como planta C₃ exhibe una respuesta altamente positiva a la suplementación con dióxido de carbono CO₂. Los niveles óptimos oscilan entre 800 y 1200 ppm. El enriquecimiento con CO₂ ha demostrado ser altamente beneficioso, resultando en un aumento de hasta 1.69 veces el peso de la planta

y elevando la concentración de compuestos de calidad, como la vitamina C, en un 14% en comparación con los sistemas convencionales (Seo *et al.*, 2017).

El déficit de presión de vapor (VPD por sus siglas en ingles) es la métrica más precisa para controlar la tasa de transpiración y la apertura estomática. Para las etapas vegetativas avanzadas de la espinaca, un VPD entre 0.8 y 1.2 kPa es crítico para mantener la apertura estomática, asegurar la absorción nutrimental y prevenir la necrosis foliar inducida por el estrés hídrico bajo alta radiación. Experimentos con baja presión total y alta humedad, resultando en VPD bajos (0.48 kPa), mostraron un aumento significativo en la tasa de crecimiento relativa (RGR) y el área foliar (Iwabuchi *et al.*, 1996).

Literatura citada

- Alahmad, T., Neményi, M., & Nyéki, A. (2023). Applying IoT Sensors and Big Data to Improve Precision Crop Production: A Review. *Agronomy*, 13(10), 2603. <https://doi.org/10.3390/agronomy13102603>
- ANSI/ASABE. (2017). *Quantities and Units of Electromagnetic Radiation for Plants (Photosynthetic Organisms)*. <https://doi.org/http://dx.doi.org/10.13031/s2000.2013>
- Bantis, F., Fotelli, M., Ilić, Z. S., & Koukounaras, A. (2020). Physiological and Phytochemical Responses of Spinach Baby Leaves Grown in a PFAL System with LEDs and Saline Nutrient Solution. *Agriculture*, 10(11), 574. <https://doi.org/10.3390/agriculture10110574>
- Bantis, F., Smirnakou, S., Ouzounis, T., Koukounaras, A., Ntagkas, N., & Radoglou, K. (2018). Current status and recent achievements in the field of horticulture with the use of light-emitting diodes (LEDs). *Scientia Horticulturae*, 235, 437-451. <https://doi.org/10.1016/j.scienta.2018.02.058>
- Barnes, C., Tibbitts, T., Sager, J., Deitzer, G., Bubenheim, D., Koerner, G., & Bugbee, B. (1993). Accuracy of quantum sensors measuring yield photon flux and photosynthetic photon flux. *HortScience: A Publication of the American Society for Horticultural Science*, 28(12), 1197-1200.
- bin Ismail, M. I. H., & Thamrin, N. M. (2017). IoT implementation for indoor vertical farming watering system. *2017 International Conference on Electrical, Electronics and System Engineering (ICEESE)*, 89-94. <https://doi.org/10.1109/ICEESE.2017.8298388>
- Bispo-Jr, A. G., Saraiva, L. F., Lima, S. A. M., Pires, A. M., & Davolos, M. R. (2021). Recent prospects on phosphor-converted LEDs for lighting, displays,

- phototherapy, and indoor farming. *Journal of Luminescence*, 237, 118167. <https://doi.org/10.1016/j.jlumin.2021.118167>
- Blanco-Valdés, Y. (2019). Importancia de la calidad de la luz entre las plantas arvenses-cultivo. *Cultivos Tropicales*, 40(4). <https://www.redalyc.org/journal/1932/193263189009/html/>
- Boros, I. F., Székely, G., Balázs, L., Csambalik, L., & Sipos, L. (2023). Effects of LED lighting environments on lettuce (*Lactuca sativa* L.) in PFAL systems – A review. *Scientia Horticulturae*, 321, 112351. <https://doi.org/10.1016/j.scienta.2023.112351>
- Bugbee, B. (2016). Toward an optimal spectral quality for plant growth and development: The importance of radiation capture. *Acta Horticulturae*, 1134, 1-12. <https://doi.org/10.17660/ActaHortic.2016.1134.1>
- Butturini, M., & Marcelis, L. F. M. (2020). Vertical farming in Europe: Present status and outlook. En *Plant Factory* (pp. 77-91). Academic Press. <https://doi.org/10.1016/B978-0-12-816691-8.00004-2>
- Chamara, N., Islam, M. D., Bai, G. (Frank), Shi, Y., & Ge, Y. (2022). Ag-IoT for crop and environment monitoring: Past, present, and future. *Agricultural Systems*, 203, 103497. <https://doi.org/10.1016/j.agry.2022.103497>
- Chaudhry, A. R., & Mishra, V. P. (2019). A Comparative Analysis of Vertical Agriculture Systems in Residential Apartments. *2019 Advances in Science and Engineering Technology International Conferences (ASET)*, 1-5. <https://doi.org/10.1109/ICASET.2019.8714358>
- Chen, C. (2015). Determining the Leaf Emissivity of Three Crops by Infrared Thermometry. *Sensors*, 15(5), 11387-11401. <https://doi.org/10.3390/s150511387>
- Chen, X., Li, Y., Wang, L., & Guo, W. (2021). Red and blue wavelengths affect the morphology, energy use efficiency and nutritional content of lettuce (*Lactuca sativa* L.). *Scientific Reports*, 11(1), 8374. <https://doi.org/10.1038/s41598-021-87911-7>
- Condotta, I. C. F. S., Brown-Brandl, T. M., Pitla, S. K., Stinn, J. P., & Silva-Miranda, K. O. (2020). Evaluation of low-cost depth cameras for agricultural applications. *Computers and Electronics in Agriculture*, 173, 105394.
- Duarte, J. E. P., & Maldonado, D. Y. V. (2022). Una Revisión: Tecnología y aplicación en las PFAL. *Avances Investigación en Ingeniería*, 19(2 (Julio-Diciembre)). <https://doi.org/10.18041/1794-4953/avances.2.8263>
- Dubey, R., Telles, A., Nikkel, J., Cao, C., Gewirtzman, J., Raymond, P. A., & Lee, X. (2024). Low-Cost CO2 NDIR Sensors: Performance Evaluation and Calibration Using Machine Learning Techniques. *Sensors*, 24(17), 5675. <https://doi.org/10.3390/s24175675>
- Duffy, S. W. (2019). *Energy efficient supplemental lighting controls in greenhouses*. <https://hdl.handle.net/1813/67527>

- Eo, Y. J., Kim, S., Oh, J. H., Lee, K. N., Kim, C., Lee, S. M., & Do, Y. R. (2022). Development of PAR Sensor Applicable to Greenhouses and Smart Farms Using a Ripple-Free Red/Blue TiO₂/SiO₂ Dual-Band Bandpass Filter. *ACS Applied Electronic Materials*, 4(12), 6125-6132. <https://doi.org/10.1021/acsaelm.2c01247>
- FAO. (2021). *World Food and Agriculture – Statistical Yearbook 2021*. FAO. <https://doi.org/10.4060/cb4477en>
- FAOSTAT. (2025). *FAOSTAT Crops and livestock products*. FAO. <https://www.fao.org/faostat/en/#data/QCL>
- Folta, K. M., & Maruhnich, S. A. (2007). Green light: A signal to slow down or stop. *Journal of Experimental Botany*, 58(12), 3099-3111. <https://doi.org/10.1093/jxb/erm130>
- Fuentes-Peñailillo, F., Gutter, K., Vega, R., & Silva, G. C. (2024). New Generation Sustainable Technologies for Soilless Vegetable Production. *Horticulturae*, 10(1), 49. <https://doi.org/10.3390/horticulturae10010049>
- GetGrowee. (2024, marzo 27). What is Automatic Temperature Compensation in Hydroponics? *Growee Smart Hydroponics*. <https://getgrowee.com/what-is-automatic-temperature-compensation/>
- González, G. A., Tellez, L. I. T., & Merino, F. C. G. (2016). *Nutrición de cultivos*. Colegio de Posgraduados.
- Graamans, L., Baeza, E., Dobbelsteen, A. V. D., Tsafaras, I., & Stanghellini, C. (2018). Plant factories versus greenhouses: Comparison of resource use efficiency. *Agricultural Systems*, 160, 31-43. <https://doi.org/10.1016/j.agsy.2017.11.003>
- Gruda, N. S. (2019). Increasing Sustainability of Growing Media Constituents and Stand-Alone Substrates in Soilless Culture Systems. *Agronomy*, 9(6), Article 6. <https://doi.org/10.3390/agronomy9060298>
- Herrera, F. G., & Velazquez, J. F. (2024). *DISEÑO E IMPLANTACIÓN DE UNA FÁBRICA DE PLANTAS DOMÉSTICA CON LUZ ARTIFICIAL (H-PFAL)*.
- Iwabuchi, K., Saito, G., Goto, E., & Takakura, T. (1996). Effect of vapor pressure deficit on spinach growth under hypobaric conditions. *Acta Horticulturae*, 440, 60-63. <https://doi.org/10.17660/actahortic.1996.440.11>
- Jiménez Berni, J. A. (2024). Investigadores del IAS desarrollan un robot que revoluciona el fenotipado agrícola. IAS-CSIC.
- Johkan, M., Shoji, K., Goto, F., Hahida, S., & Yoshihara, T. (2012). Effect of green light wavelength and intensity on photomorphogenesis and photosynthesis in *Lactuca sativa*. *Environmental and Experimental Botany*, 75, 128-133. <https://doi.org/10.1016/j.envexpbot.2011.08.010>
- Katul, G. G., Oren, R., Manzoni, S., Higgins, C., & Parlange, M. B. (2012). Evapotranspiration: A process driving mass transport and energy

- exchange in the soil-plant-atmosphere-climate system. *Reviews of Geophysics*, 50(3). <https://doi.org/10.1029/2011RG000366>
- Kazhdan, M., Bolitho, M., & Hoppe, H. (2006). Poisson surface reconstruction. In *Proceedings of the Fourth Eurographics Symposium on Point-Based Graphics* (pp. 61–70).
- Khorsandi, A., Hemmat, A., Mireei, S. A., Amirfattahi, R., & Ehsanzadeh, P. (2018). Plant temperature-based indices using infrared thermography for detecting water status in sesame under greenhouse conditions. *Agricultural Water Management*, 204, 222-233. <https://doi.org/10.1016/j.agwat.2018.04.012>
- Kozai, T. (2013). Resource use efficiency of closed plant production system with artificial light: Concept, estimation and application to plant factory. *Proceedings of the Japan Academy, Series B*, 89(10), 447-461. <https://doi.org/10.2183/pjab.89.447>
- Kozai, T. (2016). Why LED Lighting for Urban Agriculture? En T. Kozai, K. Fujiwara, & E. S. Runkle (Eds.), *LED Lighting for Urban Agriculture* (pp. 3-18). Springer. https://doi.org/10.1007/978-981-10-1848-0_1
- Kozai, T. (2018). *Smart Plant Factory* (1.^a ed.). <https://doi.org/10.1007/978-981-13-1065-2>
- Kozai, T. (2019). Towards sustainable plant factories with artificial lighting (PFALs) for achieving SDGs. *International Journal of Agricultural and Biological Engineering*, 12(5), 28-37. <https://doi.org/10.25165/ijabe.v12i5.5177>
- Kozai, T., & Niu, G. (2016). Role of the Plant Factory With Artificial Lighting (PFAL) in Urban Areas. En *Plant Factory* (pp. 7-33). Academic Press. <https://doi.org/10.1016/B978-0-12-801775-3.00002-0>
- Kozai, T., Niu, G., & Takagaki, M. (2019). *Plant Factory: An Indoor Vertical Farming System for Efficient Quality Food Production* (2.^a ed.). Academic Press.
- Kusuma, P., Pattison, P. M., & Bugbee, B. (2020). From physics to fixtures to food: Current and potential LED efficacy. *Horticulture Research*, 7, 56. <https://doi.org/10.1038/s41438-020-0283-7>
- Li, S., Cui, Z., Yang, J., & Wang, B. (2025). A review of optical-based three-dimensional reconstruction and multi-source fusion for plant phenotyping. *Sensors*, 25(11), 3401. <https://doi.org/10.3390/s25113401>
- Liu, J., & van Iersel, M. W. (2021). Photosynthetic Physiology of Blue, Green, and Red Light: Light Intensity Effects and Underlying Mechanisms. *Frontiers in Plant Science*, 12. <https://doi.org/10.3389/fpls.2021.619987>
- Llewellyn, D., Shelford, T., Zheng, Y., & Both, A. J. (2022). Measuring and reporting lighting characteristics important for controlled environment plant production | Request PDF. *ResearchGate*, 1337. <https://doi.org/10.17660/ActaHortic.2022.1337.34>

- López, A., Valera, D. L., Molina-Aiz, F., & Peña, A. (2012). Thermography and Sonic Anemometry to Analyze Air Heaters in Mediterranean Greenhouses. *Sensors*, 12(10), 13852-13870. <https://doi.org/10.3390/s121013852>
- Martin, C. R., Zeng, N., Karion, A., Dickerson, R. R., Ren, X., Turpie, B. N., & Weber, K. J. (2017). Evaluation and environmental correction of ambient CO₂ measurements from a low-cost NDIR sensor. *Atmospheric measurement techniques*, 10, 10.5194/amt-10-2383-2017. <https://doi.org/10.5194/amt-10-2383-2017>
- Martínez-Moreno, A., Frutos-Tortosa, A., Diaz-Mula, H., Mestre, T. C., & Martínez, V. (2024). Effect of the Intensity and Spectral Quality of LED Light on Growth and Quality of Spinach Indoors. *Horticulturae*, 10(4), 411. <https://doi.org/10.3390/horticulturae10040411>
- Massa, G. D., Kim, H.-H., Wheeler, R. M., & Mitchell, C. A. (2008). *Plant Productivity in Response to LED Lighting*. <https://doi.org/10.21273/HORTSCI.43.7.1951>
- McCree, K. J. (1971). The action spectrum, absorptance and quantum yield of photosynthesis in crop plants. *Agricultural Meteorology*, 9, 191-216. [https://doi.org/10.1016/0002-1571\(71\)90022-7](https://doi.org/10.1016/0002-1571(71)90022-7)
- McCree, K. J. (1972). Test of current definitions of photosynthetically active radiation against leaf photosynthesis data. *Agricultural Meteorology*, 10, 443-453. [https://doi.org/10.1016/0002-1571\(72\)90045-3](https://doi.org/10.1016/0002-1571(72)90045-3)
- Mitchell, C. A., & Sheibani, F. (2020). LED advancements for plant-factory artificial lighting. En *Plant Factory* (pp. 167-184). Academic Press. <https://doi.org/10.1016/B978-0-12-816691-8.00010-8>
- Morella, P., Lambán, M. P., Royo, J., & Sánchez, J. C. (2023). Vertical Farming Monitoring: How Does It Work and How Much Does It Cost? *Sensors*, 23(7), 3502. <https://doi.org/10.3390/s23073502>
- Nájera, C., Gallegos-Cedillo, V. M., Ros, M., & Pascual, J. A. (2023). Role of Spectrum-Light on Productivity, and Plant Quality over Vertical Farming Systems: Bibliometric Analysis. *Horticulturae*, 9(1), 63. <https://doi.org/10.3390/horticulturae9010063>
- Nelson, J. A., & Bugbee, B. (2015). Analysis of Environmental Effects on Leaf Temperature under Sunlight, High Pressure Sodium and Light Emitting Diodes. *PloS One*, 10(10), e0138930. <https://doi.org/10.1371/journal.pone.0138930>
- NIST. (2025, septiembre 24). *National Institute of Standards and Technology* [Text]. <https://www.nist.gov/>
- OIML. (2021). *International Organization of Legal Metrology*. International Organization of Legal Metrology. <https://www.oiml.org/en>
- Orsini, F., Pennisi, G., Zulfiqar, F., & Gianquinto, G. (2020). Sustainable use of resources in plant factories with artificial lighting (PFALs). *European*

- Journal of Horticultural Science*, 85(5), 297-309.
<https://doi.org/10.17660/eJHS.2020/85.5.1>
- Ouzounis, T., Rosenqvist, E., & Ottosen, C.-O. (2015). *Spectral Effects of Artificial Light on Plant Physiology and Secondary Metabolism: A Review*.
<https://doi.org/10.21273/HORTSCI.50.8.1128>
- Padhiary, M., Prasad, G., Hoque, A., Kumar, K., & Sahu, B. (2025). Advances in Vertical Farming: The Role of Artificial Intelligence and Automation in Sustainable Agriculture. *LatIA*, 3, 131-131.
<https://doi.org/10.62486/latia2025131>
- Pandey, S. K., Singh, D. K., & Pandiaraj, T. (2025). Growth and yield performance of Palak (*Spinaciaoleracea*L.) plant under hydroponic farming system for sustainable safe food production. *Agriculture Association of Textile Chemical and Critical Reviews*, 13(1), 128-130.
<https://doi.org/10.21276/AATCCReview.2025.13.01.127>
- Panotra, N., Belagalla, N., Mohanty, L. K., M, R. N., Vikash, Tiwari, A. K., Abhishek, G. J., Gulaiya, S., Yadav, K., & Pandey, S. K. (2024). Vertical Farming: Addressing the Challenges of 21st Century Agriculture through Innovation. *International Journal of Environment and Climate Change*, 14(4), 664-691. <https://doi.org/10.9734/ijeccl/2024/v14i44150>
- Park, Y., & Runkle, E. S. (2018). Far-red radiation and photosynthetic photon flux density independently regulate seedling growth but interactively regulate flowering. *Environmental and Experimental Botany*, 155, 206-216.
<https://doi.org/10.1016/j.envexpbot.2018.06.033>
- Powerkh. (2025). What is point cloud modeling? Powerkh.
- Pulighe, G., & Lupia, F. (2020). Food First: COVID-19 Outbreak and Cities Lockdown a Booster for a Wider Vision on Urban Agriculture. *Sustainability*, 12(12), 5012. <https://doi.org/10.3390/su12125012>
- Rathor, A. S., Choudhury, S., Sharma, A., Nautiyal, P., & Shah, G. (2024). Empowering vertical farming through IoT and AI-Driven technologies: A comprehensive review. *Heliyon*, 10(15), e34998.
<https://doi.org/10.1016/j.heliyon.2024.e34998>
- Sager, J. C., Smith, W. O., Edwards, J. L., & Cyr, K. L. (1988). Photosynthetic Efficiency and Phytochrome Photoequilibria Determination Using Spectral Data. *American Society of Agricultural and Biological Engineers*, 31(6).
<https://doi.org/10.13031/2013.30952>
- Schanda. (2005). *INSTRUMENTATION | Photometry*. 307-317.
<https://doi.org/10.1016/B0-12-369395-0/00701-6>
- Schunck, D., Magistri, F., Rosu, R. A., Cornelißen, A., Chebrolu, N., Paulus, S., Léon, J., Behnke, S., Stachniss, C., Kuhlmann, H., & Klingbeil, L. (2021). Pheno4D: A spatio-temporal dataset of maize and tomato plant point

- clouds for phenotyping and advanced plant analysis. *PLOS ONE*, 16(8), e0256340. <https://doi.org/10.1371/journal.pone.0256340>
- Sena, S., Kumari, S., Kumar, V., & Husen, A. (2024). Light emitting diode (LED) lights for the improvement of plant performance and production: A comprehensive review. *Current Research in Biotechnology*, 7, 100184. <https://doi.org/10.1016/j.crbiot.2024.100184>
- Seo, Y., Ide, K., Kitahata, N., Kuchitsu, K., & Dowaki, K. (2017). Environmental Impact and Nutritional Improvement of Elevated CO₂ Treatment: A Case Study of Spinach Production. *Sustainability*, 9(10), 1854. <https://doi.org/10.3390/su9101854>
- Sharpe, L. T., Stockman, A., Jagla, W., & Jägle, H. (2005). A luminous efficiency function, $V^*(\lambda)$, for daylight adaptation. *Journal of Vision*, 5(11), 948-968. <https://doi.org/10.1167/5.11.3>
- Singh, K., Yadav, M., Singh, Y., Barak, D., Saini, A., & Moreira, F. (2024). Reliability on the Internet of Things with designing approach for exploratory analysis. *Frontiers in Computer Science*, 6, 1382347. <https://doi.org/10.3389/fcomp.2024.1382347>
- Song, P., Li, Z., Yang, M., Shao, Y., Pu, Z., Yang, W., & Zhai, R. (2023). Dynamic detection of three-dimensional crop phenotypes based on a consumer-grade RGB-D camera. *Frontiers in Plant Science*, 14, 1097725. <https://doi.org/10.3389/fpls.2023.1097725>
- Stallknecht, E. J., & Runkle, E. S. (2025). Towards Understanding the Promotion of Plant Growth Under an Experimental Red-Fluorescent Plastic Film. *Horticulturae*, 11(8), 980. <https://doi.org/10.3390/horticulturae11080980>
- Thakur, M., & Kumar, R. (2021). Microclimatic buffering on medicinal and aromatic plants: A review. *Industrial Crops and Products*, 160, 113144. <https://doi.org/10.1016/j.indcrop.2020.113144>
- Van Gerrewey, T., Boon, N., & Geelen, D. (2022). Vertical Farming: The Only Way Is Up? *Agronomy*, 12(1), 2. <https://doi.org/10.3390/agronomy12010002>
- Vatistas, C., Avgoustaki, D. D., & Bartzanas, T. (2022). A Systematic Literature Review on Controlled-Environment Agriculture: How Vertical Farms and Greenhouses Can Influence the Sustainability and Footprint of Urban Microclimate with Local Food Production. *Atmosphere*, 13(8), 1258. <https://doi.org/10.3390/atmos13081258>
- Wheeler, R. M. (2024). Improving vertical farming efficiency through dynamic environmental control. *Frontiers in Science*, 2. <https://doi.org/10.3389/fsci.2024.1465403>
- 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>

- Yamori, W., Noguchi, K., Hanba, Y. T., & Terashima, I. (2006). Effects of internal conductance on the temperature dependence of the photosynthetic rate in spinach leaves from contrasting growth temperatures. *Plant & Cell Physiology*, 47(8), 1069-1080. <https://doi.org/10.1093/pcp/pcj077>
- Younesi-Alamouti, M., Khafajeh, H., & Zarein, M. (2021). Factors affecting energy consumption and productivity in greenhouses. *Spanish Journal of Agricultural Research*, 19(4), e0209-e0209. <https://doi.org/10.5424/sjar/2021194-16865>
- Zavafer, A., Mancilla, C., Jolley, G., & Murakami, K. (2023). On the concepts and correct use of radiometric quantities for assessing the light environment and their application to plant research. *Biophysical Reviews*, 15(3), 385-400. <https://doi.org/10.1007/s12551-023-01051-y>
- Zhen, S., & Bugbee, B. (2020). Far-red photons have equivalent efficiency to traditional photosynthetic photons: Implications for redefining photosynthetically active radiation. *Plant, Cell & Environment*, 43(5), 1259-1272. <https://doi.org/10.1111/pce.13730>

3. Sistema IoT para una mini-PFAL: diseño, disponibilidad de datos y validación de calidad de medición²

Resumen

Las fábricas de plantas con iluminación artificial (PFAL) permiten producir hortalizas en sistemas automatizados, pero aún existen brechas en la canalización de datos, como el monitoreo continuo, el almacenamiento estructurado y la visualización en tiempo real. El objetivo de esta investigación fue el diseño, la implementación y la evaluación de un sistema IoT integral para una mini-PFAL destinada al cultivo de hortalizas de hoja. Se propone una arquitectura IoT modular y robusta, compuesta por un módulo de adquisición de datos y un módulo de procesamiento y almacenamiento, que permite la consulta en línea mediante una interfaz gráfica en cualquier dispositivo móvil con conexión a internet. La arquitectura integra una red de sensores para medir variables ambientales, del cultivo y de la solución nutritiva. Con el uso del microcontrolador ESP32, se leen los datos de los sensores y se envían a una Raspberry Pi 5, que almacena las variables monitoreadas en MariaDB y, simultáneamente, comparte los datos en un dashboard de Node-RED; además, incorpora una captura programada de imágenes de las plantas mediante un robot cartesiano para trazabilidad visual. El sistema fue evaluado durante 21 días en un cultivo de *espinaca*. Para la validación del sistema, se emplearon métricas de continuidad y disponibilidad (completitud, MTBF/MTTR) y se caracterizaron las brechas de datos no registrados. Los resultados indicaron una tasa de completitud (C %) del 93.68 %, lo que demuestra que el sistema funcionó adecuadamente durante el período evaluado para monitorear de forma continua y eficiente las variables ambientales, del cultivo y de la solución nutritiva en una mini-PFAL. La captura programada generó un dataset de imágenes organizado por fecha y hora, sirviendo como referencia para análisis fenotípicos a largo plazo y para replicar en investigaciones futuras.

Palabras clave: Adquisición de datos, canalización de datos, ESP32, Raspberry Pi, validación metrológica.

² Tesis de Maestría en Ingeniería, Universidad Autónoma Chapingo.

Autor: José Francisco Arteaga Alarcón.

Director de tesis: Agustín Ruiz García.

Artículo enviado a la revista "Ingeniería Agrícola y Biosistemas (INAGBI)".

Estatus: Artículo enviado.

IoT System for a Mini-PFAL: Design, Data Availability, and Measurement Quality Validation²

Abstract

Plant Factories with Artificial Lighting (PFALs) enable vegetable production in automated systems, but gaps remain in the pipeline in continuous monitoring, structured storage, and real-time visualization. This study aimed to design, implement, and evaluate a comprehensive IoT system for a mini-PFAL intended for vegetable cultivation. We propose a modular and robust IoT architecture comprising a data-acquisition subsystem and a central processing and storage unit, which enables online querying via a graphical interface accessible from any internet-connected mobile device. The architecture incorporates a sensor network to measure environmental variables, crop conditions, and nutrient solution parameters. An ESP32 microcontroller reads sensor data and streams it to a Raspberry Pi 5, which stores the monitored variables in MariaDB while simultaneously serving a Node-RED dashboard; it also triggers scheduled plant imaging via a Cartesian robot to ensure visual traceability. The system was evaluated over a 21-day cultivation of *Spinacia oleracea* L. For validation, continuity and availability metrics (completeness, MTBF/MTTR) were applied, and periods of missing data were characterized. Results showed a completeness of 93.68%, demonstrating reliable operation throughout the evaluation period and enabling continuous, efficient monitoring of environmental, crop, and nutrient-solution variables in the mini-PFAL. Scheduled image acquisition generated a timestamped image dataset synchronized with sensor logs, facilitating longitudinal phenotypic analyses and enabling reuse in subsequent studies.

Keywords: Data acquisition, data piping, ESP32, Raspberry Pi, metrological validation.

² Master's Thesis in Engineering, Universidad Autónoma Chapingo.
Author: José Francisco Arteaga Alarcón.
Advisor: Agustín Ruiz García.

3.1 Introducción

La agricultura en ambientes controlados ha cobrado relevancia ante la urbanización, la escasez hídrica y la variabilidad climática. En este contexto, las Plant Factories with Artificial Lighting (PFAL) se han consolidado como sistemas verticales cerrados capaces de producir hortalizas con alta uniformidad y productividad por unidad de área, apoyados en el control preciso de la luz, el clima y la nutrición (Kozai *et al.*, 2019). En la literatura se reportan productividades por unidad de área muy superiores a las de invernadero e invernadero cuando se opera con múltiples niveles y con una gestión ambiental estricta (Kozai *et al.*, 2019).

En PFAL e invernaderos de alta tecnología, el control conjunto de temperatura, humedad relativa, CO₂ y de luz se vincula con tasas de fotosíntesis y de uso de recursos más predecibles, que ilustran la necesidad de retroalimentación basada en sensores (Zhuang *et al.*, 2024). En hidroponía, la literatura coincide en que el pH y la EC son variables críticas para la disponibilidad nutricional y la absorción, lo que justifica su monitoreo y control automatizado (Fathidarehnejeh *et al.*, 2024). A pesar de las ventajas de las PFAL, persisten brechas en la ingeniería de datos: continuidad de registro, almacenamiento estructurado y visualización en tiempo real, así como trazabilidad reproducible desde el sensor hasta la analítica. Las arquitecturas de internet de las cosas (IoT por sus siglas en inglés) de bajo costo basadas en Raspberry Pi/ESP32 con Node-RED y bases de datos relacionales permiten un prototipado ágil y la operación remota, pero presentan reportes dispares sobre la fiabilidad (disponibilidad, MTBF/MTTR) y la gobernanza de datos (Domínguez-Bolaño 2022; García 2020; Lekić, 2018).

La espinaca (*Spinacia oleracea* L.) es un cultivo ideal para PFAL debido a su ciclo breve y demanda constante, pero es foto- y termo- receptiva: los días largos pueden inducir espigado y reducir el rendimiento vegetativo si no se gestiona el fotoperiodo; el crecimiento y la fotosíntesis presentan óptimos térmicos moderados; y la productividad responde de forma no lineal a la integración diaria de luz (DLI) y a la calidad espectral (Gao *et al.*, 2020; Meng *et al.*, 2022; Wang *et*

al., 2022). Estas sensibilidades obligan a sincronizar la luz, el clima y la nutrición y a documentar la calidad de los datos que sustentan las decisiones.

El fenotipado por imagen (HTPP) se ha consolidado como pilar para cuantificar morfología, vigor y respuesta al estrés; las imágenes RGB y RGB-D permiten estimar rasgos 2D/3D y alimentar modelos de aprendizaje automático, siempre que existan datasets anotados y trazables (Xu *et al.*, 2022; Akhtar *et al.*, 2024; Mercier *et al.*, 2025). Avances recientes destacan el papel de las cámaras de profundidad y la reconstrucción 3D para superar oclusiones y mejorar métricas de arquitectura de copa/hoja, junto con marcos para evaluar y compensar errores de rango en cámaras RGB-D (Li *et al.*, 2025; Condotta *et al.*, 2020). Además, han surgido datasets RGB-Depth masivos y anotados para entrenamiento de modelos y HTPP, y las revisiones recientes en CEA/PFAL enfatizan que integrar telemetría ambiental con datasets de imagen acelera el descubrimiento de relaciones ambiente-fenotipo y la toma de decisiones (Mercier *et al.*, 2025).

Por lo anterior, el objetivo de esta investigación fue el diseño, la implementación y la validación metrológica de un sistema IoT integral para una mini-PFAL destinada al cultivo de hortalizas de hoja. Este sistema integra sensores ambientales, de solución nutritiva y de temperatura foliar, registra los datos en MariaDB, muestra los datos en un dashboard de Node-RED y automatiza la captura RGB-D mediante un robot cartesiano para futuros estudios de trazabilidad fenotípica.

3.2 Materiales y métodos

El sistema propuesto fue diseñado con un enfoque modular y escalable para el monitoreo continuo de hortalizas en un entorno tipo PFAL. La metodología comprende el diseño e integración de hardware y software para la obtención de datos de sensores montados en una mini-PFAL, la configuración de una base de datos, la visualización remota de los datos mediante una plataforma IoT, la evaluación de los datos obtenidos y la implementación de un robot cartesiano para la captura periódica de imágenes.

3.2.1 Sistema mini-PFAL

El sistema mini-PFAL construido fue diseñado con fines de investigación y estuvo compuesto por una estructura metálica modular de tres niveles de producción. Cada nivel tiene una longitud de 1.22 m, un ancho de 1.00 m y una altura de 0.35 m entre niveles. (Figura 3.1).




Figura 3.1. Esquema de la mini-PFAL construida donde se observa la distribución de sus componentes.

La iluminación en cada nivel la proporcionan diez barras LED “Sun White Pro Spectrum” (Active Grow, WA, EE. UU.) de 120 cm, con un espaciado de 10 cm entre lámparas. Estas lámparas proporcionan una intensidad promedio de radiación fotosintéticamente activa (PAR) que varía entre 293 y 470 $\mu\text{mol m}^{-2} \text{s}^{-1}$ según la distancia a la planta.

El espectro característico de las lámparas se muestra en la Figura 3.2.




Figura 3.2. Espectro promedio de emisión de las lámparas LED instaladas en la mini fábrica de plantas.

La medición característica de la densidad de flujo de fotones fotosintéticos (Figura 3.3) y la integral de luz diaria (PPFD y DLI , por sus siglas en inglés) de este arreglo de luces LED (para un fotoperiodo de 13 h) se presenta en el

Cuadro 3.1. Para dicha caracterización, se discriminaron los datos derivados del efecto de orilla.




Figura 3.3. Mapa de la densidad de flujo de fotones fotosintéticos medidos a diferentes alturas en la mini fábrica de plantas.

Cuadro 3.1. Uniformidad e intensidad de la luz a diferentes alturas e integral de luz diaria para un fotoperiodo de 13 h.

Altura en cm	PPFD promedio	PPFD mínimo	Desviación estándar	CV %	Uniformidad	DLI (mol m ⁻² día ⁻¹)
40	260.28	170	40.53	15.57	0.65	12.18
35	286.02	181	46.94	16.41	0.63	13.38
30	319.72	204	52.01	16.26	0.63	14.96
25	355.3	224	58.26	16.39	0.63	16.62
20	401.78	251	64.08	15.94	0.62	18.80
15	457.88	298	69.13	15.09	0.65	21.42

Para la producción vegetal, se implementó un sistema hidropónico tipo Nutrient Film Technique (NFT), conformado por tubos de PVC de tres pulgadas de diámetro con orificios de dos pulgadas y un espaciamiento de 12.5 cm entre perforaciones. Cada nivel contó con siete tubos de PVC con capacidad para albergar 60 plantas por nivel. El riego se realizó mediante una bomba recirculante SML-4000 de 100 W, conectada a un reservorio con capacidad de almacenar hasta 117 L de solución nutritiva. Esta bomba operó de forma intermitente, activándose durante 25 min cada hora para mantener un flujo constante de nutrientes y oxígeno hacia las raíces.

3.2.2 Configuración de hardware

El sistema de monitoreo IoT (Figura 3.4) está compuesto por tres bloques funcionales principales: red de sensores, módulo de adquisición de datos y módulo central de procesamiento y almacenamiento.




Figura 3.4. Arquitectura general del sistema IoT.

Red de sensores

La red de sensores (Figura 3.5) se diseñó para recopilar datos de la solución nutritiva, el ambiente y los parámetros fisiológicos de las plantas. La solución nutritiva se monitoreó midiendo la conductividad eléctrica (CE) y la temperatura con el sensor ES-2 (METER Group, NE, EE. UU.); el pH se registró mediante el EZO™ pH Circuit con la Isolated Carrier Board (Atlas Scientific, NY, EE. UU.) acoplado a un electrodo PHE-1304 (OMEGA Engineering, CT, EE. UU.). La profundidad en el tanque de la solución se determinó con un módulo ultrasónico JSN-SR04T (genérico, China) y el caudal y el volumen aplicado se cuantificaron con un sensor de flujo FS300A (genérico, China). En cuanto a las variables ambientales, en cada piso se midieron la temperatura y la humedad relativa con sensores SHT35 (Sensirion AG, Stäfa, Suiza); la concentración de CO₂ con un COZIR-LP3-5000 (CO2Meter, FL, EE. UU.); y la presencia/ausencia de luz con sensores BH1750 (genérico, China). Para las variables fisiológicas del cultivo, se instalaron seis sensores (dos por piso) infrarrojos MLX90614ESF-DCI (Melexis NV, Flandes, Bélgica) con los que se monitoreó la temperatura foliar; estos sensores también registran la temperatura ambiental para corregir las mediciones infrarrojas.




Figura 3.5. Distribución espacial de la red de sensores vista frontal (a) y lateral (b) (1: solución nutritiva; 2: ambientales; 3: fisiológicos; D405: cámara RGB-D).

En el Cuadro 3.2 se presentan las características de los sensores empleados en el sistema IoT.

Cuadro 3.2. Especificaciones técnicas de los sensores.

Sensor	Rango	Precisión	Resolución	Voltaje de operación	Consumo de corriente	Interfaz de comunicación
ES-2	0-120 dS m ⁻¹ y -40 a 60 °C	+/- 0.01 dS/m y +/- 1°C	0.001 dS m ⁻¹ y 0.1 °C	3.3-15.0 V DC	20 mA	DDI, SDI-12
EZO™ pH	0.001-14.0 pH	+/- 0.002 pH	0.001pH	3.3-5 V DC	14.5 mA	UART, I ² C
Isolated Carrier Board	Compatible con sensores de pH, EC, DO, ORP, RTD	N/A	N/A	3.3-5 V DC	22 mA	UART, I ² C

PHE-1304	0.0-12.0 pH	+0.02 pH	0.001	1.5-9 V DC	0.5 mA	Salida analógica
JSN-SR04T	25-450 cm	+ 2 mm	1 mm	3.3-5 V DC	30 mA	Trigger/Echo, PWM
FS300A	1-60 L/min	+ 3%	0.133 l/pulso	3.3-24 V DC	15 mA	Salida digital
SHT35	-40 a 125 °C y 0%-100% RH	+0.1 °C Y +- 1.5% RH	0.01 °C y 0.01% RH	2.15-5.5 V DC	800 µA	I ² C
LP3-5000	0-5000 ppm	+ 30 ppm	1 ppm	3.25-5.5 V DC	15 mA	UART, I ² C
BH1750	1-65535 lx	+20%	1 lx	3-5 V DC	120 µA	I ² C
MLX90614	-70 °C a 380 °C	+ 0.5 °C	0.02 °C	3.3-5 V DC	1.3 mA	I ² C

Módulo de adquisición de datos

Este módulo utilizó dos microcontroladores ESP32 DEV KIT v1 y un ESP32-S3-N16R8 (Espressif Systems, Shanghái, China). El primer ESP32 DEV KIT v1 recopiló la información de los seis sensores MLX90614 y de dos sensores LP3-5000; se envió la información mediante el protocolo UART al segundo ESP32 DEV KIT v1, que además recopiló la información de tres sensores SHT35, tres sensores BH1750, un LP3-5000 y un JSN-SR04T. Para resolver los conflictos de dirección en el bus I²C, se emplearon dos multiplexores TCA9548A (genérico, China). Los datos combinados se enviaron nuevamente por el protocolo UART desde el segundo ESP32 DEV KIT v1 al ESP32-S3-N16R8, encargado del control de riego e iluminación, y de la lectura de los sensores ES-2, PHE-1304 y FS300A, así como de un módulo reloj RTC DS3231 (genérico, China). Este microcontrolador central concentró y transmitió toda la información a través del puerto serial (COM) a una Raspberry Pi 5 (Raspberry Pi, Cambridge, UK) para su almacenamiento y visualización, con un intervalo de actualización de 2 s, enviando todas las variables concatenadas en una sola línea de texto. La arquitectura e interconexiones del módulo se ilustran en la Figura 3.6.




Figura 3.6. Distribución del hardware del módulo de adquisición de datos, con rutas por piso y por la solución nutritiva hasta la Raspberry Pi 5.

Módulo central de procesamiento y almacenamiento de datos

La Raspberry Pi 5 almacena los datos transmitidos desde el ESP32-S3-N16R8 en una base de datos de MariaDB y los muestra en un dashboard de Node-RED, accesible de forma remota mediante un túnel HTTPS (ngrok) (Figura 3.7). Además, controla un robot cartesiano de dos ejes equipado con una cámara Intel RealSense D405, configurado para captar imágenes RGB-D a las 7:30, 13:30 y 19:30 horas (Figura 3.8). Dado que fue necesario procesar simultáneamente los datos para el almacenamiento y la visualización en tiempo real, se clonó la señal del puerto serial y se emularon dos puertos COM virtuales mediante la instrucción “socat”, lo que permitió ejecutar en paralelo el script de la base de datos y el dashboard IoT (Figura 3.7).




Figura 3.7. Flujo de datos del módulo central de procesamiento y almacenamiento.



Figura 3.8. Robot cartesiano para la captura de imágenes.

Por cada captura de imagen se generaron cuatro archivos: dos documentos con la nube de puntos por píxel en formatos .npz y .csv y dos imágenes (RGB y de profundidad). Este módulo tuvo como objetivo desarrollar un sistema automatizado para capturar imágenes con fines de investigación, creando un dataset que registre el crecimiento de las plantas.

3.2.3 Diseño de base de datos

Se seleccionó MariaDB (v15.1) por ser de código abierto y por su bajo consumo de recursos. La base de datos funcionó como un servicio en segundo plano, recibiendo datos mediante un script en Python que validó la estructura del mensaje recibido por uno de los puertos COM virtuales, dividiendo la cadena de

texto y asignando cada valor a su variable correspondiente. Debido a que la Raspberry recibió información del puerto COM cada dos segundos, el script de Python esperó a recibir 4 líneas de texto; al recibir la quinta, almacenó momentáneamente los datos recibidos en la última línea de la información. Después de almacenar seis registros, el script calculó el promedio de cada variable, obteniendo así un promedio por minuto.

3.2.4 Dashboard y visualización

Simultáneamente al procesamiento y almacenamiento de los datos en MariaDB, el segundo puerto COM virtual se utilizó para alimentar el dashboard de Node-RED, recibiendo datos del ESP32-S3-N16R8 cada 2 segundos. Se utilizó la versión gratuita de ngrok para generar un túnel seguro que permitió acceder y visualizar el dashboard de Node-RED de forma remota desde cualquier lugar en cualquier dispositivo móvil con acceso a internet, facilitando el seguimiento del sistema sin necesidad de estar en la misma red local.

3.2.5 Validación del sistema y métricas de integridad de datos

La validación del sistema se centró en evaluar la capacidad de adquisición continua durante 21 días, con una frecuencia de muestreo de 1 minuto (30,240 observaciones esperadas por sensor). Se calcularon métricas de integridad y de desempeño operativo: C % (Compleitud de datos), calculada con la ecuación (1), C_recibidos % (Compleitud de datos recibidos), calculada con la ecuación (2), A % (Disponibilidad), calculada con la ecuación (3), MTBF (Tiempo medio entre fallas) y MTTR (Tiempo medio de recuperación).

$$C \% = \left(\frac{\text{registros válidos}}{\text{registros esperados}} \right) 100 \quad (1)$$

$$C_{\text{recibidos}} \% = \left(\frac{\text{registros recibidos}}{\text{registros esperados}} \right) 100 \quad (2)$$

$$A \% = \left(1 - \frac{\text{tiempo sin registro}}{\text{tiempo total}} \right) 100 \quad (3)$$

El análisis se llevó a cabo en Python (NumPy, Pandas), creando tablas que evidencian la continuidad temporal y la presencia de brechas para evaluar la confiabilidad del sistema.

Limpieza de datos

Se realizó una limpieza de datos de la información almacenada en la base de datos; se ejecutó un script en Python que validó cada registro por variable según tres criterios: límite inferior (Min), límite superior (Max) y salto máximo (Δ max) permitido entre dos mediciones consecutivas. Toda lectura que no cumplió alguno de estos criterios fue descartada. Las lecturas inválidas se anularon celda por celda, sin eliminar el resto de las variables de la fila. En el Cuadro 3.3 se muestran los parámetros empleados para la limpieza de los datos.

Cuadro 3.3 Límite máximo, mínimo y salto máximo para la limpieza de datos.

Variable	Mín.	Máx.	Δ máx.
Solución nutritiva			
pH	4.0	8.5	2.0
Conductividad eléctrica ($\mu\text{s cm}^{-1}$)	0	5000	600
Temperatura solución ($^{\circ}\text{C}$)	14	40	3.0
Volumen solución (L)	0	102	25
Litros regados (L)	0	530	10
Caudal (L min^{-1})	0	80	20
Ambiental			
Temperatura piso 1–3 ($^{\circ}\text{C}$)	14	40	5.0
Humedad piso1–3 (%)	40	100	20.0
CO_2 piso 1–3 (ppm)	300	1250	280
Radiación piso 1–3	10	325	300
Fisiológicos (mlx90614)			
Infrarrojo planta 1–6 ($^{\circ}\text{C}$)	14	45	5.0
Infrarrojo ambiental 1–6 ($^{\circ}\text{C}$)	14	45	5.0

3.2.6 Cultivo experimental y condiciones de crecimiento

El experimento se realizó del 11 de julio de 2025 al 1 de agosto del mismo año con plantas de espinaca (*Spinacia oleracea* L. var. Flamingo). Las semillas se germinaron en charolas de 50 cavidades, utilizando un sustrato compuesto por turba y perlita (3:1 v/v). En cada cavidad se colocó un total de 15 semillas, con una germinación del 90 % por cavidad. Para el desarrollo del experimento, se

adquirieron dos charolas provenientes del mismo lote, 21 días después de la siembra, al momento del trasplante.

Antes de introducir el material vegetal, las raíces de las plántulas se lavaron cuidadosamente con agua corriente para eliminar el sustrato de germinación, lo que ayudó a prevenir taponamientos en los conductos del sistema de riego. Posteriormente las plántulas se colocaron en canastillas hidropónicas y se efectuó una desinfección preventiva mediante una inmersión rápida en una solución de COBREZATE® M (DUCOR, Jalisco, México) (oxicloruro de cobre 50 % + mancozeb 36 %) a una concentración de 3 g L⁻¹ de agua, con la finalidad de reducir la carga microbiana y evitar la proliferación de enfermedades y hongos en el sistema.

El trasplante se realizó en dos configuraciones de ocupación de orificios. En los niveles inferior e intermedio, las plántulas se distribuyeron de manera homogénea, ocupando 41 orificios por piso y manteniendo una densidad uniforme. En el nivel superior, donde se encontraba el robot cartesiano, las plántulas se colocaron únicamente en 18 orificios, con un espaciado de 25 cm, a fin de facilitar la captura de imágenes RGB-D.

Posteriormente, las plantas permanecieron durante 24 h en recirculación con agua limpia y sin nutrientes para favorecer su adaptación radicular. Después del periodo de adaptación, se ajustaron los parámetros de la solución nutritiva para obtener una conductividad eléctrica cercana al rango de 1,800 a 2,000 $\mu\text{S cm}^{-1}$ y un pH entre 6.0 y 7.0. Ocho días más tarde, la conductividad se mantuvo entre 2,200 y 2,400 $\mu\text{S cm}^{-1}$.

La solución nutritiva empleada correspondió a la fórmula comercial Soluponics® Leafy Greens (Inverfarms México, Querétaro, México), diseñada especialmente para cultivos de hortalizas de hoja en sistemas hidropónicos, esta fórmula ofrece una relación equilibrada de macronutrientes, con las concentraciones (mmol L^{-1}) siguientes: 15.7 de NO_3^- ; 1.3 de NH_4^+ ; 1.3 de H_2PO_4^- ; 3.3 de SO_4^{2-} ; 6.8 de K^+ ; 4.7 de Ca^{2+} y 3.0 de Mg^{2+} . Para complementar el aporte de micronutrientes, se añadió el fertilizante Haifa Micro™ (Haifa Group, Haifa, Israel) en las dosis recomendadas por el fabricante, que incluye Fe-EDTA, Mn-EDTA, Zn-EDTA, Cu-

EDTA, B y Mo, con el objetivo de garantizar un suministro adecuado de micronutrientes y prevenir deficiencias durante el ciclo de cultivo. Se realizó un muestreo inicial de cuatro plantas representativas para establecer la línea de base de biomasa y validar la homogeneidad del lote experimental. Posteriormente, a los 21 días, se realizó un muestreo final de 4 plantas para calcular la acumulación total de biomasa.

Cada nivel recibió iluminación artificial con un fotoperíodo de 13 h de luz y 11 h de oscuridad, con un promedio inicial de intensidad PAR de $293 \mu\text{mol m}^{-2} \text{s}^{-1}$, que alcanzó aproximadamente $470 \mu\text{mol m}^{-2} \text{s}^{-1}$ al final del ciclo productivo.

Las condiciones climáticas en la habitación donde se ubicó la PFAL se controlaron mediante dos extractores: uno para regular la temperatura entre 20 y 25 °C y otro para regular la humedad relativa, la cual se mantuvo entre 55 y 70 % mediante ventilación forzada para igualar las condiciones del interior.

3.3 Resultados y discusión

3.3.1 Métricas generales de integridad y continuidad temporal del sistema

Se evaluó la integridad del sistema durante un período de 21 días, con una frecuencia de almacenamiento de datos de 1 min, y se esperó un total de 30,240 registros por sensor. A partir de las columnas de fecha y h almacenadas en la base de datos, se identificaron brechas en el registro de la información, como intervalos de tiempo mayores a 1 min ($\Delta t-1$), y se calculó su duración como $\Delta t-1$ (minutos perdidos).

En el periodo analizado se detectaron 15 brechas de información (Cuadro 3.4) con una pérdida acumulada de 1,781 min, para un total de 28,459 datos registrados por sensor.

Cuadro 3.4. Registro de brechas de adquisición de datos: duración, cadencia y causa

No. De brecha	Inicio de la brecha	Fin de la brecha	Δt entre muestras (min)	Min perdidos ($\delta t - 1$)	Causa
1	2025-07-11 22:45:00	2025-07-11 22:47:00	2	1	Jitter por CPU/E/S
2	2025-07-12 21:23:00	2025-07-12 22:23:00	60	59	Falla en la red eléctrica
3	2025-07-12 22:45:00	2025-07-12 22:54:00	9	8	Mantenimiento del sistema
4	2025-07-14 13:14:00	2025-07-14 13:32:00	18	17	Mantenimiento del sistema
5	2025-07-16 20:19:00	2025-07-17 12:47:00	988	987	Falla en la red eléctrica
6	2025-07-18 12:36:00	2025-07-18 18:17:00	341	340	Falla en la red eléctrica
7	2025-07-18 20:17:00	2025-07-18 20:20:00	3	2	Reconexión puerto serie/USB
8	2025-07-18 20:21:00	2025-07-18 22:09:00	108	107	Falla en la red eléctrica
9	2025-07-22 00:32:00	2025-07-22 04:36:00	244	243	Falla en la red eléctrica
10	2025-07-22 13:46:00	2025-07-22 13:48:00	2	1	Jitter por CPU/E/S
11	2025-07-22 18:11:00	2025-07-22 18:24:00	13	12	Mantenimiento del sistema
12	2025-07-24 23:55:00	2025-07-24 23:57:00	2	1	Jitter por CPU/E/S
13	2025-07-25 07:44:00	2025-07-25 07:46:00	2	1	Jitter por CPU/E/S
14	2025-07-29 05:15:00	2025-07-29 05:17:00	2	1	Jitter por CPU/E/S
15	2025-07-31 00:52:00	2025-07-31 00:54:00	2	1	Jitter por CPU/E/S

En el Cuadro 3.5 se presentan las métricas globales de integridad y continuidad del almacenamiento de datos.

Cuadro 3.5. Indicadores de disponibilidad, completitud y brechas de datos (MTTR/MTBF).

Métrica	Valor
Registros esperados por sensor	30,240
No. de brechas	15
Minutos perdidos	1,781 min
Completitud de los datos recibidos (%)	94.11 %
Disponibilidad A (%)	94.11 %
Datos faltantes (%)	5.89 %
MTTR (media)	118.7 min
Mediana de hueco	8 min
P95 de hueco	534 min
Máximo hueco	987 min
MTBF	31.6 h

En su conjunto, el sistema alcanzó una alta disponibilidad operativa, pero las brechas en la adquisición y visualización de datos se asociaron principalmente a contingencias externas (cortes energéticos), no al conjunto de sensores ni a la persistencia de los datos. Esto es consistente con la literatura sobre confiabilidad de sistemas IoT, que enfatiza evaluar la disponibilidad, el MTBF y el MTTR a nivel end-to-end (dispositivo → red → plataforma), ya que la electrónica rara vez es el único cuello de botella; las capas de red y de orquestación añaden vulnerabilidades operativas que pueden sesgar la continuidad si no se monitorizan explícitamente (Singh et al., 2024; Domínguez-Bolaño et al., 2022). En contraste con trabajos de laboratorio con Raspberry Pi que reportan disponibilidades cercanas al 100 % en ventanas de prueba cortas, aquí el sistema se sometió a un ciclo completo de cultivo, lo que hace aflorar fallos intermitentes de infraestructura eléctrica y de red que no se capturan en benchmarks breves. Metodológicamente, esto alinea el diseño con recomendaciones recientes como

la ITU-T Y.2060 y estándares oneM2M para evaluar arquitecturas IoT bajo condiciones de operación prolongadas.

3.3.2 Desempeño de cada sensor

Tras filtrar los datos recibidos (28,459 por sensor) con los rangos de mediciones permitidos y el umbral de datos para saltos imposibles mencionados en el punto 2.7, se determinó que, para las variables de: litros y caudal del sistema de riego, humedad y radiación del piso 1, humedad y temperatura del piso 2, humedad, temperatura y concentración de CO₂ del piso 3, no se encontraron valores inválidos detectados por los filtros aplicados. El resto de las variables se detallan en el Cuadro 3.6.

Cuadro 3.6. Calidad de datos por variable almacenada.

Variable	Fuera de rango	Salto imposible	Falla del sensor	Datos inválidos recibidos	Datos validos recibidos	% de datos validos recibidos
pH	856	9	101	966	27,493	96.606
Radiación piso 2	890	0	0	890	27,569	96.873
Co2 Piso 1	214	423	0	637	27,822	97.762
Volumen solución	281	92	251	624	27,835	97.807
Infrarrojo planta 5	105	175	0	280	28,179	99.016
Infrarrojo ambiental 5	97	143	0	240	28,219	99.157
Co2 Piso 2	37	22	0	59	28,400	99.793
Infrarrojo planta 6	29	15	0	44	28,415	99.845
Infrarrojo ambiental 6	29	11	0	40	28,419	99.859
Infrarrojo planta 4	6	10	0	16	28,443	99.944
Infrarrojo ambiental 4	6	8	0	14	28,445	99.951
Infrarrojo planta 1	2	6	0	8	28,451	99.972

Temperatura solución	0	4	0	4	28,455	99.986
Infrarrojo planta 2	2	3	0	5	28,454	99.982
Infrarrojo planta 3	2	3	0	5	28,454	99.982
Infrarrojo ambiental 3	2	2	0	4	28,455	99.986
Infrarrojo ambiental 2	2	2	0	4	28,455	99.986
Infrarrojo ambiental 1	2	2	0	4	28,455	99.986
Conductividad eléctrica	0	2	0	2	28,457	99.993
Temperatura piso 1	0	1	0	1	28,458	99.996
Radiación piso 3	0	1	0	1	28,458	99.996

En total, se almacenaron 907,200 datos de las 30 variables monitoreadas; con base en los conteos de datos válidos e inválidos y en los datos no recibidos de cada variable, la completitud (C %) del sistema fue de 93,686 % (Cuadro 3.7).

Cuadro 3.7. Completitud global del sistema: conteo de registros válidos, inválidos y faltantes (21 días, 30 variables).

Variable	Total
Datos totales (21 días)	907,200
Datos totales recibidos	853,770
Datos validos recibidos	849,922
Datos inválidos recibidos	3,848
Total de datos faltantes (inválidos recibidos más no recibidos)	57,278
% De datos validos recibidos	99,549
% De datos inválidos recibidos	0.451
% Total de datos faltantes	6.314
Total de datos validos (C %)	93.686

La cantidad de registros inválidos fue baja, aunque algunas señales, especialmente el pH, mostraron mayor tendencia a descartarse. Esto es coherente con la susceptibilidad de estos sensores a la presencia de suciedad o sulfatación en las terminales eléctricas. Asimismo, algunos sensores MLX presentaron fallos puntuales por falsos contactos, lo que resalta la importancia de fortalecer las conexiones físicas y realizar mantenimiento preventivo.

Desde una perspectiva metrológica, el esquema de filtrado basado en límites fijos y en la detección de “saltos imposibles” es funcional, pero puede generar falsos positivos. Para evitar descartes innecesarios, se propone incorporar filtros robustos (p. ej., tipo Hampel o basados en derivada) antes del descarte duro y recalibrar el $\Delta_{\text{máx}}$ por canal usando percentiles de $|\Delta|$ (por ejemplo, P99) en lugar de umbrales constantes. Esta aproximación es consistente con las guías recientes de medición microclimática, que recomiendan cuantificar explícitamente la incertidumbre instrumental y la sensibilidad de los umbrales de filtrado (De Frenne et al., 2025), así como con el marco FAIR, que enfatiza la definición clara de metadatos y diccionarios de variables para asegurar la reproducibilidad y reutilización de los datos (Wilkinson et al., 2016).

3.3.3 Desempeño del dashboard IoT y trazabilidad de datos

Durante el período de monitoreo, el sistema mantuvo una frecuencia de actualización de 2 s (correspondiente al tiempo que tarda en recibir los datos del ESP32-S3-N16R8). La latencia de extremo a extremo (desde la lectura hasta la visualización) no se cuantificó en este estudio; por lo tanto, describimos la interfaz como “cuasi en tiempo real”. Durante los 21 días de operación, se mantuvo una conexión estable a través del túnel Ngrok, sin interrupciones significativas.

La Figura 3.9 y Figura 3.10 muestran la interfaz principal del panel, organizada en niveles de cultivo y tipos de variables.




Figura 3.9. Panel principal del Dashboard: se muestran las variables medidas en cada piso y las variables correspondientes a la solución nutritiva.



Figura 3.10. Panel de sensores infrarrojos: se presentan las lecturas de temperatura de planta y de temperatura ambiental de cada sensor MLX90614.

Este desempeño sugiere que la arquitectura basada en ESP32 + Raspberry Pi 5 + Node-RED es adecuada para el monitoreo continuo, aunque queda pendiente cuantificar las métricas de latencia (p50/p95) que permitan validar formalmente el carácter “en tiempo casi real” de la visualización.

3.3.4 Captura y gestión de imágenes

El sistema de captura automatizada generó un total de 8,784 de las 9,072 imágenes RGB-D (96.825 %) esperadas durante los 21 días del ensayo, a una frecuencia de 3 capturas diarias (144 imágenes por captura), con un traslape del 80 %. Las imágenes faltantes corresponden a los cortes energéticos números 5 y 6 reportados en el Cuadro 3.4. La Figura 3.11 y la Figura 3.12 ilustran ejemplos de imágenes RGB y de profundidad obtenidas, en las que se aprecia la progresión fenotípica de las plantas en el nivel superior.



Figura 3.11. Imagen RGB (a) e imagen de profundidad (b) de plantas a 5 días del trasplante.



Figura 3.12. Imagen RGB (a) e imagen de profundidad (b) de plantas a 21 días del trasplante

El porcentaje de imágenes efectivamente capturadas confirma que la plataforma robótica y la cámara RGB-D opera de forma sincronizada con la adquisición de datos ambientales, proporcionando una base sólida para futuras tareas de fenotipado de alto rendimiento.

3.3.5 Solución nutritiva, parámetros ambientales y del cultivo

Se presenta el comportamiento de los datos recabados por la red de sensores durante el período de evaluación; las gráficas mostradas manifiestan las brechas de ausencia de datos, así como los datos inválidos recibidos.

Solución nutritiva

La bomba recirculante mantuvo un caudal promedio de 11.28 L min^{-1} y regó un promedio de 141.15 L durante los periodos de riego. La temperatura promedio de la solución fue de $21.05 \text{ }^{\circ}\text{C}$ (Figura 3.13). Durante los 21 días, el agua total utilizada en el sistema fue de 223 L , de los cuales 117 L correspondían a iniciales (90 en el reservorio y 27 en el sistema hidráulico), más 106 L añadidos a lo largo del tiempo.




Figura 3.13. Dinámica de la temperatura en la solución nutritiva.

Las variables de pH (Figura 3.14) y conductividad eléctrica (Figura 3.15) de la solución se encontraron, en promedio, en 6.67 y $2002.06 \text{ } \mu\text{S cm}^{-1}$, respectivamente.




Figura 3.14. Comportamiento del pH de la solución nutritiva durante el experimento (a: se agregó agua al sistema; b: error humano al agregar más ácido del necesario; c: adaptación radicular; d: falla del sensor por sulfatación en las terminales eléctricas).




Figura 3.15. Comportamiento de la CE de la solución nutritiva durante el experimento (a: se agregó agua al sistema; b: se compensó el descenso brusco del pH agregando agua; c: aumento de la CE tras 8 días del trasplante).

En cuanto a la gestión nutricional, las oscilaciones en pH y CE permanecieron dentro de los rangos aceptables para la espinaca en hidroponía, aunque se presentaron episodios puntuales relacionados con errores humanos y fallos en el sensor. El patrón observado indica que el ambiente radicular no limitó el crecimiento de la parte aérea. La literatura señala que la temperatura de las raíces (RZT) en sistemas NFT es un factor clave para la absorción de nutrientes y la acumulación de biomasa; temperaturas subóptimas afectan el transporte y el crecimiento, mientras que temperaturas adecuadas fomentan el flujo de

nutrientes hacia la parte aérea (Wang et al., 2022). En este contexto, la RZT (~21 °C) es consistente con condiciones favorables para la espinaca.

Aunque el caudal total medio fue suficiente para evitar estancamientos visibles, estudios recientes destacan que la oxigenación en la zona radicular y un control preciso del flujo de solución son cruciales para el crecimiento y la morfología de las raíces en hidroponía NFT (Baiyin et al., 2021; Nitu et al., 2024). Por ello, se recomienda medir el oxígeno disuelto y caracterizar el caudal en cada tubo NFT, con el fin de optimizar el entorno radicular y mejorar la respuesta de la biomasa.

Variables ambientales

Las temperaturas promedio registradas por los sensores ambientales (Figura 3.16) fueron de 20.54, 20.75 y 21.16 °C en los pisos 1, 2 y 3, respectivamente, con una temperatura media general de 20.82 ± 0.26 °C. Se aprecia una disminución de la temperatura a partir del 23/07/2025, debido a un periodo de lluvias intenso.




Figura 3.16. Comportamiento de la temperatura por nivel durante el experimento.

Las humedades relativas promedio por piso (Figura 3.17) fueron de 69.93, 73.22 y 73.39 % en los pisos 1, 2 y 3, respectivamente, con una humedad relativa media general de 72.18 ± 1.59 %.




Figura 3.17. Comportamiento de la humedad por piso durante el experimento.

Para el caso de las concentraciones promedio de CO_2 por piso (Figura 3.18), fueron de 573.91 ppm en el piso 1, 616.5 ppm en el piso 2 y 614.50 ppm en el piso 3, con una concentración media general de 601.64 ± 19.62 ppm. Los picos inconsistentes presentes en la gráfica se deben a la operación de maquinaria cerca de las instalaciones donde se encuentra la mini-PFAL.




Figura 3.18. Comportamiento del CO_2 durante el experimento.

En cuanto a las condiciones de iluminación (Figura 3.19), los tres pisos de la mini-PFAL se comportaron de manera similar, con una variación relativa de $\pm 2-3$ % respecto del promedio. En general, el sensor del piso 1 registró que las lámparas de este piso estuvieron encendidas durante 261 h (15,660 min); el sensor del piso 2, 254.1 h (15,246 min); y el sensor del tercer piso, 267.61 h (16,057 min). Las diferencias en la presencia de luz en

el piso 3 pueden deberse a que es el piso superior; el sensor de este piso alcanza a percibir la luz de las lámparas del cuarto (encendidas ocasionalmente por la presencia de personal en las instalaciones durante el período nocturno). La diferencia entre el piso 2 y el piso 1 puede deberse a que el sensor estuvo cubierto por las hojas de las plantas y se registraron valores inferiores al umbral permitido para considerar un dato válido, por lo que el filtro aplicado los descartó.




Figura 3.19. Presencia o ausencia de luz en cada piso de la mini-PFAL.

Parámetros fisiológicos

En el caso de las temperaturas registradas por los sensores MLX90614, que miden la temperatura del cultivo y la temperatura ambiental, sus valores promedio se presentan en el Cuadro 3.8 y las gráficas de comportamiento se muestran en las **¡Error! No se encuentra el origen de la referencia.** y Figura 3.21. Con base en los promedios por sensor, la temperatura de planta fue de 19.80 ± 0.38 °C y la temperatura ambiental, de 22.08 ± 0.63 °C. El diferencial térmico ($\Delta T = \text{ambiental} - \text{planta}$) promedió 2.28 ± 0.38 °C (rango: 1.88–2.99 °C). Por piso, el ΔT medio aumentó con la altura: 2.07 °C (piso 1), 2.24 °C (piso 2) y 2.55 °C (piso 3). Las medias por piso fueron: planta, 19.49, 19.66 y 20.26 °C; ambiente, 21.55, 21.89 y 22.81 °C, respectivamente, lo que muestra un gradiente vertical de ~0.77 °C en planta y de 1.26 °C en ambiente.

Cuadro 3.8. Temperaturas promedio por sensor MLX90614: planta vs. ambiente, agrupadas por piso.

Piso	No. sensor	Promedio de planta	Promedio ambiental
------	------------	--------------------	--------------------

1	1	19.44 °C	21.32 °C
	2	19.53 °C	21.78 °C
2	3	19.64 °C	21.96 °C
	4	19.67 °C	21.82 °C
3	5	20.41 °C	22.51 °C
	6	20.11 °C	23.10 °C




Figura 3.20. Comportamiento de la temperatura de la planta durante el experimento.




Figura 3.21. Comportamiento de la temperatura ambiente durante el experimento.

Los gradientes verticales de T/RH/CO₂, junto con la diferencia consistente entre la temperatura de la planta y la del aire (ΔT positiva), respaldan la presencia de una transpiración activa: la hoja, algo más fría que el aire, indica un intercambio gaseoso funcional. La literatura indica que ΔT se relaciona con la conductancia estomática y el déficit de presión de vapor (VPD); cuando la transpiración es eficiente, la hoja suele estar más fría, pero bajo condiciones de VPD extremo o cierre estomático, ΔT disminuye o incluso se invierte (Mayanja et al., 2024). En

este ensayo, los valores moderados de VPD combinados con T y HR, junto con $\Delta T > 0$, son coherentes con un equilibrio hídrico adecuado.

Por otro lado, la caracterización previa del PPFD y del DLI (Cuadro 3.1) muestra que, durante la fase de crecimiento, la planta recibe aproximadamente $17 \text{ mol m}^{-2} \text{ d}^{-1}$, un rango considerado favorable para la espinaca en PFAL (Gao et al., 2020). La disposición y el diseño de las luminarias LED influyen directamente en la uniformidad del PPFD; simulaciones y mediciones en sistemas similares sugieren que pequeñas variaciones en la ventilación o la distribución de luces entre niveles pueden amplificarse en gradientes de ΔT y afectar la distribución del crecimiento (Saito et al., 2020). En este caso, la mini-PFAL presenta un PPFD aceptable ($\text{CV} < 15 \%$), aunque se recomienda ajustar la posición de las luminarias para mejorar la uniformidad sin alterar significativamente el DLI.

3.3.6 Desempeño de la mini-PFAL y acumulación de biomasa

La mini-PFAL (Figura 3.22) operó de manera estable durante los 21 días del ciclo productivo. No se detectaron fallas mecánicas; tampoco se observaron fugas ni taponamientos en los conductos.



Figura 3.22. Estructura de la mini-PFAL con sistema hidropónico tipo NFT y arreglo de luminarias LED (vista frontal).

Las plantas presentaron crecimiento homogéneo y follaje sano; no se observaron clorosis, necrosis ni deformaciones visibles (Figura 3.23).



Figura 3.23. Planta representativa del cultivo tras 15 días de trasplante.

Los datos resumidos de los muestreos realizados para medir el crecimiento vegetal se presentan en el Cuadro 3.9.

Cuadro 3.9. Crecimiento y biomasa: comparación inicial vs. final.

Variable	Muestreo inicial (media $\pm$ de)	Muestreo final (media $\pm$ de)
Altura de planta (cm)	10.0 $\pm$ 0.7	23.2 $\pm$ 1.6
Longitud de raíz (cm)	15.8 $\pm$ 3.1	37.9 $\pm$ 4.5
Peso fresco biomasa (g)	6.3 $\pm$ 0.3	83.8 $\pm$ 2.5
Peso fresco raíz (g)	3.3 $\pm$ 0.6	17.9 $\pm$ 1.5
Peso fresco total (g)	9.6 $\pm$ 0.6	101.5 $\pm$ 3.8
Peso seco biomasa (g)	0.45 $\pm$ 0.05	6.0 $\pm$ 0.5
Peso seco raíz (g)	0.17 $\pm$ 0.03	0.79 $\pm$ 0.10
Peso seco total (g)	0.62 $\pm$ 0.07	6.9 $\pm$ 0.6

Durante el período experimental, las plantas mostraron un aumento notable de su biomasa acumulada. El peso fresco total aumentó de 9.6 $\pm$ 0.6 g a 101.5 $\pm$ 3.8

g, lo que equivale a un crecimiento aproximado del 958 %. De manera similar, el peso seco total pasó de 0.62 ± 0.07 g a 6.9 ± 0.6 g, lo que representa un incremento superior al 1000 % desde el inicio. Estos datos reflejan un crecimiento vigoroso y una eficiente acumulación de materia seca durante todo el ciclo de cultivo.

El aumento en la masa aérea observado es coherente con un ambiente no limitante en la zona radicular y condiciones de microclima adecuadas. La incorporación de un control efectivo del pH, CE y temperatura de la solución, junto con gradientes térmicos moderados y un DLI dentro del rango recomendado para espinaca, explica la magnitud de la respuesta en biomasa. Esto coincide con estudios que indican que una RZT óptima en NFT y un buen suministro de oxígeno en la solución favorecen el desarrollo radicular y la acumulación de materia seca en la parte aérea (Baiyin et al., 2021; Wang et al., 2022; Nitu et al., 2024). En resumen, el comportamiento conjunto de las variables ambientales, de la solución nutritiva, de los parámetros fisiológicos (ΔT) y de la biomasa, respalda que la mini-PFAL funcionó como un entorno de cultivo estable y controlado, capaz de sostener un crecimiento vigoroso de espinaca y de generar datos de alta resolución y calidad suficiente para análisis agronómicos y de ingeniería.

3.4 Conclusiones

Este trabajo comprobó la viabilidad de una arquitectura modular de IoT para una mini-PFAL de tres niveles, integrando microcontroladores ESP32, una Raspberry Pi 5, Node-RED, una base de datos MariaDB y un sistema de captura automatizada de imágenes RGB-D. Durante 21 días de operación continua, se registraron 30 variables con una completitud global del 93.686 %, más del 99 % de los datos recibidos fueron válidos y se documentaron métricas de disponibilidad, MTBF y MTTR, así como la trazabilidad minuto a minuto del cultivo. Las plantas de espinaca mostraron un crecimiento vigoroso y homogéneo, con incrementos superiores al 900 % en la biomasa fresca y seca, lo que indica que el sistema de cultivo y el manejo de la solución nutritiva fueron agronómicamente funcionales. La incorporación del monitoreo ambiental, de la

solución nutritiva, de los parámetros fisiológicos (como la temperatura de la planta en comparación con el ambiente) y de un sistema de visión RGB-D facilitó la recolección de un conjunto de datos detallado, ideal para futuras aplicaciones de análisis avanzado y fenotipado en PFAL. Sin embargo, los resultados también evidencian límites claros: la arquitectura se mantiene en el nivel de monitoreo y adquisición de datos, sin implementar todavía control en el lazo cerrado, analítica predictiva ni estrategias de optimización automática de los recursos. A partir de los hallazgos, se señalan tres áreas clave para mejorar: medir con precisión la latencia de extremo a extremo para confirmar que el sistema opera casi en tiempo real; mejorar la resistencia ante cortes de energía o problemas de conexión mediante técnicas de almacenamiento local, reintentos y reconexión automática del acceso remoto; y establecer reglas metrológicas más estrictas (como calibración, filtros robustos, umbrales por variable y documentación de QA/QC) que disminuyan la probabilidad de datos inválidos y faciliten la reutilización de los datos. Abordar estos aspectos permitirá transformar la mini-PFAL, de una plataforma de monitoreo confiable, en un sistema agrícola verdaderamente “inteligente” y en una PFAL de próxima generación. En conjunto, los resultados respaldan que la arquitectura propuesta es adecuada para el monitoreo continuo en PFAL a pequeña escala y sienta bases sólidas para escalar a despliegues más grandes.

Literatura citada

- Akhtar, M. S., Zafar, Z., Nawaz, R., & Fraz, M. M. (2024). Unlocking plant secrets: A systematic review of 3D imaging in plant phenotyping techniques. *Computers and Electronics in Agriculture*, 222, 109033. <https://doi.org/10.1016/j.compag.2024.109033>
- Baiyin, B., Tagawa, K., Yamada, M., Wang, X., Yamada, S., Shao, Y., An, P., Yamamoto, S., & Ibaraki, Y. (2021). Effect of nutrient solution flow rate on hydroponic plant growth and root morphology. *Plants*, 10(9), 1840. <https://doi.org/10.3390/plants10091840>
- Condotta, I. C. F. S., Brown-Brandl, T. M., Pitla, S. K., Stinn, J. P., & Silva-Miranda, K. O. (2020). Evaluation of low-cost depth cameras for agricultural applications. *Computers and Electronics in Agriculture*, 173, 105394. <https://doi.org/10.1016/j.compag.2020.105394>

- De Frenne, P., Beugnon, R., Klinges, D., Lenoir, J., Niittynen, P., Pincebourde, S., Senior, R. A., Aalto, J., Chytrý, K., Gillingham, P. K., Greiser, C., Gril, E., Haesen, S., Kearney, M., Kopecký, M., le Roux, P. C., Luoto, M., Maclean, I., Man, M., Penczykowski, R., van den Brink, L., Van de Vondel, S., De Pauw, K., Lembrechts, J. J., Kempainen, J., & Van Meerbeek, K. (2025). Ten practical guidelines for microclimate research in terrestrial ecosystems. *Methods in Ecology and Evolution*, 16(2), 269–294. <https://doi.org/10.1111/2041-210X.14476>
- Domínguez-Bolaño, T., Campos, O., Barral, V., Escudero, C. J., & García-Naya, J. A. (2022). An overview of IoT architectures, technologies, and existing open-source projects. *Internet of Things*, 20, 100626. <https://doi.org/10.1016/j.iot.2022.100626>
- Fathidarehniyeh, E., Nadeem, M., Cheema, M., Thomas, R., Krishnapillai, M., & Galagedara, L. (2024). Current perspective on nutrient solution management strategies to improve the nutrient and water use efficiency in hydroponic systems. *Canadian Journal of Plant Science*, 104(2), 88–102. <https://doi.org/10.1139/cjps-2023-0034>
- García, L., Parra, L., Jimenez, J. M., Lloret, J., & Lorenz, P. (2020). IoT-Based Smart Irrigation Systems: An Overview on the Recent Trends on Sensors and IoT Systems for Irrigation in Precision Agriculture. *Sensors*, 20(4), 1042. <https://doi.org/10.3390/s20041042>
- Gao, W., He, D., Ji, F., Zhang, S., & Zheng, J. (2020). Effects of daily light integral and LED spectrum on growth and nutritional quality of hydroponic spinach. *Agronomy*, 10(8), 1082. <https://doi.org/10.3390/agronomy10081082>
- Intel. (2019). Intel RealSense Depth Camera D400 Series: Datasheet. <https://cdrdv2-public.intel.com/841984/Intel-RealSense-D400-Series-Datasheet.pdf>
- Kozai, T., Niu, G., & Takagaki, M. (Eds.). (2019). *Plant Factory: An Indoor Vertical Farming System for Efficient Quality Food Production* (2nd ed.). Academic Press/Elsevier.
- Lekić, M., & Gardašević, G. (2018, March). IoT sensor integration to Node-RED platform. En *Proceedings of the 2018 17th International Symposium INFOTEH-JAHORINA (INFOTEH)* (pp. 1-5). IEEE. <https://doi.org/10.1109/INFOTEH.2018.8345544>
- Li, S., Cui, Z., Yang, J., & Wang, B. (2025). A review of optical-based three-dimensional reconstruction and multi-source fusion for plant phenotyping. *Sensors*, 25(11), 3401. <https://doi.org/10.3390/s25113401>
- MariaDB Corporation. (2025). InnoDB redo log. <https://mariadb.com/kb/en/innodb-redo-log/>

- Mayanja, I. K., Longchamps, L., O'Sullivan, C., & Smith, D. (2024). Practical considerations and limitations of using leaf and canopy temperature. *Field Crops Research*, 310, 108132. <https://doi.org/10.1016/j.fcr.2024.108132>
- Meng, Q., Liu, Y., Portis, E., Giovannetti, M., Sunseri, F., & Scattino, C. (2022). Quantitative trait locus mapping and identification of candidate genes controlling bolting in spinach (*Spinacia oleracea* L.). *Frontiers in Plant Science*, 13, 850810. <https://doi.org/10.3389/fpls.2022.850810>
- Mercier, F., Couasnet, G., El Ghaziri, A., Bouhlel, N., Sarniguet, A., Marchi, M., Barret, M., & Rousseau, D. (2025). Deep-learning-ready RGB-depth images of seedling development. *Plant Methods*, 21, 16. <https://doi.org/10.1186/s13007-025-01334-3>
- Nitu, O. A., Ivan, E. Ş., Tronac, A. S., & Arshad, A. (2024). Optimizing lettuce growth in nutrient film technique hydroponics: Evaluating the impact of elevated oxygen concentrations in the root zone under LED illumination. *Agronomy*, 14(9), 1896. <https://doi.org/10.3390/agronomy14091896>
- Node-RED. (n.d.). Getting started: Raspberry Pi. <https://nodered.org/docs/getting-started/raspberrypi>
- Saito, K., Iwasaki, Y., Goto, E., Fujiwara, K., & Kozai, T. (2020). Evaluation of the light environment of a plant factory using optical simulation. *Agronomy*, 10(11), 1663. <https://doi.org/10.3390/agronomy10111663>
- Schunck, D., Magistri, F., Rosu, R. A., Cornelißen, A., Chebrolu, N., Paulus, S., Léon, J., Behnke, S., Stachniss, C., Kuhlmann, H., & Klingbeil, L. (2021). Pheno4D: A spatio-temporal dataset of maize and tomato plant point clouds for phenotyping and advanced plant analysis. *PLOS ONE*, 16(8), e0256340. <https://doi.org/10.1371/journal.pone.0256340>
- Singh, K., Yadav, M., Singh, Y., Barak, D., Saini, A., & Moreira, F. (2024). Reliability on the Internet of Things with designing approach for exploratory analysis. *Frontiers in Computer Science*, 6, 1382347. <https://doi.org/10.3389/fcomp.2024.1382347>
- Song, P., Li, Z., Yang, M., Shao, Y., Pu, Z., Yang, W., & Zhai, R. (2023). Dynamic detection of three-dimensional crop phenotypes based on a consumer-grade RGB-D camera. *Frontiers in Plant Science*, 14, 1097725. <https://doi.org/10.3389/fpls.2023.1097725>
- Thimijan, R. W., & Heins, R. D. (1983). Photometric, radiometric, and quantum light units of measure: A review of procedures for interconversion. *HortScience*, 18(6), 818–822. <https://doi.org/10.21273/HORTSCI.18.6.818>
- Wang, R.-F., Qu, H.-R., & Su, W.-H. (2025). From sensors to insights: Technological trends in image-based high-throughput plant phenotyping. *Smart Agricultural Technology*, 12, 101257. <https://doi.org/10.1016/j.smate.2025.101257>

- Wang, R., Zhou, Z., Xie, J., & Zhao, T. (2022). Root-zone temperature effects on spinach biomass production using a nutrient film technique system. *HortScience*, 57(4), 532–540. <https://doi.org/10.21273/HORTSCI16472-21>
- Wilkinson, M. D., Dumontier, M., Aalbersberg, I. J., *et al.* (2016). The FAIR guiding principles for scientific data management and stewardship. *Scientific Data*, 3, 160018. <https://doi.org/10.1038/sdata.2016.18>
- Xu, R., & Li, C. (2022). A review of high-throughput field phenotyping systems: Focusing on ground robots. *Plant Phenomics*, 2022, 9760269. <https://doi.org/10.34133/2022/9760269>
- Zhuang, Y., Lu, N., Kikuchi, M., Takagaki, M., & Tamashiro, T. (2024). Productivity potential and economic feasibility of small-sized tomato production in plant factories with artificial lighting: A comparative study with high-tech greenhouse production. *Journal of Cleaner Production*, 470, 143171. <https://doi.org/10.1016/j.jclepro.2024.143171>