



UNIVERSIDAD AUTÓNOMA CHAPINGO

POSGRADO EN INGENIERÍA AGRÍCOLA Y USO INTEGRAL DEL AGUA

DISEÑO Y EVALUACIÓN DE UN SISTEMA DE MONITOREO IOT Y MODELADO PARA ACUAPONIA

TESIS DE GRADO

Que como requisito parcial
para obtener el grado de:

Doctor en Ingeniería Agrícola
y Uso Integral del Agua




APROBADA



PRESENTA:

CARLOS ENRIQUE ALVAREZ MORENO

Bajo la supervisión de: AGUSTÍN RUIZ GARCÍA, Dr.



Chapingo, Estado de México, noviembre de 2024

**DISEÑO Y EVALUACIÓN DE UN SISTEMA DE MONITOREO IOT Y
MODELADO PARA ACUAPONIA**

Tesis realizada por **CARLOS ENRIQUE ALVAREZ MORENO** bajo la supervisión del Comité Asesor indicado, aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

DOCTOR EN INGENIERÍA AGRÍCOLA Y USO INTEGRAL DEL AGUA

DIRECTOR:



DR. AGUSTÍN RUIZ GARCÍA

ASESOR:



DR. IRINEO L. LÓPEZ CRUZ

ASESOR:



DR. JOEL PINEDA PINEDA

LECTOR EXTERNO:



DR. JOSÉ OLAF VALENCIA ISLAS

CONTENIDO

Lista de cuadros.....	v
Lista de figuras.....	vi
Resumen general.....	xiii
General Abstract.....	xiv
1. Introducción general.....	2
1.1 Objetivos.....	5
1.2 Estructura de la tesis.....	6
1.3 Referencias.....	6
2. Revisión de literatura.....	11
2.1 Introducción a la acuaponía.....	11
2.1.1 Ventajas y desventajas de la acuaponía.....	11
2.1.2 Componentes de un sistema acuapónico.....	12
2.2 Cultivo de Tilapia del Nilo (<i>Oreochromis niloticus</i>).....	15
2.2.1 Etapas de crecimiento.....	15
2.3 Cultivo de lechuga.....	16
2.3.1 Acumulación de nitrato y su relación con el pH.....	17
2.4 Diseño de unidades de sistemas acuapónicos.....	17
2.5 Parámetros importantes en sistemas acuapónicos.....	21
2.5.1 Calidad del agua.....	21
2.5.2 Parámetros Ambientales.....	23
2.6 Sistema de monitoreo en acuaponía.....	24
2.6.1 Microcontrolador.....	26
2.6.2 Módulos.....	26
2.6.3 Sensores.....	26
2.7 Sistemas IoT.....	28
2.7.1 Plataformas software.....	29
2.7.2 Interfaz de programación de aplicación (API).....	29
2.7.3 Tecnologías inalámbricas.....	30

2.8	Modelación matemática	30
2.9	Modelos del crecimiento de lechuga	31
2.10	Referencias.....	32
3.	Diseño, implementación y evaluación de un sistema de monitoreo basado en lot y predicción de oxígeno disuelto para un sistema acuapónico	40
3.1	Resumen.....	40
3.2	Introducción	41
3.3	Materiales y métodos	43
3.4	Resultados y discusión	49
3.5	Referencias.....	62
4	Análisis de sensibilidad y calibración de un modelo dinámico de crecimiento y absorción de nitrógeno para lechuga en acuaponía	69
4.1	Resumen.....	69
4.2	Introducción	69
4.3	Materiales y métodos	71
4.4	Resultados y discusión	82
4.5	Conclusiones.....	90
4.6	Referencias.....	90
5.	Conclusiones generales	93

Lista de cuadros

Cuadro 1. Condiciones fisicoquímicas y ambientales óptimas para el cultivo de lechuga en un sistema acuapónico (Bautista, et al. 2021).	16
Cuadro 2. Estrategias para el uso del agua en la producción de lechuga bajo sistemas hidropónicos en diferentes estudios (Moreno et al., 2015).	20
Cuadro 3. Características de los sensores usados en el sistema de monitoreo (Elaboración propia).....	47
Cuadro 4. Estadísticos de ajuste obtenidos durante el entrenamiento y evaluación de la red neuronal artificial para la estimación del oxígeno disuelto (OD) en el sistema acuapónico.....	61
Cuadro 5. Parámetros del modelo dinámico para lechuga como factores de entrada para el análisis de sensibilidad global con el método de Sobol, y una variación de 30% del valor nominal.	79
Cuadro 6. Parámetros estimados del modelo dinámico para lechuga mediante evolución diferencial.....	88
Cuadro 7. Estadísticas de calibración y validación del modelo dinámico para lechuga con el algoritmo de evolución diferencial clásico DE/rand/1/bin.	90

Lista de figuras

Figura 1. Comparación de sistemas de producción acuícola. A) sistema tradicional; B) Sistema RAS; C) Sistema biofloc; D) Sistema Acuaponico. (Sánchez, et al. 2023).....	12
Figura 2. A) Sistema acuapónico tradicional; y B) Sistema acuapónico acoplado y desacoplado (Aslanidou et al., 2023).....	13
Figura 3. Sistema acuapónico con tanques IBC, mostrando las secciones de tanque de cultivo, sumidero y área de crecimiento de plantas, diseñado para optimizar el flujo de agua y el cultivo de hortalizas en sustrato. (Somerville, et al. 2022).	18
Figura 4. Esquema de un sistema acuapónico con tanque de peces, filtros y área de crecimiento vegetal en un sistema de cultivo hidropónico NFT, diseñado para maximizar el uso eficiente del agua y nutrientes. (Somerville, et al. 2022)... ..	19
Figura 5. Sistema acuapónico compuesto por tanques de peces, filtros y zona de crecimiento vegetal, incluyendo balsas flotantes como cama de cultivo para maximizar la producción de plantas y asegurar una buena filtración del agua. (Somerville, et al. 2022).	20
Figura 6. Componentes del sistema acuapónico donde se colocaron los sensores para la medición de variables ambientales y fisicoquímicas.	44
Figura 7. Diagrama del sistema de monitoreo para el sistema de recirculación acuapónico. Parte I: Módulo de adquisición de datos (parte izquierda); Parte II: Módulo de comunicación (parte derecha).	46
Figura 8. Variación de la radiación fotosintéticamente activa (PAR) durante los cuatro ciclos de cultivo de lechuga (febrero a julio de 2023) en el sistema acuapónico.	50
Figura 9. Temperaturas internas (TII) y externas (TEI) durante los cuatro experimentos realizados entre febrero y julio de 2023.....	51
Figura 10. Variación de la temperatura del agua en el sistema acuapónico durante los cuatro ciclos de cultivo de lechuga.....	52
Figura 11. Variación del oxígeno disuelto (OD) en el sistema acuapónico durante los dos ciclos de cultivo entre junio y julio de 2023.....	54
Figura 12. Variación de la conductividad eléctrica (CE, $\mu\text{S cm}^{-1}$) en el estanque de peces (rojo) y en la balsa flotante (azul) durante los cuatro ciclos de cultivo entre febrero y julio de 2023.	55

Figura 13. Interfaz de visualización en Google Sheets del sistema de monitoreo IoT para variables ambientales y fisicoquímicas en un sistema acuapónico.	56
Figura 14. Tilapia (<i>Oreochromis niloticus</i>) de 472 gramos y lechugas (<i>Lactuca sativa</i> L.) cultivadas en el sistema acuapónico donde con monitoreo basado en IoT.	57
Figura 15. Matriz de correlación entre variables ambientales y el oxígeno disuelto (OD).	59
Figura 16. Arquitectura de la red neuronal utilizada para la estimación del oxígeno disuelto en el sistema acuapónico, con una capa de entrada de seis variables, una capa oculta de 13 nodos con función tangente sigmoideal y una capa de salida con función lineal.	60
Figura 17. Relación entre los datos medidos y simulados de oxígeno disuelto (OD) utilizando la red neuronal artificial en la etapa de entrenamiento (izquierda) y evaluación (derecha). La línea roja representa el mejor ajuste lineal.	61
Figura 18. a) Modelo para el área proyectada (A), y b) modelo para el índice de área foliar (LAI), lechuga tipo mantequilla para los experimentos 1 y 3.....	83
Figura 19. Mediciones promedio de la intensidad de radiación fotosintéticamente activa y temperatura como entradas del modelo dinámico para el experimento 1.	85
Figura 20. Mediciones promedio de la intensidad de radiación fotosintéticamente activa y temperatura como entradas del modelo dinámico para el experimento 3.	86
Figura 21. Índices de sensibilidad global para el experimento 3 estimadas con el método de Sobol para los parámetros del modelo de Zhang para las variables de estado: A) nitrógeno acumulado Nup , B) biomasa no estructural wG , y C) biomasa estructural wS	86
Figura 22. Acumulación de nitrógeno (Nup) y materia seca (w) para lechuga en acuaponía simulado con el modelo calibrado para el experimento 3.....	89
Figura 23. Acumulación de nitrógeno (Nup) y materia seca (w) para lechuga en acuaponía simulado con el modelo calibrado para el experimento 3.....	89

DEDICATORIAS

Dedico este trabajo a las personas que han sido una fuente constante de motivación, apoyo y amor en mi vida:

A mi madre, Norma Guadalupe Moreno Valdés, por darme la vida y por su incansable esfuerzo para educarme, inculcándome los valores de sacrificio, confianza y superación. Gracias por guiarme en cada paso y enseñarme a luchar por mis sueños, haciéndome una persona comprometida y útil para la sociedad.

Para Josué Trinidad y Dulce María, por su constante apoyo incondicional, por respaldar cada una de mis decisiones y por acompañarme en cada etapa de mi vida.

A mis sobrinos, Danahe y Sebastián, por llegar en un momento crucial y llenar nuestras vidas de alegría, siendo la fuente de motivación para seguir adelante y un ejemplo a seguir en el futuro profesional.

A mi esposa, Brizía Yamilette, por su apoyo inquebrantable en la realización de cada una de mis metas, por creer en nuestro proyecto de vida y por brindarme la confianza y fortaleza para superar cada reto que se me ha presentado.

A mi querido amigo, Jesús Antonio, por demostrarme que la verdadera familia no solo está unida por lazos de sangre, sino por el cariño, la amistad y el apoyo mutuo. Gracias por tu apoyo incondicional y por ayudarme a convertir ideas en metas cumplidas, a través del esfuerzo y la dedicación.

A mis amigos y compañeros, en especial a Miguel Servín, David Cano, Mauricio Cervantes y Luisito, por su amistad y por todos los momentos inolvidables que compartimos a lo largo de nuestros estudios.

*A todos ustedes, mi más sincero agradecimiento.
Carlos Enrique*

AGRADECIMIENTOS

Agradezco profundamente al **Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONACYT)** por el apoyo económico brindado, lo que me permitió desarrollar mis estudios de posgrado y concluirlos de manera satisfactoria.

A la **Universidad Autónoma Chapingo y al Posgrado en Ingeniería Agrícola y Uso Integral del Agua (IAUIA)** por brindarme la oportunidad de realizar mis estudios de posgrado y por el acompañamiento académico a lo largo de este proceso.

Al **Círculo de Investigación, Capacitación y Desarrollo Agrícola (CICDA)** por permitirme ser parte de su proyecto y proporcionarme las facilidades a través de sus recursos humanos y económicos para llevar a cabo la etapa experimental del proyecto.

Al **Dr. Agustín Ruiz García**, por depositar su confianza en mí para llevar a cabo este trabajo, por gestionar los recursos y espacios necesarios para el desarrollo del proyecto, y por compartir generosamente su experiencia y conocimientos. Le expreso mi más profundo agradecimiento por el apoyo, el tiempo dedicado y la paciencia brindada.

Al **Dr. Irineo López Cruz**, por proporcionarme las herramientas necesarias y por su valiosa colaboración, permitiéndome llevar a cabo este proyecto de investigación de manera efectiva.

Al **Dr. Joel Pineda Pineda**, por su dedicación y experiencia brindadas a este proyecto, por sus cursos que despertaron mi interés en este tema y por facilitar los espacios necesarios para el análisis de resultados.

A mi familia, por brindarme su confianza para seguir adelante en cada paso, por su apoyo incondicional y por estar siempre presentes durante este proceso.

A todos ustedes, mi más sincero agradecimiento.

DATOS BIOGRÁFICOS



Datos personales

Nombre:	Carlos Enrique Álvarez Moreno
Fecha de nacimiento:	25 de octubre de 1993
Lugar de nacimiento:	Toluca, Estado de México
No. Cartilla Militar:	D-2073546
CURP:	AAMC931025HMCLRR03
Profesión:	Ingeniero Mecánico Agrícola
Cédula profesional:	10209271

Desarrollo Académico

Bachillerato:	Preparatoria Agrícola. Universidad Autónoma Chapingo.
Licenciatura:	Ingeniería Mecánica Agrícola. Universidad Autónoma Chapingo.
Maestría:	Posgrado en Ingeniería Agrícola y Uso Integral del Agua. Universidad Autónoma Chapingo.

Resumen general

DISEÑO E IMPLEMENTACIÓN DE UN SISTEMA DE MONITOREO BASADO EN IOT PARA ACUAPONIA ¹

La acuaponía es un sistema que combina la acuicultura con la hidroponía para crear un ambiente simbiótico, donde los desechos de los peces proporcionan nutrientes para las plantas y las plantas purifican el agua para los peces. Es esencial mantener un control preciso de las variables como la temperatura del agua, el oxígeno disuelto, pH, conductividad eléctrica y radiación, para asegurar un crecimiento óptimo de las plantas y la salud de los peces. Sin un monitoreo adecuado, estas variables pueden variar fuera de los límites permisibles, afectando negativamente la producción. Los objetivos de este trabajo de investigación fueron 1) desarrollar un sistema de monitoreo de variables fisicoquímicas y ambientales de un sistema acuapónico capaz de recopilar datos en tiempo real y 2) transmitirlos a una plataforma centralizada a través de internet (IoT), donde se pueden analizar y visualizar mediante un dispositivo externo. La implementación de este sistema permitió una gestión más eficiente de los recursos y una respuesta rápida a cualquier cambio en el sistema acuapónico. Los datos medidos por el sistema de monitoreo IoT se usaron para calibrar un modelo matemático dinámico que simula el crecimiento y la acumulación de nitrógeno en lechuga acuapónica. El método de Sobol fue utilizado para llevar a cabo un análisis de sensibilidad global del modelo. Los parámetros que más influyeron en la variabilidad de la salida del modelo fueron estimados minimizando una función de error entre las variables medidas y simuladas. De los 13 parámetros del modelo, solamente tres resultaron sensibles, dos relacionados con la absorción de nitrógeno y uno con la tasa de crecimiento. De acuerdo con las estadísticas eficiencia de modelado y raíz del cuadrado medio del error, el modelo calibrado simula de manera satisfactoria la biomasa total y contenido de nitrógeno total en el dosel.

Palabras clave: *Lactuca sativa* L., *Oreochromis niloticus*, balsa profunda, LoRa, método de Sobol, evolución diferencial.

¹ Tesis de Doctorado en Ingeniería Agrícola y Uso Integral del Agua.
Autor: Álvarez-Moreno Carlos Enrique.
Director de Tesis: Ruiz-García Agustín.

General Abstract

DESIGN AND IMPLEMENTATION OF AN IOT-BASED MONITORING SYSTEM FOR AQUAPONICS.²

Abstract.

Aquaponics is a system that combines aquaculture with hydroponics to create a symbiotic environment where fish waste provides nutrients for the plants, and the plants purify the water for the fish. Maintaining precise control of the variables ensures optimal plant growth and fish health. Without adequate monitoring, these variables can vary outside the recommended limits, negatively affecting production. The objectives of this research work were 1) to develop a system for monitoring the physicochemical and environmental variables of an aquaponic system, designed to collect data in real-time and 2) transmit them to a centralized platform through IoT, where they can be analyzed and visualized through a device connected to the internet. Implementing this system allowed for more efficient resource management and rapid response to any changes in the aquaponic system. The data measured by the IoT monitoring system were used to calibrate a dynamic mathematical model that simulates growth and nitrogen accumulation in aquaponic lettuce. The Sobol's method was used to perform a global sensitivity analysis of the model. The parameters that most influenced the variability of the model output were estimated by minimizing an error function between the measured and simulated variables. Of the 13 model parameters, only three were sensitive, two related to nitrogen uptake and one to growth rate. According to the modeling efficiency and root mean square error statistics, the calibrated model satisfactorily simulates the canopy's total biomass and total nitrogen content.

Key words: *Lactuca sativa* L., *Oreochromis niloticus*, deep pond, LoRa, Sobol's method, differential evolution.

² Thesis, Universidad Autónoma Chapingo
Author: Alvarez-Moreno Carlos Enrique
Advisor: Ruiz-García Agustín

1. Introducción general

El aumento de la demanda de alimentos de una población mundial en crecimiento se debe satisfacer mediante la intensificación de la producción agrícola, enfrentando retos como el cambio climático, la eficiencia de recursos, el bienestar animal, reducción de residuos, la seguridad alimentaria y la promoción de estilos de vida saludables en los consumidores (Taher et al., 2023; Wongkiew et al., 2017; Verdouw et al., 2019). Este desafío requiere de soluciones innovadoras que equilibren la sostenibilidad con la productividad, especialmente en lugares donde los recursos son limitados.

La acuaponía ha surgido como una alternativa tecnológica, al combinar hidroponía y acuicultura en un sistema integrado que reduce significativamente el uso de recursos como el agua y nutrientes (Ako y Baker, 2009; Abbey et al., 2019; Pérez et al., 2019). Este enfoque destaca por su potencial de producir alimentos de calidad, aprovechando los desechos metabólicos de peces como fuente de nutrientes para las plantas, en un proceso simbiótico que optimiza la eficiencia de recursos y disminuye impactos ambientales (Velichkova et al., 2019; Wongkiew et al., 2017). Los sistemas acuapónicos destacan por la producción de alimentos orgánicos, con menores residuos químicos, y contribuyen a prevenir la contaminación ambiental al reemplazar los fertilizantes químicos con desechos de peces (Velichkova et al., 2019). Una preocupación en estos sistemas es la acumulación de amoníaco y nitritos, productos metabólicos tóxicos para los peces, que deben ser tratados adecuadamente para garantizar la sostenibilidad del ecosistema (Johnson et al., 2016; Valiente et al., 2018).

Los sistemas acuapónicos se clasifican en tres tipos principales: sustrato sólido o cama de cultivo, de película de nutrientes (NFT) y de balsas flotantes. Los sistemas de cama de cultivo emplean sustratos como arena o biocarbón, ideales para cultivos que requieren mayor retención de agua; los sistemas NFT utilizan una fina película de solución nutritiva que fluye sobre las raíces, optimizando el espacio, especialmente en áreas urbanas; y los sistemas de balsas flotantes

suspenden las raíces en una solución rica en nutrientes oxigenada, destacando por su alta eficiencia en el uso de agua y nutrientes (Somerville et al., 2022). Entre estos, el sistema de balsas flotantes ha mostrado mayor rentabilidad, particularmente en cultivos de hoja como la lechuga (*Lactuca sativa* L.) (Lennard y Leonard, 2006; Abbey et al., 2019).

El suministro adecuado de nutrientes es esencial para el crecimiento óptimo de los cultivos, siendo el nitrógeno, en forma de nitrato (NO_3^-), uno de los elementos clave. Sin embargo, el exceso de nitratos en productos agrícolas representa riesgos para la salud humana debido a su toxicidad (Comisión Europea, 2011; Chowdhury y Das, 2015). En el caso de la lechuga, la acumulación de nitratos varía según factores como el tipo, las condiciones de crecimiento y los fertilizantes utilizados (Lara et al., 2019). Por ello, el manejo eficiente de nutrientes en sistemas acuapónicos es un aspecto crítico para garantizar la calidad e inocuidad del producto final.

El uso de modelos matemáticos en la agricultura ha permitido avanzar en la investigación de sistemas complejos, optimizando la producción sin necesidad de experimentos extensivos y costosos (López, 2003). En horticultura, estos modelos son útiles para maximizar el rendimiento y regular las condiciones ambientales de los cultivos. Por ejemplo, Sweeney et al. (1981) desarrollaron un modelo para lechuga que considera la materia seca estructural y no estructural como variables de estado, mientras que variables como la radiación solar y la temperatura se usan como entradas. Este modelo, validado experimentalmente, logró predecir la biomasa del cultivo (López et al., 2005). Modelos como los de Van Henten (1994a, 1994b) han incorporado estimaciones del contenido de carbohidratos, peso seco estructural y acumulación de nitratos, proporcionando un análisis más detallado de los procesos fisiológicos de la planta (Zhang et al., 2008).

El modelo desarrollado por Zhang et al. (2008), diseñado específicamente para estimar el contenido de nitrógeno y la materia seca en lechuga cultivada en sistemas hidropónicos. Este modelo se compone de tres submodelos interrelacionados: uno para la materia seca estructural, otro para la materia seca no estructural y un tercero para la acumulación total de nitrógeno. La principal fortaleza de este modelo radica en su capacidad para predecir con precisión las necesidades nutricionales del cultivo, permitiendo ajustes precisos en la administración de insumos. Además, este modelo ofrece una herramienta práctica para anticipar cómo varía la demanda de nitrógeno en la lechuga a lo largo de su ciclo de crecimiento. Su implementación en sistemas acuapónicos facilita la optimización del manejo de nutrientes, reduciendo el desperdicio y mejorando la sostenibilidad y rentabilidad del sistema.

Las variables ambientales, como la temperatura del aire, la humedad relativa, la temperatura del agua, los niveles de oxígeno disuelto y la luz, impactan directamente en el desempeño de los sistemas acuapónicos. No obstante, la falta de instrumentación accesible en México dificulta el monitoreo preciso de estas variables, afectando tanto la productividad como la calidad de los cultivos (Lugo et al., 2013). En este sentido, los avances en sensores y microcontroladores han reducido los costos de implementación, haciendo posible el monitoreo continuo y la recopilación precisa de datos ambientales (Esraa, 2023).

El Internet de las Cosas (IoT) ha surgido como una herramienta para superar estas limitaciones. Mediante tecnologías como redes de sensores inalámbricos (WSN), RFID y comunicación de campo cercano (NFC), IoT permite la supervisión remota de sistemas acuapónicos, optimizando el control de variables como pH, oxígeno disuelto y conductividad eléctrica (Khanna et al., 2019; Verdouw et al., 2019). Además, IoT facilita la integración de modelos predictivos basados en inteligencia artificial, permitiendo ajustes automáticos en tiempo real para maximizar la eficiencia y sostenibilidad del sistema (Valiente et al., 2018; Verdouw et al., 2019).

Los retos que enfrenta la acuaponía incluyen la medición en tiempo real de variables críticas como temperatura, pH, oxígeno disuelto, conductividad eléctrica y concentración de nutrientes, así como el control y manejo eficiente del biosistema, que integra peces y plantas en un entorno simbiótico (Somerville et al., 2014; Wongkiew et al., 2017). Aunque las tecnologías IoT ofrecen soluciones prometedoras para el monitoreo y control en tiempo real, su impacto es aún mayor cuando se combinan con modelos matemáticos avanzados, como el de Zhang et al. (2008), que proporcionan simulaciones precisas como referencia para la toma de decisiones. Este trabajo aborda estos desafíos mediante el desarrollo de estrategias que integren monitoreo electrónico, análisis de datos y simulación matemática, optimizando así los recursos y la eficiencia de los sistemas acuapónicos.

1.1 Objetivos

General

Calibrar y validar un modelo matemático dinámico para predecir el crecimiento y la acumulación de nitrógeno en la lechuga (*Lactuca sativa* L.) cultivada en un sistema acuapónico, utilizando un sistema de monitoreo basado en IoT.

Específicos

Diseñar e implementar un sistema de monitoreo capaz de registrar en tiempo real las variables fisicoquímicas y ambientales relevantes para el funcionamiento óptimo de un sistema acuapónico.

Integrar el sistema de monitoreo con una plataforma IoT que permita la recopilación, transmisión y visualización eficiente de los datos, asegurando su accesibilidad para análisis remoto.

Calibrar y validar un modelo matemático dinámico utilizando datos experimentales obtenidos en tiempo real, para simular de manera precisa la biomasa y la acumulación de nitrógeno en lechuga.

Evaluar la efectividad del modelo calibrado para identificar parámetros que influyen en el crecimiento de la lechuga, optimizando el uso de nutrientes y recursos en el sistema acuapónico.

1.2 Estructura de la tesis

Este trabajo se organiza en cuatro capítulos. El primer capítulo presenta una introducción general que contextualiza el problema, expone su justificación e importancia y establece los objetivos principales. El segundo capítulo ofrece una revisión de literatura que sustenta la investigación, enfocándose en los fundamentos de la acuaponía, el monitoreo mediante IoT y la modelación matemática aplicada al cultivo de lechuga. El tercer capítulo, “Diseño, implementación y evaluación de un sistema de monitoreo basado en IoT y predicción de oxígeno disuelto para un sistema acuapónico,” describe el desarrollo de un dispositivo que mide variables fisicoquímicas en un sistema acuapónico de tilapia y lechuga en balsas flotantes, empleando una red neuronal artificial para predecir los niveles de oxígeno disuelto. Se evalúa su precisión y funcionalidad. El cuarto capítulo, “Análisis de sensibilidad y calibración de un modelo dinámico de crecimiento y absorción de nitrógeno para lechuga en acuaponía,” simula la biomasa y la concentración de nitrógeno en lechuga mediante un modelo dinámico. Incluye un análisis de sensibilidad para identificar los parámetros más influyentes en la producción, optimizando el rendimiento del sistema.

1.3 Referencias

- Abbey M., Anderson N., Yue C., Schermann M., Phelps N., Venturelli P., y Vickers Z. (2019). Lettuce (*Lactuca sativa*) Production in Northern Latitudinal Aquaponic Growing Conditions. *HortScience*. 54(10), p. 1757-1761. doi: 10.21273/HORTSCI14088-19.
- Ako H., y Baker A. (2009). Small-Scale Lettuce Production with Hydroponics or Aquaponic. *UH-CTAHR*. 2(1), p. 1-7.
- Carlos, Ramos., Leonel, Nóbrega., Karolina, Baras., L.A., Gomes. (2019). 10. Experimental NFT hydroponics system with lower energy consumption. doi: 10.1109/EXPAT.2019.8876479.
- Comisión Europea (2011). Reglamento (UE) N° 1258/2011 DE LA COMISIÓN EUROPEA. *Diario Oficial de la Unión Europea*. 8 (12), 1-5. doi: 10.2903/j.efsa.2010.1935.

- Chowdhury, A., y Das, A. (2015). Nitrate accumulation and vegetable quality. *International Journal of Science and Research*. 4(2), 1668-1672.
- Esraa, E., Ammar., Ali, A.S., Sayed., Maisara, M., Rabee., Amr, E., Keshta., Malek, G., Daher., Gomaa, A., M., Ali. (2023). 1. Environmental and Agricultural Applications of Sensors. doi: 10.1007/978-3-031-16338-8_50-1
- Essawy H., Nasr P., y Sewilam H. (2019). Aquaponics: a sustainable alternative to conventional agriculture in Egypt-a pilot scale investigation. *Environmental Science and Pollution Research*. 1(1), p. 1-12. doi: doi.org/10.1007/s11356-019-049700
- Fisher, D. K. (2007). Automated collection of soil-moisture data with a low-cost microcontroller circuit. *American Society of Agricultural and Biological Engineers*. 23 (4), 493-500.
- Gary, C. (1999). Modeling greenhouse crops: state of the art and perspectives. *Acta Horticultura*. 495 (19), 317-322.
- Groener, B., Knopp, N., Korgan, K., Perry, R., Romero, J., Smith, K., Stainback, A., Strzelczyk, A., y Henriques, J. (2015). Preliminary design of a Low-Cost greenhouse with open source control systems. *Procedia Engineering*.
- Henten Van, E. J. (1994b). Validation of a dynamic lettuce growth model for greenhouse climate control. *Agricultural System*. 45 (1}, 55-72. doi: 10.1016/S0308-521X(94)90280-1
- Irving, Vitra, Paputungan., Kurniawan, D., Irianto. (2022). 2. Sistem Pemantauan Nutrisi Air Pada Tanaman Hidroponik Model Rakit Apung. *Journal of Information System Research (JOSH)*, doi: 10.47065/josh.v3i4.1843
- Juárez, A. (2010). *Validación del modelo matemático de crecimiento Nicolet b3 para el cultivo de lechuga bajo condiciones de invernadero* (Tesis de maestría). Universidad Autónoma Antonio Narro, Ciencias en Horticultura, México.
- Khanna, A., y Kaur, S. (2019). Evaluation of Internet of Things (IoT) and its significant impact in the field of Precision Agriculture. *Computers and Electronics in Agriculture*, 157(1), 218-231. doi: 10.1016/j.compag.2018.12.039
- Lara, A., Rojas, A., Romero, M., Ramirez, H., Crespo, E., Alcalá, J., y Loredó, C. (2019). Growth and NO_3^- accumulation in hydroponic lettuce with nitrate/ammonium ratios in two cultivation seasons. *Revista Fitotecnia Mexicana*, 42(3), 21-29.

- Lennard, W., y Leonard, B. (2006). A comparison of three different hydroponic sub-systems (gravel bed, floating, and nutrient film technique) in an aquaponic test system. *Springer Science+Business Media B.V.*, 14(1), 539-550. doi: 10.1007/s10499-006-9053-2
- López Cruz, I. L., Van Willigenburg, L. G., y Van Straten, G. (2003). Optimal control of nitrate in lettuce by a hybrid approach: Differential evolution and adjustable control weight gradient algorithms. *Computers and Electronics in Agriculture*, 40(3), 179-197. doi: 10.1016/S0168-1699(03)00019-X
- López, I., Ramirez, A., y Rojano, A. (2004). Sensitivity analysis of a dynamic growth model for greenhouse. *Agrociencia*, 38(6), 613-624.
- López, I., Ramirez, A., & Rojano, A. (2005). Modelos matemáticos de hortalizas en invernadero: Trascendiendo la contemplación de la dinámica de cultivos. *Revista Chapingo Serie Horticultura*, 11(2), 257-267. doi: 10.5154/r.rchsh.2003.08.050
- Love, D., Fry, J., Genello, L., Hill, E., Frederick, J., Li, X., & Semmens, K. (2014). An international survey of aquaponics practitioners. *PLoS ONE*, 9(7), 0-10. doi: 10.1371/journal.pone.0102662
- Lugo, O., Villavicencio, G., y Díaz, S. (2013). Paquete tecnológico para el monitoreo ambiental en invernaderos con el uso de hardware y software libre.
- Manuel, J. I., Alcarraz, E. W., Tapia, O., Atencio, Y. P., Mamani-Coaquira, Y., & Huillcen Baca, H. A. (2020). NFT-I technique using IoT to improve hydroponic cultivation of lettuce. *Proceedings of the Chilean Computer Science Society (SCCC)*, 4. doi: 10.1109/SCCC51225.2020.9281277
- Mehra, M., Saxena, S., Sankaranarayanan, S., & Jackson, R. (2018). IoT based hydroponics system using deep neural networks. *Computers and Electronics in Agriculture*, 155(1), 473-486. doi: 10.1016/j.compag.2018.10.015
- Muangprathub, J., Boonnam, N., Kajornkasirar, S., Lekbangpong, N., Wanichsombat, A., & Nillaor, P. (2019). IoT and agriculture data analysis for smart farm. *Computers and Electronics in Agriculture*, 156(1), 467-474. doi: 10.1016/j.compag.2018.12.011
- Pereira, W., da Silva, L., Ferrari, F., Cesar, B., & Naves, L. (2020). Environmental monitoring in a poultry farm using an instrument developed with the Internet of Things concept. *Computers and Electronics in Agriculture*, 170(1), 1-7.
- Pérez, L., Lobillo, J., Fernández, R., & Fernández, V. (2019). Suitability and optimization of FAO's small-scale aquaponics systems for joint production

- of lettuce (*Lactuca sativa*) and fish (*Carassius auratus*). *Aquacultural Engineering*, 85(1), 129-137. doi: 10.1016/j.aquaeng.2019.04.001
- Ponce, P., Molina, A., & Mata, O. (2017). Controladores inteligentes para invernadero hidropónico. *Research in Computing Science*, 135(1), 99-114.
- Roca, D., & Florian, P. (2007). Un nuevo sistema de gestión integral automática de cultivos en invernaderos hidropónicos. *Vida Rural*, 1, 40-42.
- Seginer, I., Buwalda, F., & Straten, G. (1998). Nitrate concentration in greenhouse lettuce: a modeling study. *Acta Horticulturae*, 456(1), 187-197.
- Smital, K., Plapallil, S. A., Mohanty, N., Kadam, N. N., & Thakur, M. (2016). Sustainable raft-based hydroponic system for growing spinach and coriander. In *Proceedings of the Sustainable Agriculture Conference* (pp. [specific page range if available]). doi: 10.1007/978-3-319-53556-2_13
- Sweeney, D., Hand, D., Slack, G., & Thornley, J. (1981). *Modelling the growth of winter lettuce*. Academic Press, 217-229.
- Taher, Kahil., Sanjay, Mathur. (2023). 1. Modeling Sustainable Intensification of Agriculture under Resource Constraints. doi: 10.5194/egusphere-egu23-6817
- Talavera, J., Tobón, L., Gómez, J., Culman, M., Aranda, J., Parra, D., Quiroz, L., Hoyos, A., & Garreta, L. (2017). Review of IoT applications in agroindustrial and environmental fields. *Computers and Electronics in Agriculture*, 142(1), 283–297. doi: 10.1016/j.compag.2017.09.015
- Valiente, F., Garcia, R., Domingo, E., Estante, S., Ochaves, E., Villanueva, J., y Balbin, J. (2018). Internet of Things (IoT)-based mobile application for monitoring of automated aquaponics system. *Mapúa University*, 1(1), 1–6.
- Van Henten, E. J. (1994a). Greenhouse climate management: an optimal control approach. (Tesis doctoral). Agricultural, Wageningen Agricultural University. The Netherlands.
- Velásquez, P., Ruíz, H., Chaves, G., & Luna, C. (2014). Productividad de lechuga (*Lactuca sativa*) en condiciones de macrotúnel en suelo *Vitric Haplustands*. *Revista de Ciencias Agrícolas*, 31(2), 93–105. doi: 10.22267/rcia.143102.34
- Velichkova, K., Sirakov, I., Stoyanova, S., y Staykov, Y. (2019). Cultivation of lettuce (*Lactuca sativa* L.) and rainbow trout (*Oncorhynchus mykiss* W.) in the aquaponic recirculation system. *Journal of Central European Agriculture*, 20(3), 967–973. doi: 10.5513/JCEA01/20.3.2223

- Verdouw, C., Sundmaeker, H., Tekinerdogan, B., Conzon, D., & Montanaro, T. (2019). Architecture framework of IoT-based food and farm systems: A multiple case study. *Computers and Electronics in Agriculture*, 165(1), 168–169. doi: 10.1016/j.compag.2019.104939
- Wilson, A., Lennard, B. V., & Leonard, B. (2006). A comparison of three different hydroponic sub-systems (gravel bed, floating, and nutrient film technique) in an aquaponic test system. *Aquaculture International*. doi: 10.1007/S10499-006-9053-2
- Wongkiew, S., Hu, Z., Chandran, K., Woo, J., y Kumar, S. (2017). Nitrogen transformations in aquaponic systems: A review. *Aquacultural Engineering*, 76(1), 9-19. doi: 10.1016/j.aquaeng.2017.01.004
- Zhang, K., Burns, I., y Turner, M. (2008). Derivation of a dynamic model of the kinetics of nitrogen uptake throughout the growth of lettuce: Calibration and validation. *Journal of Plant Nutrition*, 31(1), 1440-1460. doi: 10.1080/01904160802208345

2. Revisión de literatura

2.1 Introducción a la acuaponía

La acuaponía es un sistema de producción sostenible que combina la acuicultura y la hidroponía, permitiendo la coexistencia de peces y plantas en un circuito cerrado de recirculación de agua. Los desechos metabólicos de los peces, ricos en nutrientes, son transformados por bacterias en formas absorbibles por las plantas, mientras que estas contribuyen a la mejora de la calidad del agua para los peces (García et al., 2005; Roosta y Hamidpour, 2011). Este enfoque innovador optimiza recursos como agua y fertilizantes, disminuye la contaminación ambiental y representa una solución viable para la producción de alimentos en espacios limitados.

2.1.1 Ventajas y desventajas de la acuaponía

La acuaponía se destaca como una solución innovadora para la producción sostenible de alimentos, ofreciendo múltiples ventajas sobre los métodos agrícolas y acuícolas convencionales. Entre sus principales beneficios se encuentra la adaptabilidad a pequeña escala, lo que la hace viable tanto en entornos urbanos como rurales, incluso en áreas con acceso limitado a tierra agrícola. Este sistema minimiza significativamente el uso de agua y fertilizantes, promoviendo la sostenibilidad ambiental y contribuyendo al suministro de alimentos nutritivos de manera local. Además, genera impactos económicos y sociales positivos, al impulsar la producción autosuficiente y reducir la dependencia de insumos externos (Adler et al., 2003; Gómez et al., 2015).

No obstante, la acuaponía enfrenta desafíos importantes que limitan su implementación masiva. Su dependencia de equipos eléctricos, como bombas y sistemas de monitoreo, eleva los costos operativos, dificultando su viabilidad en regiones con infraestructura energética limitada o inestable. Este obstáculo resalta la necesidad de desarrollar sistemas más eficientes y energéticamente sostenibles para garantizar su adopción global (Rivas-García et al., 2020).

2.1.2 Componentes de un sistema acuapónico

En la acuicultura, los sistemas de producción presentan diferencias clave en su manejo y eficiencia. El sistema tradicional utiliza estanques abiertos con frecuentes recambios de agua, lo que genera altos volúmenes de desechos y bajo control de calidad del agua. El sistema de recirculación acuapónico (RAS) mejora este enfoque al reciclar el agua mediante biofiltros, reduciendo su consumo y los desechos, pero con un alto costo energético. Por su parte, el sistema biofloc fomenta la proliferación de flóculos microbianos que transforman desechos nitrogenados en alimento para los peces, disminuyendo costos de alimentación y aumentando la sostenibilidad, aunque requiere monitoreo constante. Finalmente, el sistema acuapónico combina acuicultura e hidroponía, aprovechando los desechos de los peces como nutrientes para las plantas y recirculando el agua, lo que resulta en un sistema integrado y eficiente que minimiza el impacto ambiental y optimiza la producción (Figura 1).




Figura 1. Comparación de sistemas de producción acuícola. A) sistema tradicional; B) Sistema RAS; C) Sistema biofloc; D) Sistema Acuapónico. (Sánchez, et al. 2023).

Los sistemas acuapónicos se dividen en acoplados y desacoplados. En los sistemas acoplados, el agua recircula directamente entre peces y plantas en un circuito cerrado, lo que simplifica la operación pero limita el control de las condiciones específicas para cada componente. En contraste, los sistemas desacoplados separan los circuitos de peces y plantas, permitiendo un control independiente de parámetros como nutrientes y calidad del agua, lo que mejora la flexibilidad y eficiencia en la producción a mayor escala (Figura 2).




Figura 2. A) Sistema acuapónico tradicional; y B) Sistema acuapónico acoplado y desacoplado (Aslanidou et al., 2023).

Un sistema acuapónico consta de diversos componentes clave que trabajan de manera integrada para garantizar su funcionamiento adecuado (Colagrosso, 2014). Los componentes principales incluyen:

Tanque de peces: Área destinada al cultivo de peces, donde se recomienda una densidad de 10 a 15 g de peces por litro de agua, tomando en cuenta el tamaño

final de los peces (Borrero et al., 2013). Los desechos metabólicos producidos por los peces son la principal fuente de nutrientes para las plantas.

Biofiltro: Elemento fundamental para la conversión de residuos, compuesto por materiales porosos que albergan bacterias nitrificantes, como *Nitrosomonas* y *Nitrobacter*, responsables de transformar el amoníaco en nitritos y nitratos, que las plantas pueden absorber. Este proceso no solo aprovecha los desechos, sino que también mejora la calidad del agua para los peces (Diver, 2006; Gómez et al., 2015).

Sistema hidropónico: Permite el crecimiento de las plantas utilizando técnicas como camas con sustrato, sistemas de balsa flotante o técnicas de película nutriente (NFT), que optimizan la absorción de nutrientes mediante una solución recirculante (Moreno et al., 2015). Estos sistemas aseguran que las plantas reciban los nutrientes necesarios para su desarrollo y, a su vez, contribuyen a la limpieza del agua.

Bombas de agua y aire: La bomba de agua recircula el líquido desde el tanque de peces hacia el sistema hidropónico, asegurando que los nutrientes estén siempre disponibles para las plantas. Por otro lado, la bomba de aire garantiza un suministro constante de oxígeno, indispensable tanto para los peces como para las bacterias nitrificantes que viven en el biofiltro (Colagrosso, 2014).

La recirculación es un proceso esencial que transporta los nutrientes desde los desechos de los peces hacia las raíces de las plantas, asegurando su disponibilidad y evitando acumulaciones tóxicas de amoníaco. Asimismo, contribuye a mantener una calidad de agua adecuada mediante la oxigenación y eliminación de compuestos tóxicos, como el amoníaco, lo cual es crucial para la salud de los peces y el rendimiento del sistema en su conjunto.

2.2 Cultivo de Tilapia del Nilo (*Oreochromis niloticus*)

La Tilapia del Nilo es una de las especies más utilizadas en acuaponía debido a su capacidad de adaptación a diversas condiciones de agua y su rápido crecimiento. Este pez es resistente a variaciones de temperatura, salinidad y oxígeno, lo que lo hace ideal para sistemas integrados. A nivel mundial, Egipto se posiciona como el mayor productor, mientras que México ocupa el tercer lugar, con Jalisco, Chiapas y Veracruz como los principales estados productores (SIAP, 2014).

2.2.1 Etapas de crecimiento

El ciclo de vida de la Tilapia del Nilo comprende cinco etapas principales, cada una con características específicas que influyen en su manejo dentro del sistema acuapónico:

- a) Desarrollo embrionario: Comprende desde la fecundación hasta la eclosión. Durante esta etapa, los huevos permanecen protegidos y requieren condiciones estables para su desarrollo.
- b) Alevín: Este periodo dura de 3 a 5 días, alcanzando un tamaño inicial de 0.5 a 1 cm. En esta fase, los peces aún dependen de sus reservas vitelinas para alimentarse.
- c) Cría: Los peces comienzan a aceptar alimento balanceado, alcanzando tamaños de 1 a 5 cm. Este es un momento crucial para asegurar una dieta adecuada que favorezca un crecimiento saludable.
- d) Juvenil: A los dos meses, los peces alcanzan tamaños entre 5 y 10 cm. Durante esta etapa, requieren condiciones de agua óptimas y alimentación continua para sostener su crecimiento.
- e) Adulto: La etapa final se caracteriza por tallas entre 10 y 18 cm y un peso de 70 a 100 g. La cosecha generalmente ocurre cuando los peces alcanzan un peso promedio de 300-350 g, lo que suele tomar entre 8 y 9 meses, dependiendo de las condiciones de cultivo (Cantor, 2007; FAO, 2015d).

El aporte de nutrientes al sistema acuapónico proviene de los desechos metabólicos de los peces, principalmente en forma de amoníaco. Por ello, mantener un balance adecuado de población y calidad del agua es crucial para maximizar la eficiencia del sistema.

2.3 Cultivo de lechuga

La lechuga (*Lactuca sativa* L.) es una de las hortalizas de hoja más demandadas a nivel comercial, especialmente en el sector de restaurantes y consumo público, debido a su alta producción y valor económico. Este cultivo destaca por su contenido en vitaminas y minerales, y es posible producir lechuga fresca y de calidad durante todo el año mediante técnicas hidropónicas (Carrillo et al., 2015; Solís, 2017).

El crecimiento exitoso de la lechuga en un sistema acuapónico depende de parámetros fisicoquímicos y ambientales cuidadosamente controlados. En acuaponía, la lechuga puede aprovechar los nutrientes derivados del metabolismo de los peces, particularmente el nitrógeno en forma de nitratos. Las condiciones óptimas incluyen:

Cuadro 1. Condiciones fisicoquímicas y ambientales óptimas para el cultivo de lechuga en un sistema acuapónico (Bautista, et al. 2021).

Parámetro	Rango óptimo
Temperatura del agua	25 -27°C
pH	6.5 – 7.0
Conductividad eléctrica	>1.5 dS/m
Oxígeno disuelto	>6 mg/L
Temperatura ambiente	18 -24 °C
Humedad relativa	50 – 70%
Radiación	200 -400 W/m ²

Estos parámetros no solo optimizan el crecimiento y la calidad de la lechuga, sino que también aseguran la compatibilidad del sistema para mantener saludables a los peces y las bacterias nitrificantes.

2.3.1 Acumulación de nitrato y su relación con el pH

La acumulación de nitratos en la lechuga está influenciada por el pH del agua. Un pH más alto favorece la formación de amoníaco (NH_3), que es tóxico para los peces, mientras que un pH más bajo incrementa la proporción de amonio (NH_4^+), menos perjudicial. Por ello, ajustes regulares del pH son esenciales para evitar acumulaciones peligrosas de nitratos, los cuales pueden representar riesgos para la salud humana al ser convertidos en nitritos (NO_2^-) (Stone y Thomforde, 2004; Wongkiew et al., 2017). Es importante señalar que no existen referencias específicas sobre la producción de lechuga en acuaponía, por lo que se suelen utilizar datos de sistemas hidropónicos como punto de partida para establecer parámetros de cultivo (Bautista et al., 2021).

El cultivo de lechuga en acuaponía se beneficia de la eficiencia en el uso de los recursos. Mientras que las plantas aprovechan los nitratos generados en el biofiltro, la calidad del agua para los peces mejora. Este equilibrio destaca la importancia de monitorear las variables del sistema, como el pH y el oxígeno disuelto, para garantizar el desarrollo saludable de ambos cultivos.

2.4 Diseño de unidades de sistemas acuapónicos

Los sistemas acuapónicos pueden configurarse de diversas maneras, dependiendo de los objetivos de producción, las especies cultivadas y las condiciones disponibles. Su diseño debe garantizar la eficiencia del uso de agua, nutrientes y energía, promoviendo un equilibrio óptimo entre los peces, las plantas y las bacterias nitrificantes. Los sistemas se clasifican en tres configuraciones principales: sistemas con sustrato sólido, sistemas de técnica de película nutritiva (NFT) y sistemas de balsas flotantes.

Sistema con sustrato sólido

Los sistemas de sustrato son una técnica innovadora en la agricultura sin suelo, utilizando diversos materiales que apoyan el crecimiento de las plantas. En estudios, la arena ha demostrado ser un sustrato viable y financieramente factible para invernaderos en pequeñas propiedades rurales, mostrando buena rentabilidad incluso en condiciones de riesgo (Souza et al., 2023). Otros sustratos, como el biocarbón combinado con hidroton, aumentan significativamente el crecimiento y el contenido nutricional en lechuga roja (Rosli et al., 2022).

Sustratos como la lana de roca y mezclas con alta capacidad de retención de agua son ideales para cultivos que requieren mayor humedad, mientras que el coco, probado en fresas, muestra rendimientos variados, sugiriendo la necesidad de más estudios para determinar la combinación óptima (Shin et al., 2022).

En la Figura 3 se muestra una representación esquemática de sistemas de producción acuapónica, destacando el uso del sustrato sólido.




Figura 3. Sistema acuapónico con tanques IBC, mostrando las secciones de tanque de cultivo, sumidero y área de crecimiento de plantas, diseñado para optimizar el flujo de agua y el cultivo de hortalizas en sustrato. (Somerville, et al. 2022).

Sistema NFT (Nutrient Film Technique)

La Técnica de Película Nutriente (NFT) es un sistema hidropónico eficiente y sostenible que permite cultivar plantas sin suelo mediante una fina capa de solución rica en nutrientes que fluye sobre las raíces, proporcionando nutrientes, agua y oxígeno (Figura 4). Dado que el NFT es sensible a cambios ambientales, es esencial un control preciso de temperatura, humedad y concentración de nutrientes. Sistemas automatizados pueden optimizar estos parámetros y mejorar la salud de las plantas (Somerville, et al. 2022).

La eficiencia energética es un factor crítico, especialmente en sistemas NFT con energía solar, donde la optimización de bombas y válvulas reduce el consumo de energía. Además, el uso de NFT en áreas urbanas permite el cultivo de hortalizas en espacios reducidos, contribuyendo a la seguridad alimentaria en entornos urbanos (Somerville, et al. 2022).




Figura 4. Esquema de un sistema acuapónico con tanque de peces, filtros y área de crecimiento vegetal en un sistema de cultivo hidropónico NFT, diseñado para maximizar el uso eficiente del agua y nutrientes. (Somerville, et al. 2022).

Sistema de balsas flotantes

El sistema de producción en balsas flotantes es una alternativa para el cultivo de hortalizas de hoja (Figura 5). Este sistema emplea una cama o contenedor con una placa de unicel, que sostiene las plantas a través de orificios y protege la solución nutritiva. Las raíces permanecen sumergidas en una solución rica en

nutrientes, que se mantiene en movimiento mediante una bomba de aire para oxigenar las raíces (Carrasco et al., 2006; Gordo, 2017).

Este sistema aumenta el rendimiento y la precocidad de la cosecha y optimiza el uso de agua y nutrientes en comparación con otros sistemas hidropónicos (Moreno et al., 2015).

Cuadro 2. Estrategias para el uso del agua en la producción de lechuga bajo sistemas hidropónicos en diferentes estudios (Moreno et al., 2015).

Sistema de cultivo	Gasto (litro * m ²)	Ahorro (%)	Consumo (litro * planta ⁻¹)	Eficiencia (litro * kg ⁻¹)	Rendimiento (kg * m ²)
Sustrato sin recirculación	89.1	-	2.8	12.6	7.03
Sustrato con Recirculación	76.0	14.3	2.3	10.8	7.02
Balsa flotante	65.8	33.6	2.0	9.0	7.31




Figura 5. Sistema acuapónico compuesto por tanques de peces, filtros y zona de crecimiento vegetal, incluyendo balsas flotantes como cama de cultivo para maximizar la producción de plantas y asegurar una buena filtración del agua. (Somerville, et al. 2022).

La selección del sistema adecuado dependerá de los objetivos específicos de producción, las especies cultivadas y los recursos disponibles. Los sistemas de

balsas flotantes son particularmente útiles para hortalizas de hoja, como la lechuga, mientras que los sistemas NFT son ideales para espacios urbanos y cultivos con menor demanda de estructura. Los sistemas de sustrato sólido, en cambio, son más versátiles y se adaptan a una mayor variedad de cultivos.

2.5 Parámetros importantes en sistemas acuapónicos

El monitoreo constante de los parámetros fisicoquímicos y ambientales es fundamental para garantizar la salud y el rendimiento de los organismos involucrados en sistemas acuapónicos. Estos parámetros determinan la calidad del agua, el crecimiento de las plantas y la supervivencia de los peces.

2.5.1 Calidad del agua

La calidad del agua actúa como eje central en los sistemas acuapónicos, ya que es el medio por el cual se transportan los nutrientes a las plantas y se eliminan los desechos metabólicos de los peces. Los factores principales que influyen en la calidad del agua incluyen:

- pH: Un pH adecuado es esencial para la disponibilidad de nutrientes para las plantas y la eficiencia del proceso de nitrificación. En sistemas acuapónicos, el pH ideal se encuentra entre 6.5 y 7.0 para optimizar tanto el crecimiento vegetal como la salud de los peces. Un rango fuera de estos límites puede provocar deficiencias nutricionales en las plantas o toxicidad en los peces (Tyson et al., 2011).
- Temperatura del agua: La temperatura influye directamente en la nitrificación, el metabolismo de los peces y la absorción de nutrientes por parte de las plantas. El rango óptimo varía según los componentes del sistema, pero en general, las bacterias nitrificantes funcionan mejor entre 17°C y 34°C (Somerville et al., 2014).
- Oxígeno disuelto: Los niveles de oxígeno deben mantenerse por encima de 5 mg/L para los peces y superiores a 3 mg/L para las raíces de las plantas. Las bacterias nitrificantes, esenciales para el sistema, requieren

entre 4 y 8 mg/L de oxígeno disuelto para operar eficientemente (Sallenave, 2012).

- Conductividad eléctrica (CE): Este parámetro mide la salinidad del agua y está estrechamente relacionado con la concentración de nutrientes. Una CE fuera de rango puede indicar desequilibrios en el sistema, afectando la salud de los peces y la disponibilidad de nutrientes para las plantas.

Nitrificación

La nitrificación es un proceso clave en sistemas acuapónicos, ya que convierte el amoníaco tóxico excretado por los peces en nitratos asimilables por las plantas. Este proceso ocurre en dos etapas:

- Conversión de amoníaco (NH_3) a nitrito (NO_2): Realizada por bacterias nitrificantes como Nitrosomonas.
- Conversión de nitrito (NO_2) a nitrato (NO_3): Llevada a cabo por bacterias como Nitrobacter. Los nitratos son la forma menos tóxica de nitrógeno y constituyen el principal nutriente para las plantas.

El equilibrio del pH juega un papel crucial en este proceso. A un pH elevado, el amoníaco predomina, mientras que a un pH más bajo, el amonio (NH_4^+) es la forma predominante, siendo esta última menos tóxica para los peces. Sin embargo, un pH fuera del rango óptimo puede reducir la eficiencia de las bacterias nitrificantes (Ebeling et al., 2006; Wongkiew et al., 2017).

TAN (Nitrógeno amoniacal total)

El nitrógeno amoniacal total (TAN) generado se calcula mediante la fórmula:

$$P_{TAN} = F * PC * c$$

donde P_{TAN} es la tasa de producción de TAN (kg/día), F representa la tasa de alimentación (kg/día), PC es el contenido de proteína (fraccional) y c es la cantidad constante de TAN excretado por la entrada de proteína basada en la tasa de alimentación. La constante c se obtiene empíricamente y, para sistemas acuapónicos es $c=0.092$ (Ebeling et al., 2006).

Rangos óptimos de nitrógeno:

- Amoníaco: Menos de 2 mg/L en agua caliente y menos de 1 mg/L en agua fría.
- Nitrito: Entre 0 y 1 mg/L.
- Nitrato: Entre 50 y 100 ppm, manteniendo niveles inferiores a 90 mg/L para evitar toxicidad en los peces (Stone y Thomforde, 2004).

Relación entre el pH, el amoníaco y la acumulación de nitritos

El pH influye directamente en el equilibrio entre amoníaco y amonio, afectando la acumulación de nitratos en el sistema. Un pH elevado favorece la formación de amoníaco, que es altamente tóxico, mientras que un pH más bajo incrementa la proporción de amonio, que es menos perjudicial. La acumulación excesiva de nitratos en las plantas, como la lechuga, puede representar riesgos para la salud humana, incluyendo la formación de compuestos cancerígenos (Lara et al., 2019). Por ello, es fundamental mantener un pH estable y realizar ajustes regulares para evitar desequilibrios en el sistema.

2.5.2 Parámetros Ambientales

Además de los factores fisicoquímicos, las condiciones ambientales como la temperatura, la luz y la humedad relativa desempeñan un papel crucial en la productividad del sistema.

Temperatura del aire

La temperatura afecta directamente el crecimiento de las plantas, ya que temperaturas elevadas aceleran los procesos químicos internos. Al disminuir o elevarse demasiado, la actividad enzimática se deteriora, causando estrés, limitando el crecimiento y eventualmente llevando a la muerte de la planta. Se recomienda mantener la temperatura en niveles óptimos para una maduración rápida y exitosa. Por lo tanto, la temperatura del agua y del aire deben ser monitoreados y controlados (Brechner y Both, 2005; Azcón et al., 2008). Mantener la temperatura en niveles óptimos es fundamental para buen

crecimiento; por ello, el monitoreo y control de la temperatura del agua y del aire es esencial (Brechtner y Both, 2005; Azcón et al., 2008).

Humedad relativa

La humedad relativa está directamente relacionada con la transpiración de las plantas; una humedad elevada reduce la transpiración, limitando el transporte de nutrientes desde las raíces y disminuyendo la refrigeración de las hojas (Brechtner y Both, 2005). Además, una humedad alta puede afectar el desarrollo de la planta e incrementar la propagación de enfermedades, especialmente fúngicas (Azcón et al., 2008).

Intensidad de la luz

La luz se mide utilizando un sensor cuántico, diseñado para registrar los niveles de radiación fotosintéticamente activa (PAR) en unidades de micromoles de fotones por metro cuadrado por segundo ($\mu\text{mol}/\text{m}^2/\text{s}$). La radiación PAR corresponde al espectro de luz comprendido entre 400 y 700 nm, que es utilizado por las plantas en el proceso de fotosíntesis. Este sensor mide los fotones que impactan en la superficie por unidad de tiempo, lo cual proporciona una referencia sobre la cantidad de energía disponible para la fotosíntesis. Aunque las mediciones de PAR están relacionadas con el potencial fotosintético y el crecimiento de las plantas, estos procesos también dependen de otras variables, como la concentración de dióxido de carbono, la temperatura y la eficiencia de las enzimas fotosintéticas (Brechtner y Both, 2005).

2.6 Sistema de monitoreo en acuaponía

Establecer un sistema de control climático en el invernadero es fundamental, ya que condiciones óptimas para las plantas generan un rendimiento significativo en productividad y calidad, lo cual hace rentable el sistema de producción (Molina et al., 2010).

El conocimiento de las condiciones ambientales en un cultivo permite ajustar sus necesidades y prevenir el estrés en la planta. La medición de forma manual en el

campo puede ser laboriosa y demandar mucho tiempo; en cambio, un dispositivo de monitoreo electrónico facilita un registro continuo y autónomo, garantizando precisión en las variables registradas (Fisher, 2007).

La implementación de nuevas tecnologías hoy en día para optimizar los medios técnicos y ejercer un control más efectivo sobre las condiciones de producción son necesarias (Roca y Florian, 2007). Sin embargo, uno de los inconvenientes de estas tecnologías es el elevado costo de los equipos de instrumentación y monitoreo. Para minimizar este problema, se han desarrollado sistemas que reducen costos, tiempos de transporte y mejoran la eficiencia tecnológica (Cisneros et al., 2014). Un sistema de monitoreo es adaptable a distintos entornos, proporcionando datos en tiempo real con una interfaz amigable y fácil de usar (Pablo et al., 2015).

Domingues et al. (2012) desarrollaron un sistema de monitoreo para lechugas hidropónicas que permite el control automatizado del pH y la CE de una solución, ajustando válvulas o solenoides para suministrar ácido, base o nutrientes según sea necesario. Lugo et al. (2013) crearon un sistema de monitoreo ambiental para invernaderos usando software y hardware libres, logrando una instrumentación de bajo costo y confiable, comparable a sensores comerciales. La plataforma Arduino se utilizó para monitorear variables como velocidad del viento, radiación solar, temperatura y humedad relativa. Yang et al. (2017) llevaron a cabo un diagnóstico para el monitoreo y control de calidad del agua en acuicultura, optimizando el rendimiento y detectando fallas en parámetros como pH, conductividad eléctrica (CE), temperatura y nivel del agua. Chang et al. (2018) desarrollaron un sistema para hidroponía que, mediante monitoreo de CE, pH, oxígeno disuelto y temperatura, ajusta el caudal y repone nutrientes según los valores de monitoreo, basándose en reglas difusas para mantener estabilidad en el sistema.

2.6.1 Microcontrolador

Para un buen manejo de los factores en un invernadero, se ha optado por el uso de microcontroladores, los cuales mantienen un control eficaz de las variables en el sistema de producción (Gordo, 2017). Arduino es una herramienta fácil de usar, con software y hardware versátiles; su programación se realiza en un lenguaje de alto nivel basado en Processing y está disponible para descarga gratuita (Ossa, 2017). El Arduino Mega 2560 es un microcontrolador eficaz con entradas y salidas digitales, salidas PWM, entradas analógicas, UARTs, incluye un oscilador de 16 MHz, un conector de alimentación, una conexión USB, un conector ICSP y un pulsador de reinicio (Perea, 2016). La alimentación del Arduino se puede realizar mediante puerto USB o una fuente externa, requiriendo una conversión de AC/DC para un funcionamiento óptimo. Con baterías, se recomienda un voltaje entre 7V y 12V (Gordo, 2017).

2.6.2 Módulos

El reloj de tiempo real (RTC) es un dispositivo electrónico que proporciona mediciones precisas de tiempo y cuenta con un resonador de cristal integrado. Su uso reduce el consumo de energía y permite al microcontrolador delegar las tareas de tiempo; generalmente, incluye una batería externa que mantiene el tiempo en caso de pérdida de alimentación (Gordo, 2017). Las pantallas de cristal líquido (LCD) ofrecen una interfaz simple para el usuario, facilitando la programación y visualización de caracteres o números generados por el microcontrolador, además de tener bajo consumo energético (Gutiérrez, 2016).

2.6.3 Sensores

Sensor de temperatura y humedad relativa

Los dispositivos de medición de temperatura transforman las variaciones físicas en señales eléctricas, permitiendo su posterior procesamiento. Hay tres tipos principales: detectores de temperatura de resistencia (RDT), termopares y termistores, siendo el RDT el más utilizado por su precisión (Perea, 2016). El sensor DHT22 mide humedad y temperatura (Vargas et al., 2013), pasando valores a través de un módulo de procesamiento digital por protocolo I2C

(Figueroa y Castañeda, 2016). Su calibración de fábrica asegura confiabilidad, con rangos de humedad de 0 a 100% y temperatura de -40°C a 80°C, y alimentación de 3.3-6 VDC (Ossa, 2017).

Sensor de temperatura del cultivo

El sensor infrarrojo (IRT) modelo MLX90614 mide la temperatura de la hoja de la planta. Este dispositivo cuenta con un chip detector de termopila sensible a la radiación infrarroja y un chip para el acondicionamiento de señal, todo en una unidad compacta de 8 mm de diámetro y 4 mm de altura. El sensor incorpora un convertidor analógico-digital de 17 bits y un filtro óptico que proporciona inmunidad a condiciones ambientales, siendo sensible a la radiación infrarroja en un rango de 5.5 a 14 metros. La comunicación se lleva a cabo a través del protocolo I2C, con una precisión de ± 0.5 °C y una resolución de 0.02 °C (Fisher y Kebede, 2010).

Sensor de conductividad eléctrica

El sensor ES-2, desarrollado por Decagon Device®, está diseñado para medir la conductividad eléctrica y la temperatura del agua en tubos o tanques. Posee un termistor para registrar la temperatura y una matriz de cuatro electrodos en su superficie para la medición de conductividad. Su rango de medición de temperatura es de -40 °C a 60 °C, con una precisión de ± 1 °C y resolución de 0.1 °C. La conductividad se mide en un rango de 0 a 120 dS/m, con una precisión de ± 0.01 dS/m o ± 10 % y una resolución de 0.001 dS/m. Este sensor tiene un tiempo de respuesta de 300 ms y emplea el protocolo SDI-12 para la adquisición de datos (Decagon Device, 2014).

Sensor de pH

La utilización de electrodos con preamplificadores integrados es fundamental para obtener datos precisos de pH en entornos de laboratorio o aplicaciones industriales. El sensor de pH modelo Phe-1304 de OMEGA® está diseñado para interactuar con equipos que aceptan señales de entrada en milivoltios y poseen una impedancia de entrada de 10 k Ω (OMEGA, 2018). Los preamplificadores

convierten la alta impedancia del electrodo en una señal de baja impedancia, evitando pérdida de señal. El sensor opera en el rango de +414.1 mV (pH 0) a -414.1 mV (pH 14), soporta temperaturas de 0 a 100 °C y requiere una fuente de alimentación de $\pm 1.5\text{Vdc}$ a $\pm 9\text{Vdc}$, 0.5 mA (OMEGA, 2018). Se usa en sistemas automatizados de invernaderos para controlar la fertirrigación en cultivos hidropónicos (Steidle et al., 2014).

Sensor de radiación PAR

La fotosíntesis se impulsa principalmente por fotones de luz en el rango de 400 a 700 nm, se conoce como radiación fotosintéticamente activa o luz PAR. La intensidad de esta radiación, expresada como densidad de flujo de fotones fotosintéticos, se mide en $\mu\text{mol m}^{-2} \text{s}^{-1}$. Para capturar esta variable, se empleó el sensor de luz cuántico Full Spectrum de Apogee Instruments, el cual mide PAR en una gama de 400 a 700 nm con salidas analógicas en rangos como 0-40 mV, 0-2.5 V, 0-5.0 V y 4-20 mA, permitiendo transformar valores de voltaje a $\mu\text{M/ m}^{-2} \text{s}^{-1}$.

2.7 Sistemas IoT

Internet of Things (IoT) busca resolver problemas de conectividad entre sistemas. Su objetivo es permitir que la maquinaria industrial se comuniquen entre sí y facilite la toma de decisiones basada en datos sin intervención humana. La mejora de la capacidad de la red con 4G y 5G aumenta la viabilidad de IoT y fomenta nuevos hardware, protocolos y marcos de comunicación. Actualmente, la comunicación entre dispositivos es menos limitada, aumentando la flexibilidad, interoperabilidad e integración de sistemas en escenarios industriales complejos como la acuaponía. En agricultura, IoT se implementa para mejorar GPS, predicciones meteorológicas, inventarios e información productor-consumidor (Kumar et al. 2016).

2.7.1 Plataformas software

En una arquitectura IoT, existen múltiples opciones para almacenar, analizar y visualizar datos de sensores, incluidas plataformas de software o servidores web especializados en IoT. La selección del servidor adecuado depende de las necesidades y experiencia del desarrollador, ya que algunas plataformas están orientadas a la educación y otras al uso profesional. Algunas ofrecen un ecosistema integral de software y hardware, mientras que otras son privadas y requieren un pago por su uso. En plataformas de código abierto, el desarrollador puede seleccionar los dispositivos para su red IoT. Ejemplos de plataformas libres incluyen ThingSpeak, FIWARE, openMTC, SiteWhere y Webinos; en soluciones privadas destacan AWS IoT, IBM's Watson Platform y Samsung's Smart Things (Kumar et al. 2016).

2.7.2 Interfaz de programación de aplicación (API)

Una API es un conjunto de comandos y funciones previamente definidos que facilitan la creación de programas o aplicaciones dentro de sistemas o ecosistemas específicos. Su propósito central es permitir la visualización, manipulación y análisis de datos, lo cual simplifica considerablemente el trabajo de los desarrolladores al no requerir que comiencen su desarrollo desde cero. Las APIs permiten conectarse a un conjunto de dispositivos y establecer comunicación inteligente entre sensores y aplicaciones, promoviendo la integración entre ellos. Además, una ventaja significativa de las APIs es su capacidad para conectar varias aplicaciones desarrolladas por diferentes proveedores, añadiendo valor o funciones adicionales. Un ejemplo de esto es la incorporación de servicios de geolocalización mediante la API de Google, pagos en línea a través de APIs bancarias, y la integración de redes sociales, entre otras opciones (Bose et al., 2018).

2.7.3 Tecnologías inalámbricas

Las tecnologías inalámbricas suelen estar ligadas a la supervisión remota o a interfaces de control, y algunos estudios se enfocaron en su aplicación en acuaponía para mejorar la conectividad. Wang et al. (2015) diseñó una arquitectura para monitorear y controlar un sistema de acuaponía con información de Arduino y sensores, almacenando datos en nodos WRT y transmitiéndolos a un servidor OpenWrt mediante un módulo Wi-Fi. Kumar et al. (2016) usó el protocolo 6LOWPAN y una red de sensores inalámbricos. Murad et al. (2017) empleó tecnología GSM para notificar fuera de rango en pH y temperatura, y Mamatha y Namratha (2017) usaron ThingSpeak para almacenar información. Sreelekshmi y Madhusoodanan (2018) desarrollaron un sistema en ThingSpeak con Arduino Uno y ESP8266-01, y Jacob (2017) usó una Raspberry Pi con Wi-Fi para controlar parámetros en la nube mediante plataformas como Pubnub, Cloudinary y Dweet, y un panel IoT con Freeboard. Las tecnologías inalámbricas facilitan el monitoreo y control de parámetros.

2.8 Modelación matemática

La modelación matemática es una herramienta poderosa que permite comprender y predecir el comportamiento de sistemas acuapónicos, ayudando a optimizar su funcionamiento y maximizar su eficiencia. Estos modelos se basan en ecuaciones que representan interacciones clave entre las variables del sistema, como el crecimiento de los cultivos, el manejo de nutrientes y la calidad del agua. Para producir hortalizas en invernadero y obtener mayores rendimientos con calidad deseable en el mercado, es necesario controlar las variables ambientales, siendo una alternativa emplear modelos matemáticos que proyecten el crecimiento del cultivo a lo largo del tiempo (López et al., 2004).

Existen tres tipos de modelos: empíricos, que describen datos sin explicar mecanismos subyacentes; teleonómicos, que relacionan variables en función de objetivos; y mecanicistas, que utilizan ecuaciones diferenciales no lineales para describir las variables de salida del sistema, requiriendo análisis, calibración y validación (López et al., 2005; Zhang et al., 2008). El proceso de calibración

ajusta los parámetros para que las predicciones se alineen con los datos observados, centrándose en aquellos que influyen más en el modelo. La evaluación, por otro lado, establece la utilidad del modelo en una aplicación específica (Juárez, 2010).

2.9 Modelos del crecimiento de lechuga

Se han propuesto varios modelos para simular el crecimiento de la lechuga, y numerosos estudios han centrado su atención en este cultivo debido a su sencilla producción (López et al., 2005).

Modelo de Sweeney

Sweeney et al. (1981) desarrollaron un modelo para lechuga, considerando la materia seca estructural y no estructural como variables de estado, omitiendo la materia seca de las raíces. Las variables de entrada incluyen radiación total y temperatura del aire ambiente, mientras que las variables de salida son la materia seca y el área foliar. Este modelo requiere resolver ecuaciones algebraicas no lineales y emplea funciones exponenciales para simular la acumulación de materia seca estructural y el proceso de fotosíntesis. Los parámetros fueron estimados y el modelo validado con datos experimentales obtenidos en Inglaterra, logrando una predicción precisa de la biomasa de la lechuga (López et al., 2005; Juárez, 2010).

Modelo de Van Henten

Van Henten (1994) propuso otro modelo para lechuga, con variables de estado como el peso seco estructural y no estructural, donde la suma de ambos da el peso seco total. El peso seco no estructural se compone de carbohidratos y almidón, mientras que el peso seco estructural abarca todos los componentes de la planta, excluyendo aquellos pertenecientes al peso no estructural. Las variables de entrada son radiación PAR, CO₂ y temperatura del aire dentro del invernadero. El modelo requiere la estimación de 17 parámetros, siendo la eficiencia en el uso de la luz y la conversión de materia seca no estructural los

más influyentes. La evaluación se llevó a cabo en invernaderos en los Países Bajos durante dos ciclos anuales el cual fue realizada por los autores originales del modelo (López et al., 2005; Juárez, 2010).

Modelo NICOLET

El modelo NICOLET (Nitrate Control in Lettuce) utiliza dos variables de estado: la cantidad de carbono en vacuolas y en la estructura celular. Calcula la concentración de nitratos en vacuolas mediante ecuaciones algebraicas que relacionan carbono y nitrógeno. Las salidas son el peso seco, peso fresco y nitratos en la planta. Este modelo permite desarrollar estrategias para el control preciso de nitratos en lechuga (López et al., 2004; López et al., 2005).

Modelo de Zhang

El modelo Zhang (2008) es un modelo mecanicista dinámico para predecir la acumulación de biomasa en la lechuga, así como la cantidad de nitrógeno que se acumula durante el desarrollo del cultivo. Así mismo se han realizado trabajos de modelación en la cinética de la cantidad de nutrientes que hay en un cultivo de lechuga, especialmente nitrógeno, mismo que se han calibrado y validado (Juárez, 2010).

2.10 Referencias

- Aslanidou, M., Mente, E., Katsoulas, N., & Levizou, E. (2023). Basil functional and growth responses when cultivated via different aquaponic and hydroponic systems. *PeerJ*. <https://doi.org/10.7717/peerj.15664>
- Adler P., Summerfelt S., Glenn D., Takeda F. (2003). Mechanistic approach to phytoremediation of water. *Ecol. Eng.* 20: 251-264.
- Anthonisen, A.C., Loehr, R.C., Prakasam, T.B., Srinath, E.G., (1976). Inhibition of nitrification by ammonia and nitrous acid. *J. Water Pollut. Control Fed.* 48, 835-852.
- Azcón, J., Fleck, I., Aranda, X., & Gómez, N. (2008). Fotosíntesis, factores ambientales y cambio climático. En *Fundamentos de fisiología vegetal* (2da ed., pp. 247-263). McGraw Hill.

- Bautista Olivas, A. L., Fernández, D. R., Álvarez Chávez, C. R., Sánchez Mexia, Á. C., Mendoza-Cariño, M., & García Cabello, K. (2021). Productividad de la lechuga (*Lactuca sativa* L.) en acuaponía e hidroponía. *European Scientific Journal*, 17(21), 283. doi: 10.19044/esj.2021.v17n21p2837
- Bhatnagar, A., Devi, P., (2013). Water quality guidelines for the management of pond fish culture. *Int. J. Environ. Sci.* 3, 1980-2009. doi: 10.6088/ijes.2013030600019.
- Borrero C., Martínez M., Baigorri A., Rico L. (2013). Acuapónicos: Una alternativa productiva en el hogar. *FIATMAR Revista Marina* 3(1): 4-5.
- Brechner, M., y Both, A. J. (2005). *Hydroponic Lettuce Handbook*. Cornell University CEA Program., 48. doi: 10.1158/1078-0432.CCR-13-0358
- Cantor, A. (2007). *Manual de producción de tilapia*. Secretaría de Desarrollo Rural del Estado de Puebla. Puebla, México.
- Carrasco, G., Tapia, J., y Urrestarazu, M. (2006). Contenido de nitratos en lechugas cultivadas en sistemas hidropónicos. *IDESIA*. 24 (1), 25-30.
- Carrillo, G. M., Herrera, A. L., Evelia, L., Bernal, P., Flores, M. L., Jesús, J., Mejía, A., & Llamas, L. (2015). Evaluación técnica y financiera del cultivo de lechuga en invernadero, como alternativa para invierno. *Terra Latinoamericana*, 33(7), 251-260.
- Carta Nacional Acuícola. (2012). *Diario Oficial de la Federación, actualización de la Carta Nacional Acuícola*.
- Colagrosso, A. (2014). *Instalación y manejo de sistemas de cultivo acuapónico a pequeña escala*.
- Comisión Europea (2011). Reglamento (UE) N° 1258/2011 DE LA COMISIÓN EUROPEA. *Diario Oficial de la Unión Europea*. 8 (12), 1-5. doi: 10.2903/j.efsa.2010.1935.
- Chang, C., Hong, G., y Fu, W. (2018). Diseño y ejecución de un sistema de riego a soluciones nutrientes basado en conocimientos para aplicaciones hidropónicas. *American Society of Agricultural and Biological Engineers*. 61 (2), 369-379. doi: 10.13031/trans.11564
- Cisneros, H., Vargas, E., y Ortega, A. (2014). *Implementación de un sistema de instrumentación eficiente y rentable para invernaderos*. En A. Lara (Ed.), *V Congreso Internacional de la Ciencia de Sistemas*. Guanajuato, México. doi: 10.13140/2.1.2332.6083

- Coronado, A. (2016). *Uso de silicio en lechuga (Lactuca sativa) en sistema NFT y raíz flotante*. Tesis de Licenciatura en Agronomía en Horticultura Protegida, Universidad Autónoma Chapingo. México.
- Decagon Device (2014), ES-2. *DATA SHEET*. Decagon Device Inc., EE.UU. 2014.
- Diver, S. (2006). Aquaponics-integration of hydroponics with aquaculture, ATTRA - National Sustainable Agriculture Information Service (*National Center for Appropriate Technology*).
- Domingues, D. S., Takahashi, H. W., Camara, C. A. P., y Nixdorf, S. L. (2012). Automated system developed to control pH and concentration of nutrient solution evaluated in hydroponic lettuce production. *Computers and Electronics in Agriculture*. 84 (12), 53-61. doi: 10.1016/j.compag.2012.02.006
- Ebeling, J.M., Timmons, M.B., Bisogni, J.J., (2006). Engineering analysis of the stoichiometry of photoautotrophic, autotrophic, and heterotrophic removal of ammonia-nitrogen in aquaculture systems. *Aquaculture* 257, 346-358. doi: 10.1016/j.aquaculture.2006.03.019.
- FAO. (2015d). Visión general del sector acuícola nacional - México.
- Fisher, D. K. (2007). Automated collection of soil-moisture data with a low-cost microcontroller circuit. *American Society of Agricultural and Biological Engineers*. 23 (4), 493-500.
- Fisher, D. K., y Kebede, H. (2010). Application note A low-cost microcontroller-based system to monitor crop temperature and water status. *Computers and Electronics in Agriculture*. 74 (1), 168-173. doi: 10.1016/j.compag.2010.07.006
- García M., León C., Hernández F., Chávez R. (2005). Evaluación de un sistema experimental de acuaponía. *Avances en Investigación Agropecuaria* 9(1): 1-5.
- Gili, A. A., Baudino, E. M., Siliquini, O. A., Morazzo, G. C., y Sánchez, T. M. (2012). Contenido de nitratos y proteína en lechugas cressa y amaranto hortícola producidos con enmienda y urea. *Revista Chapingo Serie Horticultura*. 18 (2), 217-226. doi: 10.5154/r.rchsh.2011.02.027
- Gómez F., Ortega N., Trejo L., Sánchez R., Salazar E., Salazar J. (2015). La acuaponía: Alternativa sustentable y potencial para producción de alimentos

- en México. *Agroproductividad* 8(8): 60-65.
- Gordo, A. D. (2017). *Desarrollo e implementación de un invernadero automatizado con cultivo hidropónico y aplicación móvil para el seguimiento de datos*. (Tesis de pregrado). Departamento de Control Automático, Universidad de Sevilla. España.
- Gutiérrez, J. (2011). *Producción de lechuga con y sin recirculación de solución nutritiva*. (Tesis de maestría). Instituto de Horticultura, Universidad Autónoma Chapingo. México.
- Gutiérrez, J. (2016). *Equipo para medir la conductividad eléctrica del suelo en tiempo real*. (Tesis de maestría). Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo. México.
- Hu, Z., Lee, J.W., Chandran, K., Kim, S., Brotto, A.C., Khanal, S.K., (2015). Effect of plant species on nitrogen recovery in aquaponics. *Bioresour. Technol.* 188, 92-98. doi: 10.1016/j.biortech.2015.01.013.
- Juárez, A. (2010). *Validación del modelo matemático de crecimiento NICOLET B3 para el cultivo de lechuga bajo condiciones de invernadero*. (Tesis de maestría). Ciencias en Horticultura, Universidad Autónoma Antonio Narro. México.
- Kumar, N.H., Baskaran, S., Hariraj, S., Krishnan, V., (2016). An autonomous aquaponics system using LoWPAN based WSN. In: 2016 IEEE 4th International Conference on Future Internet of Things and Cloud Workshops (FiCloudW). IEEE, 125-132. doi: 10.1109/W-FiCloud.2016.37.
- Lara, A., Rojas, A., Romero, M., Ramírez, H., Crespo, E., Alcalá, J., y Loredó, C. (2019). Growth and NO₃⁻ accumulation in hydroponic lettuce with nitrate/ammonium ratios in two cultivation seasons. *Revista Fitotecnia Mexicana*. 42 (3), 21-29.
- López, I., Ramírez, A., y Rojano, A. (2004). Sensitivity analysis of a dynamic growth model for greenhouse. *Agrociencia*. 38 (6), 613-624.
- López, I., Ramírez, A., y Rojano, A. (2005). Modelos matemáticos de hortalizas en invernadero: trascendiendo la contemplación de la dinámica de cultivos. *Revista Chapingo Serie Horticultura*. 11 (2), 257-267. doi: 10.5154/r.rchsh.2003.08.050
- López, I. L. C., Ruiz, A. G., Ramírez, A. A., y Vázquez, M. A. P. (2013). Análisis de incertidumbre de un modelo para lechugas (*Lactuca sativa* L.) cultivadas en invernadero. *Revista Chapingo Serie Horticultura*. 19 (1), 33-47. doi:

10.5154/r.rchsh.2011.09.049

- Mamatha, M.N., Namratha, S.N., (2017). Design & implementation of indoor farming using automated aquaponics system. In: 2017 IEEE International Conference on Smart Technologies and Management for Computing, Communication, Controls, Energy and Materials (ICSTM). IEEE, 396-401. doi: 10.1109/ICSTM.2017.8089192.
- Maroto, J. (2002). *Horticultura herbácea especial*. pp. 704. Valencia, España. Mundi Prensa. Quinta edición.
- Molina, J., Martín, B., Vázquez, S., y Sánchez, F. (2010). *Desarrollo de un sistema de adquisición de datos climáticos para un invernadero*. Promise (Presidencia). 12th International Conference on Project Engineering. Ciudad Real, España.
- Moreno, E., Sánchez, F., Gutiérrez, J., González, L., y Pineda, J. (2015). Greenhouse lettuce production with and without nutrient solution recycling. *Revista Chapingo Serie Horticultura*. 21 (1), 43-55. doi: 10.5154/r.rchsh.2013.12.047
- Murad, S.A.Z., Harun, A., Mohyar, S.N., Sapawi, R., Ten, S.Y., (2017). Design of aquaponics water monitoring system using Arduino microcontroller. In: AIP Conference Proceedings. doi: 10.1063/1.5002442, 020248.020248.
- Nagayo, A.M., Mendoza, C., Vega, E., Izki, R.K.S. Al, Jamisola, R.S., (2017). An automated solar-powered aquaponics system towards agricultural sustainability in the Sultanate of Oman. In: 2017 IEEE International doi: 10.1109/ICSGSC.2017.8038547.
- Odema, M., Adly, I., Wahba, A., Ragai, H., (2018). Smart aquaponics system for industrial internet of things (IoT). In: Hassanien, A.E., Tolba, M.F., Shaalan, K., Azar, A.T. (Eds.), *Proceedings of the International Conference on Advanced Intelligent Systems and Informatics, Advances in Intelligent Systems and Computing*. Springer International Publishing, Cham, 844-854. doi: 10.1007/978-3-319-64861-3_79.
- Omega (2018), PHE-1304. DATA SHEET. Omega Inc., EE.UU. 2018.
- Ossa, S. I. (2017). Monitoreo y control de variables ambientales mediante una red inalámbrica para agricultura de precisión en invernaderos. *Vector*. 12 (1), 51-60. doi: 10.17151/vect.2017.12.6
- Pablo, J., Vargas, B., y Navia, G. (2015). Desarrollo de un sistema de control para la captura y medición experimental de la eficiencia y curva característica

- i-v en tiempo real de un sistema fotovoltaico utilizando labview y arduino. INVESTIGACIÓN & DESARROLLO. 1 (15), 49-64.
- Perea, J. (2016). *Diseño de un sistema de monitoreo, registro y control de temperatura y humedad para un cultivo de invernadero*. (Tesis de pregrado). Ingeniería Eléctrica, Universidad Tecnológica de Pereira. Colombia.
- Roca, D., y Florian, P. (2007). *Un nuevo sistema de gestión integral automática de cultivos en invernaderos hidropónicos*. In Vida Rural. Vol. 1, 40-42.
- Rodríguez H., Rubio S., García M., Montoya M., Magallón F. (2015). Análisis técnico de la producción de tilapia (*Oreochromis niloticus*) y lechuga (*Lactuca sativa*) en dos sistemas de acuaponía. *Agroproductividad*. 8(3):15-19.
- Roosta H., Hamidpour M. (2011). Effects of foliar application of some macro- and micro-nutrients on tomato plants in aquaponic and hydroponic systems. *Scietia Horticulturae* 129: 396-402.
- Sallenave, R., (2012). Understanding Water Quality Parameters to Better Manage Your Pond. College of Agricultural, *Consumer and Environmental Sciences*. New Mexico State University Guide W-10, 4.
- Somerville, C., Cohen, M., Pantanella, E., Stankus, A. & Lovatelli, A. 2022. Producción de alimentos en acuaponía a pequeña escala – Cultivo integral de peces y plantas. FAO Documento Técnico de Pesca y Acuicultura No. 589. FAO, Roma. doi: 10.4060/i4021es.
- Sánchez Estrada, M. de la L., Caltzontzin Rabell, V., Flores Aguilar, P. S., & Soto Zarazúa, G. M. (2023). Tecnologías para optimizar el agua en la acuicultura. *Revista Nthe*, (41), 19-26.
- SIAP. (2014). *Con los pies en la tierra*. (1ª ed.).
- Sreelekshmi, B., Madhusoodanan, K.N., (2018). Automated aquaponics system. In: Emerging Trends in Engineering, Science and Technology for Society, Energy and Environment - Proceedings of the International Conference in Emerging Trends in Engineering, Science and Technology, ICETEST 2018, pp. 695e700.
- Solís, F. (2017). *Evaluación del rendimiento en el cultivo de lechuga (Lactuca Sativa), en sistemas hidropónicos y aeropónicos automatizados*. (Tesis de pregrado). Ingeniería Agronómica, Universidad Técnica de Machala. Ecuador.
- Somerville, C., Cohen, M., Pantanella, E., Stankus, A., Lovatelli, A., (2014). Small-

scale aquaponic food production. Integrated Fish and Plant Farming. FAO *Fisheries and Aquaculture Technical Paper* No.589.

- Steidle, A., Zolnier, S., y Carvalho, D. (2014). Development and evaluation of an automated system for fertigation control in soilless tomato production. *Computers and Electronics in Agriculture*. 103 (1), 17-25. doi: 10.1016/j.compag.2014.02.001
- Stone, N.M., Thomforde, H.K., (2004). Understanding Your Fish Pond Water Analysis Report, Cooperative Extension Program. University of Arkansas at Pine Bluff, Pine Bluff.
- Sweeney, D., Hand, D., Slack, G., y Thornley, J. (1981). Modelling the growth of winter lettuce. *Academic Press.*, 217-229.
- Tomás, Rivas-García., Ramsés, Ramón, González-Estrada., Roberto, G., Chiquito-Contreras., Juan, José, Reyes-Pérez., Uriel, González-Salas., Luis, Guillermo, Hernández-Montiel., Bernardo, Murillo-Amador. (2020). 9. Biocontrol of Phytopathogens under Aquaponics Systems. *Water*, doi: 10.3390/W12072061
- Tyson, R.V., Simonne, E.H., Treadwell, D.D., White, J.M., Simonne, A., (2008). Reconciling pH for ammonia biofiltration and cucumber yield in a recirculating aquaponic system with perlite biofilters. *Hortscience* 43, 719e724. <https://doi.org/10.21273/HORTSCI.43.3.719>.
- Tyson, R.V., Treadwell, D.D., Simonne, E.H., (2011). Opportunities and challenges to sustainability in aquaponic systems. *HortTechnology* 21, 6e13. doi: 10.21273/HORTTECH.21.1.6.
- Van Henten E.J., Van Henten G. (1994). Sensitivity analysis of a dynamic growth model of lettuce. *Journal Agricultural Engineering Res.* 59 (1), 19-33.
- Wada, T., (2019). Theory and technology to control the nutrient solution of hydroponics. In: *Plant Factory Using Artificial Light*. Elsevier, pp. 5-14. doi: 10.1016/B978-0-12-813973-8.00001-4.
- Wang, D., Zhao, J., Huang, L., & Xu, D. (2015). Diseño de un control y monitoreo inteligente sistema para acuaponia basado en OpenWrt. En *Actas de la 5ª Conferencia Internacional sobre Ingeniería de la Información para Mecánica y Materiales* (937-942). Atlantis Press. doi:10.2991/icimm-15.2015.171.
- Wei, Y., Li, W., An, D., Li, D., Jiao, Y., Wei, Q., (2019). Equipment and intelligent control system in aquaponics: a review. *IEEE Access* 7, 169306e169326. <https://doi.org/10.1109/ACCESS.2019.2953491>.

- Wongkiew, S., Hu, Z., Chandran, K., Lee, J.W., Khanal, S.K., (2017). Nitrogen transformations in aquaponic systems: a review. *Aquacult. Eng.* 76, 9e19. doi: 10.1016/j.aquaeng.2017.01.004.
- Yang, H., Hassan, S. G., Wang, L., y Li, D. (2017). Fault diagnosis method for water quality monitoring and control equipment in aquaculture based on multiple SVM combined with D-S evidence theory. *Computers and Electronics in Agriculture.* 141 (1), 96-108. doi: 10.1016/j.compag.2017.05.016
- Zhang, K., Burns, I., y Turner, M. (2008). Derivation of a Dynamic Model of the Kinetics of Nitrogen Uptake Throughout the Growth of Lettuce: Calibration and Validation Derivation of a Dynamic Model of the Kinetics of Nitrogen Uptake Throughout the Growth of Lettuce: Calibration and Validation A. *Journal of Plant Nutrition.* 31 (1), 1440-1460. doi: 10.1080/01904160802208345

3. Diseño, implementación y evaluación de un sistema de monitoreo basado en IoT y predicción de oxígeno disuelto para un sistema acuapónico

3.1 Resumen

Este estudio presenta el diseño y evaluación de un sistema de monitoreo basado en Internet de las Cosas (IoT), el cual mide, almacena y transmite las variables ambientales y fisicoquímicas del agua; radiación fotosintéticamente activa (PAR), temperatura, pH, conductividad eléctrica, y oxígeno disuelto, en un sistema integrado (acuaponía) de tilapia (*Oreochromis niloticus*) y lechuga (*Lactuca sativa* L.); además de la estimación de oxígeno disuelto (OD) en el tanque de agua a través de una red neuronal. El sistema emplea sensores conectados a un microcontrolador Arduino Mega y una placa TTGO LoRa, que permite la transmisión de datos en tiempo real a Google Sheets, facilitando su visualización y análisis continuo. Para estimar los niveles OD, se implementó una red neuronal artificial (RNA) multicapa en MATLAB, utilizando el algoritmo de Levenberg-Marquardt para el entrenamiento de la red. La RNA fue entrenada y evaluada con datos recopilados durante un ciclo de producción de lechuga. Las variables de entrada: temperatura interior y exterior del invernadero, radiación fotosintéticamente activa (PAR), temperatura, pH y conductividad eléctrica del agua del estanque, fueron seleccionados por su correlación con el oxígeno disuelto. La evaluación de la RNA se llevó a cabo mediante los índices estadísticos de desempeño, obteniendo en la fase de evaluación un coeficiente de determinación (R^2) de 0.93, un error cuadrático medio (RMSE) de 0.19 mg L⁻¹ y un error absoluto medio (MAE) de 0.15 mg L⁻¹, valores que indican que las estimaciones de OD por la RNA son confiables. Este desarrollo contribuye al avance de prácticas de monitoreo en acuaponía, ofreciendo un enfoque innovador y sostenible para sistemas de producción integrados.

Palabras clave: Arduino, Google Sheets, *Lactuca sativa* L., *Oreochromis niloticus*, protocolo LORA, red neuronal prealimentada.

3.2 Introducción

La acuaponía combina la cría de peces y el cultivo de plantas en un sistema integrado, donde los desechos de los peces se convierten en nutrientes para las plantas mediante bacterias nitrificantes, mejorando así la calidad del agua y reduciendo la necesidad de fertilizantes químicos. Este sistema permite una producción eficiente en espacios reducidos, minimizando el uso de pesticidas o herbicidas y con menor dependencia de las condiciones climáticas (Love et al., 2014; Huan et al., 2020). Además, su capacidad para operar en espacios reducidos y entornos controlados lo convierte en una alternativa viable para enfrentar los desafíos asociados a la agricultura convencional, como la escasez de agua y la contaminación del suelo (Somerville et al., 2014; Wongkiew et al., 2017).

Sin embargo, la implementación eficiente de sistemas acuapónicos presenta varios retos operativos. El éxito de estos sistemas depende del monitoreo constante de variables fisicoquímicas críticas, como la temperatura del agua, el oxígeno disuelto (OD), el pH y la conductividad eléctrica, que influyen directamente en el crecimiento de las plantas, la salud de los peces y el equilibrio microbiano del sistema (Shin et al., 2024). Por ejemplo, niveles bajos de OD pueden limitar la nitrificación y aumentar el estrés en los peces, mientras que desequilibrios en el pH afectan la disponibilidad de nutrientes para las plantas (Valiente et al., 2018). A pesar de su importancia, el monitoreo se enfrenta a limitantes como el elevado costo de los sensores, su susceptibilidad a condiciones ambientales adversas y la falta de soluciones tecnológicas accesibles en algunos lugares (Verdouw et al., 2019).

El monitoreo de variables ambientales y fisicoquímicas en sistemas acuapónicos mejora la calidad del agua y la productividad de los cultivos (Deshpande et al., 2024). Valiente et al. (2018) encontraron que el seguimiento continuo de la temperatura, la conductividad eléctrica y el oxígeno disuelto optimiza el crecimiento de las plantas y reduce el riesgo de enfermedades en los peces,

prolongando así el ciclo de vida del sistema. Sin embargo, aún existen limitaciones en la precisión y robustez de los datos transmitidos. Algunos sistemas carecen de mecanismos de almacenamiento, lo cual puede afectar su capacidad de respuesta ante cambios imprevistos (Valiente et al., 2018). Además, la estabilidad de la conectividad en áreas remotas sigue siendo un desafío (Verdouw et al., 2019).

El Internet de las Cosas (IoT) ofrece una solución innovadora para mejorar el monitoreo de sistemas acuapónicos. Al permitir la recopilación, transmisión y almacenamiento en tiempo real de datos generados por sensores, el IoT no solo reduce la dependencia de la supervisión manual, sino que también optimiza la toma de decisiones mediante el análisis de las condiciones del sistema (Verdouw et al., 2019; Valiente et al., 2018).

Las RNA son capaces de modelar relaciones no lineales entre variables ambientales, aprendiendo patrones a partir de datos históricos mediante algoritmos de aprendizaje supervisado. Por ejemplo, se ha demostrado que las RNA pueden predecir niveles de OD en tiempo real con alta precisión, incluso bajo condiciones cambiantes, lo que facilita un monitoreo continuo y adaptativo en sistemas acuapónicos. Este enfoque, de predecir variables, resulta especialmente útil en entornos donde el acceso a sensores especializados es limitado (Xinhui et al., 2023).

Adicionalmente, las redes neuronales artificiales (RNA) proporcionan un enfoque complementario al facilitar la estimación de variables complejas como el oxígeno disuelto (OD), utilizando otras mediciones correlacionadas, como la temperatura del agua, temperatura ambiente, el pH y la conductividad eléctrica. Estas herramientas permiten generar predicciones confiables y precisas, reduciendo la dependencia de sensores especializados y los costos asociados (Mohamed, 2019; Jaroslaw et al., 2022).

El uso de RNA en sistemas acuapónicos es una alternativa prometedora para reducir costos y superar las limitaciones de los sensores, que suelen ser costosos y sensibles a las condiciones ambientales (Verdouw et al., 2019). Estas redes permiten estimar variables difíciles de medir en tiempo real, proporcionando datos confiables sin depender exclusivamente de equipos de medición especializados. Así, las RNA mejoran la precisión y continuidad del monitoreo, optimizando el control del sistema acuapónico y promoviendo una gestión más eficiente y sostenible (Cardenas et al., 2022).

La lechuga (*Lactuca sativa* L.), una de las hortalizas más cultivadas en acuaponía por su alta demanda y ciclo de crecimiento corto, ha mostrado rendimientos altos en sistemas acuapónicos de balsas flotantes (Abbey et al., 2019). El monitoreo de las condiciones ambientales es crucial para optimizar el rendimiento de estos cultivos, y el uso de sistemas electrónicos automatizados puede permitir un control continuo, preciso y con menor intervención manual (Fisher, 2007).

Por lo anterior, los objetivos de este estudio fueron 1) diseñar, implementar y evaluar un sistema de monitoreo basado en IoT para medir las principales variables ambientales y fisicoquímicas en un sistema acuapónico; 2) predecir el contenido de oxígeno disuelto (OD) en el estanque de peces mediante una red neuronal prealimentada con las mediciones del sistema de monitoreo.

3.3 Materiales y métodos

Descripción del experimento

El estudio se realizó en un invernadero tipo capilla con cubierta de polietileno y ventilación natural, ubicado en Texcoco, México (19° 29' N, 98° 53' O, y altitud de 2240 m). El invernadero tiene dimensiones 12.0 x 5.0 x 3.5 m de largo, ancho, y alto, respectivamente.

Se instaló un sistema acuapónico tipo RAS (Sistema de Recirculación Acuapónica) (Figura 6) que incluye un estanque para peces de 1000 L, un

sedimentador modificado a partir de un contenedor de 200 L con un fondo cónico para la recolección de sólidos, un mineralizador adaptado de un tanque de polietileno endurecido de 120 L con una malla de 70 x 22 hilos para la filtración de sólidos suspendidos, un biofiltro con 160 taparroscas que proporcionan 52.8 m² de superficie para la colonización de bacterias nitrificantes, y una balsa flotante de madera (2.40 x 1.10 x 0.30 m) forrada con polietileno negro calibre 600.

Durante el período de febrero a agosto de 2023, se realizaron cuatro ciclos de cultivo de lechuga en el sistema acuapónico, con renovaciones periódicas de las plantas y ajustes en la biomasa de tilapias según su crecimiento. Los trasplantes de lechuga se efectuaron en las siguientes fechas: 23 de febrero, 24 de abril, 27 de junio y 31 de julio, mientras que la biomasa de tilapias se actualizó progresivamente en cada ciclo.




Figura 6. Componentes del sistema acuapónico donde se colocaron los sensores para la medición de variables ambientales y fisicoquímicas.

En el primer experimento, se introdujeron 350 tilapias (*Oreochromis niloticus*) con un peso promedio de 6 gramos, representando una biomasa inicial total de 2.1

kg. Simultáneamente, se colocaron 59 plantas de lechuga tipo mantequilla, variedad cortesana. Al inicio del segundo experimento, las tilapias alcanzaron un peso promedio de 30 gramos, con 330 unidades, mientras que las plantas de lechuga se renovaron completamente. Para el tercer experimento, las tilapias registraron un peso promedio de 80 gramos, manteniendo su cantidad, y nuevamente se realizó una renovación total de las plantas en la balsa flotante. Finalmente, en el cuarto experimento, las tilapias alcanzaron un peso promedio de 160 gramos, con 300 individuos activos, y se renovaron las 59 plantas de lechuga.

Diseño del sistema de monitoreo

El sistema de monitoreo se compone de dos módulos principales: módulo de adquisición de datos y módulo de comunicación. El módulo de adquisición de datos está integrado de un tablero que contiene una tarjeta Arduino Mega como controlador principal, circuitos de tecnología LoRa, una tarjeta microSD de 64 GB para almacenamiento de respaldo, un botón de reinicio, una pantalla LCD para visualización y una caja de fusibles para controlar los actuadores (Figura 7, Parte I). Este módulo recolecta datos de los sensores cada 10 segundos, los cuales se promedian cada 10 minutos antes de ser almacenados en la tarjeta microSD, asegurando un registro continuo y confiable a largo plazo. Luego de almacenar y transmitir los datos por radiofrecuencia, estos se imprimen en la pantalla LCD, permitiendo su visualización directa en el sitio y facilitando la supervisión rápida de las variables.




Figura 7. Diagrama del sistema de monitoreo para el sistema de recirculación acuapónico. Parte I: Módulo de adquisición de datos (parte izquierda); Parte II: Módulo de comunicación (parte derecha).

En el centro del invernadero un sensor DS18B20 (Maxim Integrated) mide la temperatura del aire ($^{\circ}\text{C}$). En la cama de cultivo se encuentran: un sensor DHT22 que mide tanto la temperatura del aire ($^{\circ}\text{C}$) como la humedad relativa (%), un sensor SQ-515 (Apogee Instruments) que mide la radiación fotosintéticamente activa (PAR), un sensor ES-2 (Meter) que mide la conductividad eléctrica (dS m^{-1}), un sensor PHE-1304 para medir el pH, y un sensor MLX90614 (Melexis) que monitorea la temperatura del cultivo y del aire ($^{\circ}\text{C}$). En el estanque de peces se instalaron, un sensor DS18B20 para la temperatura del agua ($^{\circ}\text{C}$), un sensor ES-2 para la conductividad eléctrica (dS m^{-1}), un sensor PHE-1304 para el pH, y un sensor EZO-DO que mide el oxígeno disuelto en el agua. En el exterior del invernadero se instaló un sensor DS18B20 para monitorear la temperatura del aire exterior ($^{\circ}\text{C}$) (Cuadro 1).

La radiación fotosintéticamente activa (PAR), medida en unidades de flujo de fotones ($\mu\text{mol m}^{-2} \text{s}^{-1}$) mediante el sensor SQ-515, fue convertida a radiación total (W m^{-2}) utilizando un factor de conversión de 1/4.6.

La comunicación entre el microcontrolador principal y los sensores se realiza mediante los protocolos I2C y 1-Wire, asegurando una conexión confiable y eficiente para la transmisión de datos en el sistema de monitoreo.

Cuadro 3. Características de los sensores usados en el sistema de monitoreo (Elaboración propia).

Sensor	Variable	Rango de operación	Precisión
DHT22	Temperatura	-40 °C a 80 °C	± 0.5 °C
	Humedad	0% - 100%	± 2% HR
SQ-515	Radiación PAR	0-400 $\mu\text{mol m}^{-2} \text{s}^{-1}$	± 0.5 %
MLX90614	Temperatura	-70 °C a 380 °C	± 0.5 °C
ES-2	Conductividad eléctrica	0-120 dS m^{-1}	± 2%
PHE-1304	pH	0 - 14	± 0.01
EZO-DO	Oxígeno disuelto	0 - 100 mg L^{-1}	± 0.05 mg L^{-1}
DS18B20	Temperatura	-55 °C - 125 °C	± 0.5 °C
DHT22	Temperatura	-40 °C a 80 °C	± 0.5 °C
	Humedad	0% - 100%	± 2% HR
SQ-515	Radiación PAR	0-400 $\mu\text{mol m}^{-2} \text{s}^{-1}$	± 0.5 %
MLX90614	Temperatura	-70 °C a 380 °C	± 0.5 °C

El módulo de comunicación realiza la transmisión de datos desde el módulo de adquisición hacia un receptor LoRa en una ubicación remota. La comunicación local se refiere al envío de datos entre el Arduino Mega y el transmisor LoRa mediante conexión RX/TX. El módulo TTGO LoRa32 V2.1.6 a 915 MHz, equipado con un microcontrolador ESP32, convierte los datos promediados en una señal de radiofrecuencia y los envía a un receptor LoRa ubicado en una instalación con acceso a internet, aproximadamente a 200 metros de distancia del invernadero.

El receptor LoRa, que también cuenta con un ESP32, recibe la señal de radiofrecuencia y la conecta a una red Wi-Fi. A través de la API de Google, el ESP32 transmite los datos automáticamente a una hoja de cálculo de Google Sheets (Figura 7, Parte II). Este proceso asegura que la información recolectada esté disponible en tiempo real y se pueda consultar desde cualquier dispositivo con acceso a la hoja de cálculo, lo que permite una gestión centralizada y segura de los datos.

La plataforma Google Sheets facilita el análisis y la organización de la información de manera flexible, optimizando la toma de decisiones basadas en datos. Aunque los datos se almacenan en Google Sheets, el respaldo en la tarjeta microSD en el módulo de adquisición asegura que se mantenga un registro local y seguro en caso de que se produzcan interrupciones en la transmisión remota.

Estimación del oxígeno disuelto

Para estimar el oxígeno disuelto (OD) en el estanque de los peces, se entrenó una red neuronal artificial (RNA) con una estructura perceptrón multicapa, utilizando como entradas las variables climáticas más correlacionadas. La selección de estas variables de entrada se basó en un análisis de correlación, en el cual se aplicó el coeficiente de correlación de Pearson para determinar la relación lineal entre cada variable climática y el OD. Este análisis permitió identificar aquellas variables con una relación estadísticamente significativa con el OD. Solo las variables con un coeficiente de correlación alto y significativo fueron seleccionadas para optimizar la precisión de la RNA y reducir la complejidad, excluyendo variables con correlación baja o nula.

La estructura de la RNA fue diseñada con una capa oculta. El número de neuronas en esta capa oculta (h) se varió tomando como referencia los criterios: $h=\sqrt{mn}$ como límite inferior y $h=2n+1$ como límite superior, en donde n es el número de entradas y m el número de salidas, de acuerdo con el teorema de Kolmogorov (Mohamed, 2019). La función de activación utilizada en las neuronas de esta capa fue una función sigmoide, mientras que en la capa de salida se empleó una función lineal para ajustar mejor la salida continua de los valores de OD.

La RNA fue programada en MATLAB utilizando el Toolbox de Neural Networks y la función “newff” para crear, entrenar y validar la red. La cantidad de neuronas en la capa oculta se determinó mediante un análisis exploratorio, combinando diferentes configuraciones hasta obtener el mejor desempeño del modelo.

El entrenamiento de la RNA realizó con el algoritmo de Levenberg-Marquardt aplicado a los pesos y sesgos (Jaroslaw et al., 2022). El entrenamiento se realizó hasta alcanzar el mínimo del error cuadrático medio (MSE).

Para el entrenamiento, validación y prueba de la red neuronal, se utilizó una partición de los datos en 50%, 25% y 25%, respectivamente, de un total de 1202 datos el cuarto experimento. La RNA se evaluó utilizando los índices de desempeño: coeficiente de determinación (R^2), error absoluto medio (MAE), raíz cuadrada del error cuadrático medio (RMSE) y la eficiencia (Ef),

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (1)$$

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

$$Ef = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

donde: y_i representa el valor observado de OD, $\hat{y}_i$ el valor estimado de OD por la RNA, $\bar{y}$ es el promedio de los valores observados de OD y n el número de datos en el registro (Cort et al. 2023).

3.4 Resultados y discusión

Variables medidas en el sistema RAS

Los valores promedio y máximo de la radiación PAR fueron de 64.70 W m⁻² y 400.37 W m⁻², respectivamente (Figura 8), registrándose valores menores a 15 W m⁻² como cero (Brechner y Both, 2005). En primavera, la estabilidad de los niveles de PAR favoreció el crecimiento de la lechuga mientras que, en verano,

los ciclos tres y cuatro presentaron picos altos y variabilidad debido a la nubosidad. Aunque estos picos pudieron intensificar la fotosíntesis, también aumentaron el riesgo de estrés lumínico en días de alta radiación.




Figura 8. Variación de la radiación fotosintéticamente activa (PAR) durante los cuatro ciclos de cultivo de lechuga (febrero a julio de 2023) en el sistema acuapónico.

Se observa que la temperatura interior (TII) fue consistentemente más alta que la temperatura exterior (TEI) durante todos los experimentos, con diferencias notorias entre las estaciones del año (Figura 9). En primavera, correspondiente al primer y segundo experimento, la TII permaneció dentro del rango óptimo para el crecimiento de la lechuga, fluctuando entre 15 y 23 °C (Figura 9). Estas condiciones favorecieron un desarrollo estable y eficiente de las plantas, acorde con lo reportado por Brechner y Both (2005). En contraste, durante el verano, correspondiente al tercer y cuarto experimento, los picos de la TII alcanzaron valores de hasta 40 °C, superando el rango recomendado para la lechuga. Las TEI, aunque más bajas, fluctuaron entre 20 y 35 °C, reflejando las condiciones externas más cálidas propias de la temporada.

Según Somerville et al. (2014), temperaturas superiores a 23 °C pueden ocasionar estrés térmico en las plantas, incrementando su tasa de respiración y disminuyendo la eficiencia en la fotosíntesis y la absorción de nutrientes. Estas variaciones resaltan la necesidad de implementar medidas de control térmico, como sistemas de sombreado automatizados o ventilación controlada, para mitigar los efectos de las temperaturas extremas en el sistema acuapónico.




Figura 9. Temperaturas internas (TII) y externas (TEI) durante los cuatro experimentos realizados entre febrero y julio de 2023.

La temperatura del agua durante los experimentos mostró valores máximos, mínimos y promedio de 36.6 °C, 17.7 °C y 27.8 °C, respectivamente (Figura 10). Estos rangos se encuentran dentro de los límites óptimos para la nitrificación y el crecimiento de la tilapia del Nilo, que requiere temperaturas entre 17 y 34 °C, así como para el desarrollo de la lechuga, cuyos rangos óptimos se sitúan entre 22 y 32 °C (Brechner y Both, 2005; Azcón et al., 2008). Aunque los valores se mantuvieron en general dentro de estos rangos, se observaron picos notables en el primer y cuarto experimento, los cuales coinciden con los recambios de agua en el sistema. Durante estos recambios, el ingreso de agua a temperatura ambiente es distinta a la del sistema reflejando ese ingreso en la gráfica.

El sistema cuenta con calefacción en el agua que ayuda a mantenerla dentro de un rango estable de 20 a 30 °C, lo cual asegura condiciones favorables para la operación general. En el primer experimento, los picos térmicos se atribuyen al ingreso inicial de agua a temperatura ambiente, lo que resultó en un ligero incremento térmico hasta que el sistema alcanzó un equilibrio. De manera similar, en el cuarto experimento, las altas temperaturas externas durante los recambios aumentaron los cambios térmicos, llevando a un ajuste gradual hacia los valores deseados.

Adicionalmente, el sistema actual cuenta con un control PID que trabaja en conjunto con el sistema de calefacción para estabilizar la temperatura del agua incluso después de los recambios. Sin embargo, en condiciones de alta radiación o temperaturas externas extremas, como las observadas en verano, se requiere un sistema de regulación más preciso. Para optimizar el manejo térmico, se sugiere la implementación de un actuador controlado por el microcontrolador, que permita ajustes inmediatos y graduales.




Figura 10. Variación de la temperatura del agua en el sistema acuapónico durante los cuatro ciclos de cultivo de lechuga.

El rango deseable de oxígeno disuelto (OD) para una óptima nitrificación y el crecimiento de la tilapia se encuentra entre 4 y 8 mg L⁻¹ (Somerville et al., 2014). En este estudio, aunque en los experimentos 1 y 2 no se contaba con un sensor para monitorear el OD, los datos obtenidos en los experimentos 3 y 4 permitieron analizar su variación (Figura 11). En el experimento 3, los niveles de OD se encontraron entre 2 y 4 mg L⁻¹, lo cual se encuentra por debajo del nivel óptimo. Esta disminución se atribuye al incremento de la temperatura del agua en verano, que reduce la solubilidad del oxígeno y aumenta la demanda de oxígeno debido a una mayor biomasa y concentración de sólidos en el sistema.

Estas condiciones probablemente provocaron estrés en los peces y afectaron la eficiencia del proceso de nitrificación. En contraste, en el experimento 4, los niveles de OD se estabilizaron dentro del rango deseable de 4 a 8 mg L⁻¹, lo que refleja mejoras en la gestión del sistema de aireación. Sin embargo, los cambios observados indican que el sistema aún requiere ajustes más precisos, especialmente en condiciones críticas.

El sistema de aireación actual opera mediante un esquema de control On-Off integrado con un temporizador, que permite activar y desactivar la aireación en intervalos predefinidos. Aunque este sistema proporciona un cierto nivel de automatización, depende de configuraciones fijas que no se adaptan dinámicamente a las variaciones del oxígeno disuelto (OD) en tiempo real. Para mejorar su desempeño, podría explorarse la incorporación de controles más avanzados, como sistemas basados en setpoints, que activen la aireación al detectar niveles críticos de OD. Un controlador PID, por ejemplo, podría ser una opción viable para ajustar de manera gradual la aireación en función de las necesidades del sistema, proporcionando una regulación más precisa y minimizando los cambios del OD.




Figura 11. Variación del oxígeno disuelto (OD) en el sistema acuapónico durante los dos ciclos de cultivo entre junio y julio de 2023.

La conductividad eléctrica (CE) en el sistema mostró variaciones significativas, especialmente en el estanque de peces, donde se alcanzaron valores cercanos a $1000 \mu\text{S cm}^{-1}$ en el primer experimento. Esta tendencia creciente se debe a la acumulación de nutrientes y desechos metabólicos que incrementan la CE en el estanque comparado con la balsa de cultivo, donde se registraron valores entre 400 y $600 \mu\text{S cm}^{-1}$. Si bien el ajuste de agua y la eliminación de residuos estabilizaron los niveles de CE en los experimentos posteriores, un control automático de CE podría optimizar aún más este parámetro. Para lograr una regulación de la CE, se sugiere un sistema automatizado de dilución, en el que el microcontrolador active válvulas que ajusten el flujo de agua según el nivel de CE. Esta intervención podría mitigar la acumulación de solutos en el sistema.




Figura 12. Variación de la conductividad eléctrica (CE, $\mu\text{S cm}^{-1}$) en el estanque de peces (rojo) y en la balsa flotante (azul) durante los cuatro ciclos de cultivo entre febrero y julio de 2023.

Interfaz de visualización

Los datos obtenidos por el sistema de monitoreo IoT se visualizan automáticamente en Google Sheets (Figura 13). Esta interfaz permite monitorear en tiempo real las variables ambientales y fisicoquímicas del sistema acuapónico desde cualquier dispositivo con acceso a internet. La plataforma muestra de manera continua las lecturas de temperatura, pH, conductividad eléctrica, oxígeno disuelto, y otras variables críticas, facilitando el análisis visual mediante gráficos y tablas actualizados dinámicamente.

La interfaz en Google Sheets permite exportar los datos en formato “.csv” para análisis detallado y respaldo. Esta flexibilidad facilita el seguimiento histórico del sistema y permite detectar tendencias o fluctuaciones en los parámetros de operación. Además, la comunicación IoT asegura que los datos se transmitan de manera confiable desde el sitio de instalación, incluso en ubicaciones remotas.

Además de la visualización en Google Sheets, es posible desarrollar aplicaciones móviles para acceder y visualizar los datos de monitoreo en tiempo real desde cualquier dispositivo móvil. Mediante el uso de la API de Google Sheets y la obtención de una API Key específica, los datos pueden ser extraídos directamente de la hoja de cálculo y mostrados en una aplicación personalizada.




Figura 13. Interfaz de visualización en Google Sheets del sistema de monitoreo IoT para variables ambientales y fisicoquímicas en un sistema acuapónico.

Esta capacidad de integración permite al usuario final monitorear las variables ambientales y fisicoquímicas de forma conveniente y en tiempo real, independientemente de la ubicación, optimizando la gestión del sistema acuapónico y mejorando la capacidad de respuesta ante cualquier cambio en las condiciones del sistema.

La precisión de los sensores fue verificada utilizando sus soluciones de calibración originales, provistas por los fabricantes. Para el pH, se emplearon soluciones de referencia con valores de 4, 7 y 10. Las mediciones de temperatura se compararon con un termómetro de mercurio, que tiene una precisión de ± 0.5 °C, confirmando que las lecturas de los sensores se mantenían dentro de los rangos especificados de fábrica. Esta validación asegura que los sensores operan con alta precisión en el sistema acuapónico, optimizando la gestión de sus condiciones ambientales y fisicoquímicas.

El peso de 472 gramos registrado en la tilapia y el crecimiento homogéneo de las lechugas es resultado de las condiciones fisicoquímicas y ambientales adecuadas en el sistema acuapónico. Este desempeño refleja la efectividad del monitoreo continuo mediante el sistema basado en IoT y la red neuronal artificial, asegurando un entorno favorable para los organismos acuáticos y el desarrollo integral del sistema (Figura 14).



Figura 14. Tilapia (*Oreochromis niloticus*) de 472 gramos y lechugas (*Lactuca sativa* L.) cultivadas en el sistema acuapónico donde con monitoreo basado en IoT.

RNA para estimar el oxígeno disuelto

La matriz de correlación permite identificar las relaciones entre las diferentes variables del sistema acuapónico y el oxígeno disuelto (OD). Entre las variables evaluadas, la temperatura de la balsa de peces (TBP) mostró una correlación negativa significativa con el OD (-0.68). Este resultado refleja que un aumento en la temperatura del agua reduce la solubilidad del oxígeno, lo que puede afectar negativamente la salud de los peces y la eficiencia del sistema. Por otro lado, la radiación fotosintéticamente activa (PAR) presentó una correlación positiva moderada con el OD (0.45), indicando que mayores niveles de radiación PAR favorecen la generación de oxígeno, probablemente a través del incremento en la actividad fotosintética de las algas (Stefano et al., 1990).

La temperatura interior (TI) mostró una correlación positiva débil con el OD (0.14), lo que podría deberse a su influencia indirecta en las condiciones térmicas generales del sistema. Sin embargo, la temperatura exterior (TE) exhibió una correlación prácticamente nula (0.05), lo que sugiere una relación directa sobre el OD es mínimo. Tanto el pH (0.12) como la conductividad eléctrica (CE) (0.14) presentaron correlaciones débiles negativas, lo que indica que, aunque no son determinantes directas del OD, podrían estar relacionadas con cambios en la calidad del agua o en la dinámica de los nutrientes.

La matriz de correlación indica la selección de TBP, PAR y TI como entradas clave en el modelo de red neuronal, dado su impacto más significativo en la dinámica del OD. Por otro lado, variables como TE, con correlación prácticamente nula, fueron descartadas, mientras que pH y CE, aunque con relaciones débiles, fueron consideradas en el modelo debido a su posible influencia indirecta. Este enfoque asegura una predicción más precisa y un mejor control del sistema acuapónico al priorizar las variables más relevantes y su relación con el oxígeno disuelto (Figura 15).




Figura 15. Matriz de correlación entre variables ambientales y el oxígeno disuelto (OD).

La estimación del oxígeno disuelto (OD) se llevó a cabo durante los cuatro ciclos de cultivo de lechuga en el sistema acuapónico, evaluando el desempeño del modelo bajo diversas condiciones experimentales. La red neuronal artificial (RNA) diseñada para esta tarea quedó compuesta por tres capas principales. La capa de entrada consta de seis nodos correspondientes a las variables independientes: temperatura del agua, temperatura exterior, temperatura interior, pH, conductividad eléctrica y radiación fotosintéticamente activa (PAR). Estas entradas están conectadas a una capa oculta con 13 nodos, los cuales utilizan la función de activación tangente sigmoidea, permitiendo capturar relaciones no lineales entre las variables. Finalmente, la capa de salida incluye un único nodo que proporciona la estimación del OD, utilizando una función de activación lineal, adecuada para generar una salida continua (Figura 16).

Esta estructura asegura que la RNA pueda modelar de forma precisa la relación entre las variables climáticas y fisicoquímicas con el OD, optimizando el análisis y control del sistema acuapónico.




Figura 16. Arquitectura de la red neuronal utilizada para la estimación del oxígeno disuelto en el sistema acuapónico, con una capa de entrada de seis variables, una capa oculta de 13 nodos con función tangente sigmoide y una capa de salida con función lineal.

Durante el entrenamiento, evaluación y prueba, el modelo demostró un alto nivel de precisión, con un coeficiente de determinación (EFF) de 0.93, un error absoluto medio (MAE) de 0.15 mg/L y un error cuadrático medio (RMSE) de 0.19 mg/L. Estos resultados indican que la red neuronal artificial puede predecir con gran exactitud el oxígeno disuelto (OD), capturando las relaciones no lineales entre las variables de entrada y generando salidas que se alinean estrechamente con los datos observados (Cuadro 4). Estos resultados destacan la capacidad del modelo para captar las variaciones en el OD, reforzando su utilidad como herramienta de monitoreo en tiempo real para la gestión eficiente del sistema acuapónico.

Cuadro 4. Estadísticos de ajuste obtenidos durante el entrenamiento y evaluación de la red neuronal artificial para la estimación del oxígeno disuelto (OD) en el sistema acuapónico.

Estadístico	Entrenamiento	Evaluación
MSE	0.036361	0.036361
RMSE	0.19069	0.19069
MAE	0.14788	0.14788
EFF	0.92519	0.92519

La relación entre los datos medidos y simulados de oxígeno disuelto (OD) refleja un ajuste lineal preciso, donde los puntos estimados se alinean cercanamente con los valores medidos. Este comportamiento destaca la capacidad del modelo para capturar las variaciones del OD con un error absoluto medio (MAE) de 0.15 mg L⁻¹, un error cuadrático medio (RMSE) de 0.19 mg L⁻¹ y una eficiencia (EFF) de 0.93, lo que demuestra la efectividad de la red neuronal artificial implementada para el monitoreo del sistema acuapónico (Figura 17).




Figura 17. Relación entre los datos medidos y simulados de oxígeno disuelto (OD) utilizando la red neuronal artificial en la etapa de entrenamiento (izquierda) y evaluación (derecha). La línea roja representa el mejor ajuste lineal.

La utilidad de tener predicciones sobre OD radica en la capacidad de tener datos que pueden mostrarnos una falla en los sensores o la capacidad de

estimar el dato en caso de que no se cuente con el sensor en algún momento. La falta de datos precisos de OD influye en la calidad de las plantas y peces.

Conclusiones

La implementación de un sistema de monitoreo en tiempo real basado en Internet de las Cosas (IoT) en el sistema acuapónico permitió una gestión eficiente de las variables ambientales y fisicoquímicas, como la temperatura, el pH, la conductividad eléctrica, el oxígeno disuelto y la radiación fotosintéticamente activa. Esta herramienta facilitó el monitoreo de las condiciones óptimas para el crecimiento de la lechuga y la tilapia, ofreciendo datos precisos y confiables que mejoraron la toma de decisiones en el manejo del sistema. La aplicación de un modelo de red neuronal artificial para estimar el oxígeno disuelto demostró ser eficaz, proporcionando una valiosa herramienta de apoyo en la gestión del sistema acuapónico. La RNA logró capturar las fluctuaciones del oxígeno disuelto en función de factores ambientales, lo cual resulta fundamental para asegurar condiciones estables y adecuadas para los organismos acuáticos.

3.5 Referencias

- Abbey M., Anderson N., Yue C., Schermann M., Phelps N., Venturelli P., Vickers Z. 2019. Lettuce (*Lactuca sativa*) production in northern latitudinal aquaponic growing conditions. *HortScience* 54 (10): 1757-1761. doi: 10.21273/HORTSCI14088-19
- Azcón-Bieto J., Fleck BI, Aranda X, Gómez CN. 2008. Fotosíntesis, factores ambientales y cambio climático. In Azcón-Bieto J, Talón M (eds.), *Fundamentos de Fisiología Vegetal* (Segunda edición). McGraw Hill, Madrid, España. pp. 247-263
- Bilski J, Smolag J, Kowalczyk B, Grzanek K, Izonin I. 2023. Fast computational approach to the Levenberg-Marquardt algorithm for training feedforward neural networks. *Journal of Artificial Intelligence and Soft Computing Research* 13(2): 45-61. doi: 10.2478/jaiscr-2023-0006
- Brechner M., Both A. J. 2013. *Hydroponic lettuce handbook*. Cornell University. <https://bpb-us-e1.wpmucdn.com/blogs.cornell.edu/dist/8/8824/files/2019/06/Cornell-CEA-Lettuce-Handbook-.pdf> (Recuperado: noviembre 2024).

- Cardenas-Cartagena J., Elnourani M, Beferull-Lozano B. 2022. Forecasting aquaponic systems behaviour with recurrent neural networks models. Proceedings of the Northern Lights Deep Learning Workshop 3: 1-6. doi: 10.7557/18.6236
- Deshpande A, Deshpande P, Padmini TN. 2024. Smart aquaponics: Water quality monitoring and cloud based alert. 3rd International Conference on Artificial Intelligence For Internet of Things (AIIoT), Vellore, India, pp. 1-6, doi: 10.1109/AIIoT58432.2024.10574727.
- Love DC, Fry JP, Genello L, Hill ES, Frederick JA, Li X, Semmens K. 2014. An international survey of aquaponics practitioners. PLoS ONE 9 (7): e102662. doi: 10.1371/journal.pone.0102662
- Marsili-Libelli S. (1990). Modelling photosynthetic oxygen production in rivers. Environmental Technology 12(1): 59-67. doi: 10.1080/09593339109384982
- Mohamed ZE. 2019. Using artificial neural networks for prediction and validating solar radiation. Journal of the Egyptian Mathematical Society 27: 47. doi: 10.1186/s42787-019-0043-8
- Somerville C., Cohen M., Pantanella E., Stankus A., Lovatelli A. 2014. Small-scale aquaponic food production: Integrated fish and plant farming. FAO Fisheries and Aquaculture Technical Paper No. 589.
- Stone N. M., Thomforde H. K. 2004. Understanding your fish pond water analysis report. Cooperative Extension Program, University of Arkansas at Pine Bluff, Pine Bluff. <https://extension.rwfm.tamu.edu/wp-content/uploads/sites/8/2013/09/Understanding-Your-Fish-Pond-Water-Analysis-Report1.pdf> (Recuperado: noviembre 2024).
- Su MH, Azwar E, Ya Y, Sonne C, Yek PNY, Liew RK, Cheng CK, Show PL, Lam SS. 2020. Simultaneous removal of toxic ammonia and lettuce cultivation in aquaponic system using microwave pyrolysis biochar. Journal of Hazardous Materials 396: 122610. doi: 10.1016/j.jhazmat.2020.122610
- Valiente F., Garcia R., Domingo E., Estante S., Ochaves E., Villanueva J., Balbin J. 2018. Internet of Things (IoT)-Based mobile application for monitoring of automated aquaponics system. 2018 IEEE 10th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM), Baguio City, Philippines. doi: 10.1109/HNICEM.2018.8666439.
- Verdouw C, Sundmaeker H, Tekinerdogan B, Conzon D, Montanaro T. 2019. Architecture framework of IoT-based food and farm systems: A multiple case study. Computers and Electronics in Agriculture 165(1): 168-169. doi: 10.1016/j.compag.2019.104939
- Yau R, Jalani J, Amirul, Sadun S, Rejab M, John J. 2025. Development of an aquaponics farming technology system using Arduino based on Internet

of Things. Journal of Advanced Research in Applied Sciences and Engineering Technology 45(2): 11-24. doi: 10.37934/araset.45.2.1124

- Willmott CJ, Matsuura K. 2005. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. Climate Research 30(1): 79-82. doi: 10.3354/CR030079
- Wongkiew S, Hu Z, Chandran K, Woo J, Kumar S. 2017. Nitrogen transformations in aquaponic systems: A review. Aquacultural Engineering 76(1): 9-19. doi: 0.1016/j.aquaeng.2017.01.004
- Zhou X, Wang J, Liu Y, Duan Q. 2023. Deep learning with PID residual elimination network for time-series prediction of water quality in aquaculture industry. Computers and Electronics in Agriculture 212: 108125. doi: 10.1016/j.compag.2023.108125

4 Análisis de sensibilidad y calibración de un modelo dinámico de crecimiento y absorción de nitrógeno para lechuga en acuaponía

4.1 Resumen

Los modelos de simulación son útiles para predecir las respuestas de los cultivos a factores ambientales y de manejo; sin embargo, requieren calibrarse antes de aplicarlos en un nuevo ambiente. El objetivo de este estudio fue realizar un análisis de sensibilidad global y calibrar un modelo dinámico de crecimiento y absorción de nitrógeno para lechuga en acuaponía. Se realizaron cuatro experimentos en lechuga cultivadas en un sistema acuapónico. En periodos regulares se realizaron mediciones de peso fresco y seco, área foliar, área proyectada y contenido de nitrógeno total en el dosel. Asimismo, se midieron la temperatura del aire y radiación solar fotosintéticamente activa. El método de Sobol fue utilizado para calcular los índices sensibilidad de primer orden y de efecto total. Los parámetros que más influyeron en la variabilidad de la salida del modelo fueron estimados minimizando una función de error entre las variables medidas y simuladas. De los 13 parámetros del modelo, solamente tres resultaron sensibles, dos relacionados con la absorción de nitrógeno y uno con la tasa de crecimiento. De acuerdo con las estadísticas eficiencia de modelado y raíz del cuadrado medio del error, el modelo calibrado simula de manera satisfactoria la biomasa total y contenido de nitrógeno total en el dosel para lechuga cultivadas en acuaponía.

Key words: *Lactuca sativa* L., *Oreochromis niloticus*, balsa profunda, método de Sobol, modelación matemática, evolución diferencial.

4.2 Introducción

La acuaponía combina la cría de peces y el cultivo de plantas en un sistema integrado, donde los desechos de los peces se convierten en nutrientes para las plantas mediante bacterias nitrificantes (Huan et al., 2020). En estos sistemas, el

nitrógeno es uno de los principales nutrientes para el crecimiento de los peces y las plantas. Debido al metabolismo de los peces, el nitrógeno presente en el alimento puede convertirse en sustancias tóxicas que, en altas concentraciones, afectarán la salud de los peces. Por lo tanto, es particularmente importante controlar la concentración de nitrógeno para gestionar el crecimiento de peces, bacterias y plantas en los sistemas acuapónicos (Li et al., 2021).

Los modelos de cultivos basados en procesos son ampliamente usados para explorar las interacciones entre el crecimiento de las plantas y los nutrientes de las plantas bajo diversas condiciones ambientales y de manejo (Rathnappriya et al., 2022). Estos modelos pueden utilizarse para evaluar el balance de nitrógeno en los sistemas acuapónicos y para predecir la absorción de nitrógeno por las plantas mediante la alteración de los parámetros del modelo.

La lechuga es una de las hortalizas más cultivadas en acuaponía por su ciclo de crecimiento corto, numerosos tipos de mercado, variedades disponibles y tener un sistema de raíces adaptables a los sistemas de producción hidropónicos y acuapónicos (Abbey et al., 2019). En la literatura se han propuestos diversos modelos mecanicistas de crecimiento para lechuga. Entre otros, destacan los modelos de Sweeney et al. (1981), Pearson et al. (1997), Seginer et al. (1998) y van Henten (1994), usados en invernaderos principalmente. Li et al. (2021) desarrollaron un modelo matemático mecanicista para un sistema acuapónico acoplado, combinado modelos de crecimiento para tilapia y plantas de col china. En este modelo, la biomasa de las plantas se modela con un polinomio empírico y la absorción de nitrógeno con una ecuación de Michaelis-Menten.

Zhang et al. (2008) desarrollaron un modelo dinámico para predecir la absorción de nitrógeno y la acumulación de materia seca para una planta de lechuga cultivada en solución nutritiva. El modelo combina la absorción de nitrógeno con la acumulación de materia seca utilizando un enfoque mecanicista de dos compartimentos. El modelo fue calibrado y evaluado con datos experimentales realizados en diferentes condiciones de luz. Los resultados mostraron que el modelo realizó buenas predicciones de la absorción de nitrógeno por las plantas desde la etapa de plántulas hasta la madurez en un invernadero.

Cuando los modelos matemáticos de cultivos van a utilizarse en una situación particular, el desempeño del modelo debe evaluarse críticamente para aumentar la confianza y reducir la incertidumbre en las simulaciones (Angulo et al., 2013). Esto requiere una calibración cuidadosa de los modelos con datos medidos y una evaluación crítica para evaluar la solidez del modelo en diferentes entornos (He et al., 2017). La calibración de modelos generalmente implica la estimación de los parámetros clave del modelo ajustando el modelo general a los datos observados (Wallach et al., 2011). Esto es necesario porque no todos los parámetros del modelo se pueden medir directamente (He et al., 2017).

En un proceso de calibración, solamente los parámetros que más influyen en la salida son calibrados para evitar el sobreajuste del modelo. El análisis de sensibilidad (SA) permite determinar los parámetros más influyentes en los modelos de cultivos (Pianosi et al., 2015). Las técnicas de SA se pueden clasificar en SA local y SA global. SA local examina la respuesta de la salida del modelo a la variación de una entrada, mientras mantiene fijas las otras entradas. Una desventaja del SA local es que en la evaluación de la sensibilidad no considera la interacción entre parámetros. SA global se basa en la respuesta promedio de la salida del modelo cuando se permite que todas las entradas varíen dentro de un rango predefinido (Lu et al., 2021). SA global es capaz de capturar las respuestas del modelo no lineal y las interacciones entre los parámetros del modelo (Cariboni et al., 2007), pero requieren un mayor esfuerzo computacional. Los métodos globales de SA basados en la varianza son los más ampliamente utilizados.

En la literatura no se ha reportado la evaluación del modelo de Zhang et al. (2008) para lechugas cultivadas en acuaponía. Por lo anterior, los objetivos de este estudio fueron: 1) realizar un análisis de sensibilidad global para determinar los parámetros más sensibles del modelo; y 2) calibrar el modelo mediante algoritmos de evolución diferencial para lechuga en un sistema acuapónico.

4.3 Materiales y métodos

Descripción del experimento

El estudio se realizó en un invernadero tipo capilla con cubierta de polietileno y ventilación natural, ubicado en Texcoco, México (19° 29' N, 98° 53' O). Se instaló un sistema acuapónico tipo RAS (Sistema de Recirculación Acuapónica) que incluye un estanque de 1000L, un sedimentador modificado a partir de un contenedor de 200 L, un mineralizador adaptado de un tanque de polietileno endurecido de 120 L con una malla de 70 x 22 hilos para la filtración de sólidos suspendidos, un biofiltro conteniendo taparroscas como superficie para la colonización de bacterias nitrificantes, y una balsa flotante construida de madera con dimensiones 2.40 x 1.10 x 0.30 m de largo, ancho y profundidad, respectivamente.

Entre febrero y agosto de 2023, se llevaron a cabo cuatro ciclos experimentales en un sistema acuapónico, combinando el cultivo de lechugas tipo mantequilla, variedad cortesana, con la cría de tilapias (*Oreochromis niloticus*). En el primer ciclo, se introdujeron 350 tilapias con un peso promedio inicial de 6 gramos, alcanzando una biomasa total de 2.1 kg, mientras se colocaron 59 plantas de lechuga. Los trasplantes de las plantas se efectuaron el 23 de febrero, 24 de abril, 27 de junio y 31 de julio, con una renovación completa al inicio de cada ciclo. Durante el segundo experimento, las tilapias alcanzaron un peso promedio de 30 gramos con 330 individuos, mientras que en el tercero mantuvieron su cantidad con un peso promedio de 80 gramos. En el cuarto ciclo, el número de tilapias activas fue de 300, con un peso promedio de 160 gramos, y nuevamente se renovaron las plantas de lechuga al inicio de cada etapa. Los ajustes en la biomasa de tilapias se realizaron progresivamente en función de su crecimiento a lo largo del estudio.

Mediciones de variables del clima y de la solución nutritiva

Dentro del invernadero se instaló un sistema de monitoreo basado en Arduino para medir variables ambientales y fisicoquímicas esenciales. La temperatura del aire (°C) y la humedad relativa (%) fueron monitoreadas con un sensor DHT22 (Aosong Electronics), ubicado dentro de una cubierta protectora. La radiación

fotosintéticamente activa (PAR, $\mu\text{mol m}^{-2} \text{s}^{-1}$) se midió con un sensor SQ-515 (Apogee Instruments), colocado a 1.5 metros de altura junto al depósito del cultivo. Además, en el centro del invernadero, se utilizó un sensor DS18B20 (Maxim Integrated) para medir la temperatura del aire ($^{\circ}\text{C}$). En la cama de cultivo, se instalaron sensores para variables específicas: un ES-2 (Decagon Devices) para la conductividad eléctrica (dS m^{-1}), un PHE-1304 (Omega) para el pH y un MLX90614 (Melexis) para registrar la temperatura del cultivo y del ambiente. En el estanque de peces, se colocaron un sensor DS18B20 para medir la temperatura del agua ($^{\circ}\text{C}$), un ES-2 para la conductividad eléctrica (dS m^{-1}), un PHE-1304 para el pH y un EZO-DO para determinar el oxígeno disuelto. Se instaló un sensor DS18B20 en el exterior del invernadero para monitorear la temperatura del aire exterior ($^{\circ}\text{C}$). Los datos de todos los sensores fueron recolectados cada 10 segundos, promediados cada 10 minutos y almacenados automáticamente en un archivo “.csv”, garantizando un registro continuo y confiable para el análisis posterior.

Mediciones de variables del cultivo y contenido de nitrógeno

Se realizaron siete muestreos de biomasa en ambos ciclos de cultivo a intervalos regulares de tres a cuatro días, separando la biomasa aérea y la biomasa de raíces. Se seleccionaron al azar cuatro y tres plantas en el primer y subsiguientes muestreos, respectivamente. El peso fresco de la biomasa aérea se midió con una báscula digital de precisión Pioneer escala PA2102 (Ohaus) con capacidad de 2100 g y precisión de 0.01 g. El área foliar se midió con un medidor de área foliar LI-3100 (LI-COR). Las muestras se secaron durante 48 h en un horno a una temperatura de 60°C hasta alcanzar un peso constante. El área proyectada de cada una de las plantas de las muestras fue estimada mediante el tratamiento digital de las imágenes tomadas con la cámara de un smartphone a 1 m de distancia vertical sobre las plantas.

El contenido de nitrógeno en las muestras de lechuga se determinó con siguiente procedimiento. La materia seca del dosel correspondiente a cada muestreo fue

mezclada para obtener una muestra compuesta con la materia seca proveniente de 3 plantas. Las muestras compuestas se molieron en un mortero y posteriormente se tomaron muestras de 0.5 g de materia seca. Para realizar la digestión húmeda se agregaron 4 ml de una mezcla di ácida de ácido sulfúrico y ácido perclórico en relación (4:1) y 2 ml de peróxido de hidrogeno al 30%, se mantuvieron por 8 horas en la campana de extracción, posteriormente se aforaron con agua destilada a 50 ml. El contenido de nitrógeno en las muestras se determinó con el método micro Kjeldahl por arrastre de vapor (Alcántar y Sandoval, 1999).

Descripción del modelo matemático de cultivo

El modelo dinámico se compone de tres compartimientos: reserva estructural, reserva no estructural y nitrógeno total, respectivamente. En el submodelo de acumulación de nitrógeno se asume que la tasa de absorción de nitrógeno depende de la concentración de nitrógeno y del peso seco del dosel, así como de la disponibilidad de nitrógeno para la planta. La tasa de absorción de nitrógeno se modela mediante una ecuación cinética de saturación (Zhang et al., 2008), esto es:

$$\frac{dN_{up}}{dt} = J_{max} \frac{C_N w}{C_N + K} \quad (1)$$

donde N_{up} (mmol) es el nitrógeno acumulado en el dosel, J_{max} (mmol h⁻¹ g[DM]⁻¹) es la tasa máxima de absorción de nitrógeno por unidad de materia seca del dosel, w (g) es el peso seco del dosel, C_N (mM) es la concentración de nitrógeno en la solución nutritiva, y K (mM) es la constante de semi-saturación para absorción de nitrógeno. J_{max} decrece con el peso seco del dosel y se calcula con la siguiente ecuación (Zhang et al., 2008),

$$J_{max} = J_{max,0} \exp(-\alpha w) \quad (2)$$

donde $J_{max,0}$ (mmol h⁻¹ g[DM]⁻¹) es el valor de J_{max} cuando $w = 0$, y α (g[DM]⁻¹) es un parámetro.

En el submodelo de acumulación de materia seca se asume que la lechuga tiene dos reservorios de carbono separados: biomasa estructural y biomasa no

estructural. La fotosíntesis del dosel suministra asimilados de carbono a ambos reservorios. La acumulación de materia seca en los reservorios estructural y no estructural se describen mediante las siguientes ecuaciones (Zhang *et al.*, 2008):

$$\frac{dw_G}{dt} = \mu_{max} \frac{w_S}{w_S + w_G} c_{q10,\mu}^{(T-20)/10} w_G \quad (3)$$

$$\frac{dw_S}{dt} = \theta P_g - \frac{1}{Y_G} \frac{dw_G}{dt} \quad (4)$$

donde t es el tiempo (h), T (°C) es la temperatura del aire, w_G (g) es el peso seco del reservorio estructural, w_S (g) es el peso seco del reservorio no estructural, μ (h⁻¹) es la tasa de crecimiento de saturación a 20 °C, $c_{q10,\mu}$ es el factor Q_{10} para crecimiento, T (°C) es la temperatura del aire, θ es un factor para convertir CO₂ a materia seca, P_g (g[CO₂] h⁻¹) es la tasa de fotosíntesis bruta del dosel, y Y_G es la eficiencia de conversión. El peso seco total del dosel w (g) es la suma de w_G y w_S .

La fotosíntesis del dosel se calcula con la siguiente ecuación (Zhang *et al.*, 2008),

$$P_g = A[1 - \exp(-kL_{AI})]f(N_{up}) \frac{\xi I(\sigma C_{CO2} - \beta)}{\xi I + \sigma C_{CO2}} \quad (5)$$

donde A (m²) es el área proyectada por una planta, k es el coeficiente de extinción, L_{AI} es el índice de área foliar, $f(N_{up})$ es una función que toma valores entre 0 y 1, ξ (g[CO₂] J⁻¹) es la eficiencia de uso de luz de la hoja, β (g[CO₂] m⁻² h⁻¹) es el punto de compensación de CO₂, I (J m⁻² h⁻¹) es la radiación fotosintéticamente activa incidente, C_{CO2} (g[CO₂] m⁻³) es la concentración de CO₂ en el aire, y σ (m h⁻¹) es la conductancia de la hoja a la difusión de CO₂.

El efecto de la concentración de nitrógeno en el dosel sobre la tasa de fotosíntesis se modela con la siguiente ecuación,

$$f(N_{up}) = \begin{cases} 0 & \text{cuando } (N_{up}/w) < 0.02 \\ \frac{1}{3} \left(\frac{N_{up}}{w} - 0.02 \right) \times 100 & \text{cuando } 0.02 \leq (N_{up}/w) \leq 0.05 \\ 1 & \text{cuando } (N_{up}/w) > 0.05 \end{cases} \quad (6)$$

donde 0.05 es la suma de las concentraciones de nitrato y nitrógeno orgánico en el dosel.

Procedimiento del análisis de sensibilidad global

En este estudio se utilizó el método de Sobol para llevar a cabo el análisis de sensibilidad global de los parámetros del modelo de Zhang et al. (2018). El método de Sobol se basa en descomponer la varianza total de la salida del modelo en las contribuciones de primer orden y de orden superior de la variación de los parámetros (Lu et al., 2021). La varianza total de la salida de una función $Y = f(X_1, X_2, \dots, X_n)$, $V(Y)$, causada por la variación de los n parámetros X del modelo, se puede dividir de la siguiente manera (Varella et al., 2010):

$$V(Y) = \sum_{1 \leq i \leq n} V_i + \sum_{1 \leq i < j \leq n} V_{ij} + \dots + V_{12\dots n} \quad (7)$$

donde $V_i = V[E(Y|X_i)]$ mide el efecto principal del parámetro X_i , $i = 1, \dots, n$, y los otros términos miden los efectos de interacción. $E(Y|X_i)$ es la esperanza de la salida del modelo condicionada a un valor fijo de X_i .

La descomposición de la ecuación (7) se utiliza para derivar dos tipos de índices de sensibilidad definidos por:

$$S_i = \frac{V[E(Y|X_i)]}{V(Y)} \quad (8)$$

$$S_{Ti} = 1 - \frac{V(E(Y|\mathbf{X}_{-i}))}{V(Y)} = 1 - \frac{V_{-i}}{V(Y)} \quad (9)$$

donde V_{-i} es la suma de todos los términos de varianza que no incluyen el índice i , $\mathbf{X}_{-i} = (X_1, \dots, X_{i-1}, X_{i+1}, \dots, X_n)$ es el vector de entrada sin X_i . S_i es el índice de sensibilidad de primer orden o principal para el parámetro i . Calcula la fracción de la varianza de Y explicada por la incertidumbre del parámetro X_i y representa el efecto principal de este parámetro en la variable de salida Y (Varella et al., 2010). S_{Ti} es el índice de sensibilidad total para el parámetro i y es la suma de todos los efectos (de primer orden y de orden superior) que involucran al parámetro X_i .

S_i y S_{Ti} están ambos en el rango $(0,1)$, valores bajos indican efectos insignificantes y valores cercanos a 1 efectos grandes. S_{Ti} tiene en cuenta tanto S_i como las interacciones entre el parámetro i y los otros n parámetros, interacciones que pueden evaluarse mediante la diferencia entre S_{Ti} y S_i . Los

términos de interacción de un conjunto de parámetros representan la fracción de la varianza de Y inducida por la varianza de estos parámetros pero que no puede explicarse por la suma de sus efectos principales. Los dos índices de sensibilidad S_i y S_{Ti} son iguales si el efecto del parámetro i en la salida del modelo es independiente de los valores de los otros parámetros: en este caso, no hay interacción entre este parámetro y los otros y se dice que el modelo es aditivo con respecto a X_i .

La principal dificultad para evaluar los índices de sensibilidad de primer orden y total es que requieren el cálculo de integrales de dimensión alta (Varella *et al.*, 2010). En este estudio se usó el método de Homma-Saltelli modificado para mejorar el uso de las evaluaciones del modelo (Fang *et al.* 2015; Wu *et al.*, 2012). El procedimiento del método se describe a continuación.

1. Generar una matriz A de tamaño $N \times n$ a partir de la función de densidad de probabilidad (PDF) de los parámetros, donde N es el tamaño de la muestra y n es el número de parámetros,

$$A = \begin{bmatrix} x_1^{(1)} & \dots & x_i^{(1)} & \dots & x_k^{(1)} \\ x_1^{(2)} & \dots & x_i^{(2)} & \dots & x_k^{(2)} \\ \dots & \dots & \dots & \dots & \dots \\ x_1^{(N)} & \dots & x_i^{(N)} & \dots & x_k^{(N)} \end{bmatrix} \quad (10)$$

2. Generar otra matriz de muestreo B de dimensión $N \times n$ a partir de la PDF de los parámetros,

$$B = \begin{bmatrix} x_1^{(N+1)} & \dots & x_i^{(N+1)} & \dots & x_k^{(N+1)} \\ x_1^{(N+2)} & \dots & x_i^{(N+2)} & \dots & x_k^{(N+2)} \\ \dots & \dots & \dots & \dots & \dots \\ x_1^{(2N)} & \dots & x_i^{(2N)} & \dots & x_k^{(2N)} \end{bmatrix} \quad (11)$$

3. Definir una matriz C_i formada por todas las columnas de B excepto la i -ésima columna, que se toma de A ,

$$C_i = \begin{bmatrix} x_1^{(N+1)} & \dots & x_i^{(1)} & \dots & x_k^{(N+1)} \\ x_1^{(N+2)} & \dots & x_i^{(2)} & \dots & x_k^{(N+2)} \\ \dots & \dots & \dots & \dots & \dots \\ x_1^{(2N)} & \dots & x_i^{(N)} & \dots & x_k^{(2N)} \end{bmatrix} \quad (12)$$

4. Definir una matriz D_i formada por todas las columnas de A excepto la i -

ésima columna, que se toma de B ,

$$D_i = \begin{bmatrix} x_1^{(1)} & \dots & x_i^{(N+1)} & \dots & x_k^{(1)} \\ x_1^{(2)} & \dots & x_i^{(N+2)} & \dots & x_k^{(2)} \\ \dots & \dots & \dots & \dots & \dots \\ x_1^{(N)} & \dots & x_i^{(2N)} & \dots & x_k^{(N)} \end{bmatrix} \quad (13)$$

5. Calcular la salida del modelo para cada conjunto de parámetros de las cuatro matrices (esto es, para cada fila en cada matriz) para obtener vectores de salidas del modelo de dimensión N :

$$y_A = f(A), y_B = f(B), y_{C_i} = f(C_i), y_{D_i} = f(D_i) \quad (14)$$

El índice de primer orden se calcula con el estimador de Homma y Saltelli (Fang *et al.*, 2015):

$$S_i = \frac{V[E(Y|X_i)]}{V(Y)} = \frac{\frac{1}{2N}(\sum_{j=1}^N y_A^{(j)} y_{C_i}^{(j)} + \sum_{j=1}^N y_B^{(j)} y_{D_i}^{(j)}) - \hat{f}_0^2}{\frac{1}{2N} \sum_{j=1}^N [(y_A^{(j)})^2 + (y_B^{(j)})^2] - \hat{f}_0^2} = \frac{\bar{V}_i - \hat{f}_0^2}{\bar{V} - \hat{f}_0^2} \quad (15)$$

donde

$$\hat{f}_0^2 = \frac{1}{2N} \sum_{j=1}^N (y_A^{(j)} y_B^{(j)} + y_{C_i}^{(j)} y_{D_i}^{(j)}) \quad (16)$$

es la media. El índice de sensibilidad total S_{Ti} se calcula con el estimador propuesto por Jansen (Fang *et al.*, 2015):

$$S_{Ti} = \frac{\frac{1}{N} \sum_{j=1}^N (y_A^{(j)} - y_{D_i}^{(j)})^2}{\frac{1}{N} \sum_{j=1}^N [(y_A^{(j)})^2 + (y_{D_i}^{(j)})^2] - (\frac{1}{N} \sum_{j=1}^N y_A^{(j)})^2 - (\frac{1}{N} \sum_{j=1}^N y_{D_i}^{(j)})^2} \quad (17)$$

Las ecuaciones del modelo de Zhang *et al.* (2018) y las ecuaciones (11) a (17) fueron programadas en el software MATLAB. Las salidas del modelo fueron el nitrógeno acumulado en el dosel (N_{up}), biomasa estructural (w_G) y biomasa no estructural (w_S). Se considero para cada parámetro una función de densidad de probabilidad uniforme. Se generaron las matrices A (ecuación 10) y B (ecuación 11) de tamaño $N = 3000$, con un muestreo hipercubo latino y una variación de 20% del valor nominal de los parámetros. Los índices de sensibilidad de primer orden y de orden total se calcularon con las ecuaciones (15) y (17), respectivamente.

En el Cuadro 5 se muestran los símbolos, valores nominales, y rango de los parámetros del modelo usados en este estudio. Los valores nominales fueron obtenidos de Zhang et al. (2008).

Cuadro 5. Parámetros del modelo dinámico para lechuga como factores de entrada para el análisis de sensibilidad global con el método de Sobol, y una variación de 30% del valor nominal.

No.	Símbolo	Unidades	Valor nominal	Límite inferior	Límite superior
1	θ	adimensional	0.680	0.476	0.884
2	$c_{q10,\mu}$	adimensional	1.60	1.12	2.08
3	k	adimensional	0.90	0.63	1.00
4	ξ	$\text{g}[\text{CO}_2] \text{ J}^{-1}$	14×10^{-6}	9.8×10^{-6}	18.2×10^{-6}
5	β	$\text{g}[\text{CO}_2] \text{ m}^{-2} \text{ h}^{-1}$	0.360	0.252	0.468
6	σ	m h^{-1}	7.20	5.04	9.36
7	Y_G	adimensional	0.80	0.56	1.00
8	μ_{max}	h^{-1}	0.010	0.007	0.130
9	C_{CO2}	$\text{g}[\text{CO}_2] \text{ m}^{-3}$	0.720	0.504	0.936
10	C_N	mmol	4.0	2.8	5.2
11	$J_{max,0}$	$\text{mmol h}^{-1} \text{ g}[\text{DM}]^{-1}$	0.0440	0.0308	0.0572
12	α	$\text{g}[\text{DM}]^{-1}$	0.1545	0.1081	0.2009
13	K	mmol	0.040	0.028	0.052

Algoritmo de evolución diferencial

Evolución diferencial (DE) es un algoritmo evolutivo propuesto por Storn y Price en 1997 para problemas de optimización de parámetros reales. Con las ventajas de su simplicidad, rápida convergencia y pocos parámetros, DE ha sido usado para resolver problemas de optimización numérica en muchas áreas (Das et al. 2016).

Una población consiste en NP individuos $\mathbf{u}_{i,G}$, $i = (1, 2, 3, \dots, NP)$, donde G denota una generación. El tamaño de la población no cambia durante el proceso de optimización. Un individuo $\mathbf{u}_{i,G}$ consiste en D variables que son acotados por límites inferior y superior $[b_{j,\min}, b_{j,\max}]$, $j = (1, 2, 3, \dots, D)$. Los individuos iniciales son determinados aleatoriamente; entonces, las operaciones de mutación y cruzamiento son usados para generar los nuevos individuos, y la operación de

selección es aplicada para determinar que individuo, el nuevo o el original, sobrevivirá en la siguiente generación.

Mutación. Para cada vector objetivo $\mathbf{u}_{i,G}$, $i = (1,2,3, \dots, NP)$, un vector mutante es generado de acuerdo con los operadores clásicos de mutación:

DE/rand/1/bin:

$$\mathbf{v}_{i,G} = \mathbf{u}_{r_1,G} + F \cdot (\mathbf{u}_{r_2,G} - \mathbf{u}_{r_3,G}) \quad (18)$$

DE/rand/2/bin:

$$\mathbf{v}_{i,G} = \mathbf{u}_{r_5,G} + F \cdot (\mathbf{u}_{r_1,G} + \mathbf{u}_{r_2,G} - \mathbf{u}_{r_3,G} - \mathbf{u}_{r_4,G}) \quad (19)$$

DE/best/1/bin:

$$\mathbf{v}_{i,G} = \mathbf{u}_{best,G} + F \cdot (\mathbf{u}_{r_2,G} - \mathbf{u}_{r_3,G}) \quad (20)$$

DE/best/2/bin:

$$\mathbf{v}_{i,G} = \mathbf{u}_{best,G} + F \cdot (\mathbf{u}_{r_1,G} + \mathbf{u}_{r_2,G} - \mathbf{u}_{r_3,G} - \mathbf{u}_{r_4,G}) \quad (21)$$

donde los índices aleatorios $r_1, r_2, r_3, r_4 \in (1,2,3, \dots, NP)$ son enteros y mutuamente diferentes, y estos también son diferentes del índice de vector i . En la fórmula (18) se puede observar que éste contiene 4 vectores, así el tamaño mínimo de población es 4. El factor de escala $F \in [0,2]$ es un parámetro de control.

Cruzamiento. El vector objetivo es combinado con el vector mutante usando el cruzamiento binomial para obtener el vector de prueba:

$$\mathbf{u}'_{i,G} = \mathbf{u}_{j,i,G} = \begin{cases} v_{j,i,G} & \text{if } randb(j) \leq CR \text{ or } j = rnbr(i) \\ u_{j,i,G} & \text{otherwise} \end{cases} \quad (22)$$

donde $randb(j) \in [0,1]$ es la j -ésima evaluación de un generador de números aleatorios uniforme, $rnbr(i) \in (1,2, \dots, D)$ es un índice elegido aleatoriamente para asegurar que al menos un elemento del vector es obtenido del vector mutante, y $CR \in [0,1]$ es la probabilidad de cruzamiento, que debe ser definido por el usuario.

Selección. La operación de selección determina si el vector de prueba $\mathbf{u}'_{i,G}$ o el vector objetivo $\mathbf{u}_{i,G}$ sobrevive pasando a formar parte de la siguiente generación $G + 1$, en base a la aptitud del vector:

$$\mathbf{u}_{i,G+1} = \begin{cases} \mathbf{u}'_{i,G} & \text{if } \Phi(\mathbf{u}'_{i,G}) < \Phi(\mathbf{u}_{i,G}) \\ \mathbf{u}_{i,G} & \text{otherwise} \end{cases} \quad (23)$$

donde $\Phi(\mathbf{u}'_{i,G})$ y $\Phi(\mathbf{u}_{i,G})$ son los valores de la función objetivo. La condición $\Phi(\mathbf{u}'_{i,G}) < \Phi(\mathbf{u}_{i,G})$ es usado para problemas de minimización.

Una vez que la nueva población está establecida; el proceso de mutación, recombinación y selección es repetido hasta que el óptimo es localizado o se satisface un criterio de finalización especificado; por ejemplo, un número máximo de generaciones $G_{\max}$. El algoritmo DE clásico tiene tres parámetros de control que requieren ser ajustados por el usuario: el factor de escala de mutación F , la constante de cruzamiento CR y el tamaño de la población NP .

Calibración del modelo

La calibración del modelo dinámico se llevó a cabo minimizando el criterio de mínimos cuadrados ponderados (Rodriguez-Fernandez *et al.*, 2006):

$$J(p) = \sum_{i=1}^{NV} \sum_{j=1}^{NM_i} w_j \left(y_{ij} - \hat{y}_{ij}(p) \right)^2 \quad (24)$$

donde y_{ij} representa la variable medida, $\hat{y}_{ij}$ representa la correspondiente variable simulada por el modelo, NV es el número de variables, NM es el número de mediciones en el conjunto de datos y p son los parámetros del modelo incluidos en la calibración. w_j representa los diferentes pesos para normalizar la contribución de cada término:

$$w_j = \left(\frac{1}{\max(y_{ij})} \right)^2 \quad (25)$$

Las variables consideradas para la calibración fueron el nitrógeno acumulado (N_{up}) y la biomasa (w). El problema de optimización se resolvió mediante cuatro algoritmos de evolución diferencial: DE/rand/1/bin, DE/rand/2/bin, DE/best/1/bin, DE/best/2/bin. En la calibración se incluyeron los parámetros que más influyen en las variables nitrógeno acumulado (N_{up}), biomasa estructural (w_G) y biomasa no estructural (w_S), de acuerdo con el análisis de sensibilidad global. En el presente estudio se consideró como sensibles o influyentes los parámetros con un índice de sensibilidad total mayor o igual a 0.1. Para el algoritmo de evolución diferencial se consideraron los siguientes parámetros de control: tamaño de la población

$NP = D \times 10$, donde D es el número de parámetros a estimar; factor de escala de mutación $F = 0.6$; constante de cruzamiento $CR = 0.9$; y número máximo de generaciones $G_{max} = 200$. La optimización de la función de costo (ecuación 24) se repitió 10 veces.

Las salidas del submodelo nitrógeno acumulado (N_{up}) y biomasa (w) fueron comparadas con los datos medidos y fueron evaluados usando tres índices estadísticos: relative root mean squared error (RRMSE), mean absolute error (MAE) y model efficiency (EF) (Wallach et al., 2019):

$$RRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}}{\bar{y}} \quad (26)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (27)$$

$$EF = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (28)$$

donde $\hat{y}_i$ es el valor simulado en el tiempo i , y_i es el valor medido en el tiempo i , $\bar{y}$ es el valor promedio de los valores medidos, y n es el número de mediciones.

4.4 Resultados y discusión

Modelo para el área proyectada e índice de área foliar

La calibración del modelo dinámico se realizó con los datos de biomasa (w) y nitrógeno total acumulado (N_{up}) obtenidos en los experimentos 1 y 3. Los datos de los experimentos 2 y 4 fueron descartados debido a inconsistencias en los valores de nitrógeno acumulado en la planta.

Para el cálculo de la tasa de fotosíntesis en el modelo dinámico, se requiere el área de cobertura del suelo por planta A (m^2) y el índice de área foliar L_{AI} . Por lo anterior, se ajustó una relación empírica entre la materia seca (w) y estas dos variables (A y L_{AI}). La ecuación con el mejor ajuste para el área de cobertura por planta A (m^2) para los experimentos 1 y 3 fue (Figura 18a):

$$A = \begin{cases} -0.0006w^2 + 0.012w + 0.0057 & \text{si } w < 10.02 \\ 5.04 & \text{caso contrario} \end{cases} \quad (29)$$

con un coeficiente de correlación (R^2) de 0.9481, mientras que para índice de área foliar L_{AI} la ecuación con el mejor ajuste fue (Figura 18b):

$$L_{AI} = \begin{cases} -0.0141w^2 + 0.4936w + 1.5059 & \text{si } w < 10.02 \\ 0.06653 & \text{caso contrario} \end{cases} \quad (30)$$

con coeficiente de correlación de 0.9517. Con base en los coeficientes de correlación, las ecuaciones ajustadas son confiables y pueden usarse en las simulaciones del modelo dinámico, para estimar el área proyectada por planta e índice de área foliar con la biomasa simulada.




Figura 18. a) Modelo para el área proyectada (A), y b) modelo para el índice de área foliar (L_{AI}), lechuga tipo mantequilla para los experimentos 1 y 3.

Análisis de sensibilidad

El análisis de sensibilidad se realizó con los datos del clima y condiciones iniciales de biomasa y nitrógeno acumulado para los experimentos 1. En las Figura 19 y 20 se presentan la radiación PAR y la temperatura promedio cada hora en el interior del invernadero, usados como entradas en el modelo dinámico para realizar las simulaciones. Como se observa las gráficas, la radiación promedio

fue similar en ambos experimentos; sin embargo, la temperatura en el experimento 3 fue mayor que la registrada en el experimento 1.

Para la variable nitrógeno acumulado por la planta (N_{up}), los parámetros más influyentes de acuerdo con el índice de sensibilidad total ($S_{Ti} \geq 0.10$) fueron, en orden descendente: $J_{max,0}$ y α . Para la variable biomasa estructural (w_G) los parámetros más influyentes fueron, en orden descendente: μ_{max} , θ , $J_{max,0}$, σ y C_{CO2} . Mientras que para la biomasa no estructural (w_S) los parámetros más influyentes fueron: μ_{max} , θ , $J_{max,0}$, C_{CO2} y σ . En total, de los 13 parámetros del modelo matemático, solamente cinco parámetros fueron sensibles: $J_{max,0}$, μ_{max} , α , C_{CO2} y σ . Los parámetros C_{CO2} y σ relacionados con la difusión del CO_2 , presentaron una importancia similar y mucho menor, comparado con los otros tres parámetros restantes.

El índice de sensibilidad de primer orden fue menor que el índice de sensibilidad global total para las tres variables de salida del modelo. Esto indica que existe interacción entre parámetros, y el modelo es no aditivo con respecto a los parámetros. La estimación de los índices de sensibilidad se realizó también para un tamaño de muestra de $N = 5000$, resultando que los parámetros sensibles fueron los mismos y en mismo orden, por lo que se concluye que el tamaño de muestra $N = 3000$ usando en el análisis fue adecuado.




Figura 19. Mediciones promedio de la intensidad de radiación fotosintéticamente activa y temperatura como entradas del modelo dinámico para el experimento 1.




Figura 20. Mediciones promedio de la intensidad de radiación fotosintéticamente activa y temperatura como entradas del modelo dinámico para el experimento 3.




Figura 21. Índices de sensibilidad global para el experimento 3 estimadas con el método de Sobol para los parámetros del modelo de Zhang para las variables de estado: A) nitrógeno acumulado N_{up} , B) biomasa no estructural w_G , y C) biomasa estructural w_S .

Calibración del modelo

De acuerdo con el análisis de sensibilidad global, los parámetros más sensibles y candidatos para ser estimados en un proceso de calibración del modelo matemático fueron: $J_{max,0}$, μ_{max} , α , C_{CO2} y σ . De estos parámetros $J_{max,0}$ y α están relacionados con la absorción de nitrógeno por la planta. Zhang et al. (2008) sugieren que, en la calibración del modelo matemático, primero se calibre los parámetros del submodelo de absorción de nitrógeno ($J_{max,0}$, α , y K) y en un segundo paso, calibrar los parámetros relacionados con la acumulación de materia seca.

Entonces, siguiendo la recomendación de Zhang et al. (2008), se calibraron solamente los dos parámetros $J_{max,0}$ y α , dado que el parámetro K presentó un índice sensibilidad total menor a 0.1. Zhang et al. (2008) encontraron que los parámetros $J_{max,0}$ y α varía a lo largo de año, en función de la radiación solar promedio incidente en el cultivo. Por ello, este trabajo se calibraron estos dos parámetros y no se realizó una evaluación del modelo calibrado con datos independientes.

En el Cuadro 6 se presentan los valores estimados de los parámetros calibrados con los cuatro algoritmos de evolución diferencial. Los valores estimados de los parámetros fueron diferentes para cada experimento, siendo mayores en el experimento 1 comparado con el experimento 3. Esta tendencia es contraria a la encontrada por Zhang et al. (2008), quienes encontraron que los dos parámetros presentaron una correlación positiva con la radiación solar promedio durante el ciclo del cultivo. Esto contrasta con lo encontrada en la calibración, donde los parámetros muestran una correlación negativa con la radiación solar.

Cuadro 6. Parámetros estimados del modelo dinámico para lechuga mediante evolución diferencial.

Parámetro	Algoritmo			
	DE/rand/1/bin	DE/rand/2/bin	DE/best/1/bin	DE/best/2/bin
Experimento1				
$J_{max,0}$	0.0314 (9.56e-11)	0.0314 (1.89e-10)	0.0314 (9.94e-11)	0.0314 (9.96e-11)
α	0.1568 (1.01e-09)	0.1568 (2.68e-09)	0.1568 (8.33e-10)	0.1568 (8.45e-10)
Experimento 3				
$J_{max,0}$	0.0271 (0)	0.0271 (0)	0.0271 (0)	0.0271 (0)
α	0.3674 (0)	0.3674 (0)	0.3674 (0)	0.3674 (0)

[1] El número entre paréntesis es la desviación estándar.

Los valores estimados de los parámetros por los cuatro algoritmos de evolución diferencial fueron los mismos, con diferencias pequeñas en la desviación estándar. Para el experimento 3, esta desviación estándar fue de 0 para los cuatro algoritmos. Por lo tanto, se puede utilizar cualquiera de las cuatro variantes del algoritmo de evolución diferencial para estimar los parámetros del modelo dinámico para lechugas. Se observó diferencias en la tasa de convergencia en los algoritmos (datos no mostrados), resultando que una generación máxima de 150 generaciones fue suficiente para minimizar la función de costo usada en la calibración.

En la Figura 22 se muestra los datos medidos y simulados con el modelo calibrado para las variables nitrógeno absorbido y biomasa, para el experimento 1. Se puede observar que el modelo simula de manera satisfactoria la dinámica de ambas variables, con pequeñas desviaciones a la mitad del ciclo del cultivo, especialmente para el nitrógeno acumulado. Este mismo comportamiento fue observado por Zhang et al. (2008) en la evaluación del modelo.




Figura 22. Acumulación de nitrógeno (N_{up}) y materia seca (w) para lechuga en acuaponía simulado con el modelo calibrado para el experimento 3.




Figura 23. Acumulación de nitrógeno (N_{up}) y materia seca (w) para lechuga en acuaponía simulado con el modelo calibrado para el experimento 3.

En el Cuadro 7 se presentan las estadísticas de la calibración del modelo matemático, obtenidas con el algoritmo de evolución diferencial clásico DE/rand/1/bin. De acuerdo con los índices estadísticos $RRMSE$, AE y EF el modelo calibrado simula de manera satisfactoria la dinámica del nitrógeno acumulado y la biomasa de la lechuga cultivadas en acuaponía.

Cuadro 7. Estadísticas de calibración y validación del modelo dinámico para lechuga con el algoritmo de evolución diferencial clásico DE/rand/1/bin.

Índice estadístico	Experimento 1	Experimento 3
Nitrógeno acumulado (N_{up})		
<i>RRMSE</i>	0.1571	0.1868
<i>MAE</i>	0.9806	0.7613
<i>EF</i>	0.9703	0.9572
Biomasa (w)		
<i>RRMSE</i>	0.1053	0.2000
<i>MAE</i>	0.3005	0.4189
<i>EF</i>	0.9860	0.9347

4.5 Conclusiones

El análisis de sensibilidad global del modelo matemático para lechuga en acuaponía permitió estimar los parámetros más sensibles, que fueron cinco: $J_{max,0}$, μ_{max} , α , C_{CO2} y σ , tres relacionados con la acumulación de biomasa y dos relacionados con la absorción de nitrógeno. Los cuatro algoritmos de evolución diferencial estimaron los mismos valores de los parámetros calibrados $J_{max,0}$ y α , por lo que cualquiera de estos algoritmos permite resolver el problema de optimización planteado para la calibración del modelo matemático. De acuerdo con los índices estadísticos *RRMSE*, *AE* y *EF* el modelo calibrado simula de manera satisfactoria la dinámica del nitrógeno acumulado y la biomasa de la lechuga cultivadas en acuaponía en los dos experimentos. Se cuenta con un modelo matemático para simular la absorción de nitrógeno y acumulación de biomasa para un cultivo de lechuga en acuaponía.

4.6 Referencias

Abbey, M., Anderson, N. O., Yue, C., Schermann, M., Phelps, N., Venturelli, P., & Vickers, Z. (2006). Lettuce (*Lactuca sativa*) production in northern latitudinal aquaponic growing conditions. *HortScience*, 54(10): 1757-1761. doi: 10.21273/HORTSCI14088-19

- Alcántar, G., & Sandoval, M. (1999). Manual de análisis químico de tejido vegetal. Publicación Especial 10. Sociedad Mexicana de la Ciencia del Suelo. Chapingo, México. 125 pp.
- Angulo, C., Rötter, R., Lock, R., Enders, A., Fronzek, S., & Ewert, F. (2013). Implication of crop model calibration strategies for assessing regional impacts of climate change in Europe. *Agricultural and Forest Meteorology*, 170: 32-46. doi: 10.1016/j.agrformet.2012.11.017
- Cariboni, J., Gatelli, D., Liska, R., & Saltelli, A. (2007). The role of sensitivity analysis in ecological modelling. *Ecological Modelling*, 203(1-2): 167-182.
- Das, S., Mullick, S.S., & Suganthan, P.N. (2016). Recent advances in differential evolution - An update survey. *Swarm and Evolutionary Computation* 27: 1-30.
- Fang, G., Lu, Z., and Cheng., L. 2015. A new methodology based on covariance and HDMR for global sensitivity analysis. *Applied Mathematical Modelling*, 39: 5399-5414. doi: 10.1016/j.apm.2015.01.011.
- Gallardo, M., Fernández, M.D., Giménez, C., Padilla, F.M., and Thompson, R.B. 2016. Revised VegSyst model to calculate dry matter production, critical N uptake and ETc of several vegetable species grown in Mediterranean greenhouses. *Agricultural Systems* 146: 30-43.
- He, D., Wang, E., Wang, J., & Robertson, M.J. (2017). Data requirement for effective calibration of process-based crop models. *Agricultural and Forest Meteorology*, 234–235: 136-148. doi: 10.1016/j.agrformet.2016.12.015
- Huan, M., Azwar, E., Yang, Y., Sonne, C., Nai, P., Keey, R., Kui, C., Loke, P., & Shiung, S. (2020). Simultaneous removal of toxic ammonia and lettuce cultivation in aquaponic system using microwave pyrolysis biochar. *Journal of Hazardous Materials*, 396: 45200. doi: 10.1016/j.jhazmat.2020.122610
- Lara-Izaguirre, A.Y., Rojas-Velázquez, A.N., Romero-Méndez, M.J., Ramírez-Tobías, H.M., Cruz-Crespo, E., Alcalá-Jáuregui, J.A., and Loredó-Ostí, C. 2019. Growth and NO₃- accumulation in hydroponic lettuce with nitrate/ammonium ratios in two cultivation seasons. *Revista Fitotecnia Mexicana* 42(1): 21-29.
- Li, Q., Gao, H., Zhang, X., Ni, J., and Mao, H. 2022. Describing lettuce growth using morphological features combined with nonlinear models. *Agronomy* 12:860. doi: 10.3390/agronomy12040860.
- Li, H., Li, W., McEwan, M., Li, D., Lian, G., & Chen, T. (2021). Adaptive filtering-based soft sensor method for estimating nitrogen in aquaponic systems. *Computers and Electronics in Agriculture*, 186: 106175. doi:

10.1016/j.compag.2021.106175

- Lu, Y., Chibarabada, T. P., McCabe, M. F., De Lannoy, J. M., & Sheffield, J. (2021). Global sensitivity analysis of crop yield and transpiration from the FAO-AquaCrop model for dryland environments. *Field Crops Research*, 269: 108182. doi: 10.1016/j.fcr.2021.108182
- Pearson, S., Wheeler, T. R., Hadley, P., & Wheldon, A. E. (1997). A validated model to predict effects of environment on the growth of lettuce (*Lactuca sativa* L.): Implications for climate change. *Journal of Horticultural Science*, 72(4): 503-517. doi: 10.1080/14620316.1997.11515538
- Pianosi, F., Sarrazin, F., & Wagener, T. (2015). A Matlab toolbox for global sensitivity analysis. *Environmental Modelling & Software*, 70: 80-85. doi: 10.1016/j.envsoft.2015.04.009
- Rathnappriya, R.H.K., Sakai, K., Okamoto, K., Kimura, S., Haraguchi, T., Nakandakari, T., Setouchi, H., & Bandara, W.B.M.A.C. (2022). Global sensitivity analysis of key parameters in the APSIMX-Sugarcane model to evaluate nitrate balance via treed gaussian process. *Agronomy*, 12: 1979. doi: 10.3390/agronomy12081979.
- Rodriguez-Fernandez, M., Mendes, P., & Banga, J.R. (2006). A hybrid approach for efficient and robust parameter estimation in biochemical pathways. *BioSystems*, 83: 248-265.
- Seginer, I., Buwalda, F., & van Straten, G. 1998. Nitrate concentration in greenhouse lettuce: a modelling study. *Acta Horticulturae* 456: 189-197.
- Sago, Y., and Shigemura, A. 2018. Quantitative nutrient management reduces nitrate accumulation in hydroponic butterhead lettuces grown under artificial lighting. *HortiScience* 53: 963-967.
- Sweeney, D. J., Hand, D. W., Slack, G. and Thornley, J. H. M. (1981). Modelling the growth of winter lettuce. In: D. A. Rose, & D. A. Charles-Edwards (Eds), *Mathematics and plant physiology in experimental botany* (pp. 217-229). London: Academic Press.
- Varella, H., Guérif, M., & Buis, S. (2010). Global sensitivity analysis measures the quality of parameter estimation: The case of soil parameters and crop model. *Environmental Modelling & Software*, 25: 310-319. doi:10.1016/j.envsoft.2009.09.012
- Van Henten, E. J. (1994). Validation of a dynamic lettuce growth model for greenhouse climate control. *Agricultural Systems*, 45(1): 55-72. doi: 10.1016/S0308-521X(94)90280-1

- Wallach, D., Buis, S., Lecharpentier, P., Bourges, J., Clastre, P., Launay, M., Bergez, J.E., Guerif, M., Soudais, J., & Justes, E. (2011). A package of parameter estimation methods and implementation for the STICS crop-soil model. *Environmental Modelling & Software*, 26(4): 386-394. doi: 10.1016/j.envsoft.2010.09.004.
- Wu, Q.L., & Cournède, P.H., & Mathieu, A. (2012). An efficient computational method for global sensitivity analysis and its application to tree growth modelling. *Reliability Engineering and System Safety*, 107: 35-43.
- Zhang, K., Burns, I.G., & Turner, M.K. 2008. Derivation of a dynamic model of the kinetics of nitrogen uptake throughout the growth of lettuce: Calibration and validation. *Journal of Plant Nutrition*, 31:1440-1460. doi: 10.1080/01904160802208345

5. Conclusiones generales

Este trabajo de investigación logró importantes avances en el desarrollo de un sistema de monitoreo basado en IoT para sistemas acuapónicos, demostrando su efectividad en la gestión y monitoreo de variables fisicoquímicas y ambientales para estimar a través de redes neuronales el oxígeno disuelto. La capacidad del sistema para recopilar datos en tiempo real y transmitirlos a plataformas centralizadas no solo facilitó una mejor toma de decisiones, sino que también permitió optimizar la sostenibilidad y la eficiencia en la producción.

La integración de un modelo matemático dinámico orientado a la predicción del crecimiento y la acumulación de nitrógeno en lechuga aportó un enfoque innovador para simular y comprender el comportamiento del sistema. El análisis de sensibilidad global realizado con el método de Sobol identificó los parámetros críticos que influyen en la variabilidad del modelo, contribuyendo a su calibración y validación. Este modelo no solo permitió simular el sistema con precisión, sino que también sentó las bases para un manejo más eficiente de los recursos en futuras aplicaciones.

El uso de tecnologías IoT destacó como una solución práctica para superar las limitaciones tradicionales en el monitoreo y control de sistemas acuapónicos,

reduciendo los costos operativos y mejorando la precisión en la supervisión de variables. Este enfoque también contribuyó a disminuir la dependencia de insumos químicos al aprovechar eficientemente los nutrientes generados dentro del sistema, favoreciendo la sostenibilidad ambiental y posicionando la acuaponía como una alternativa viable ante los desafíos globales de seguridad alimentaria y cambio climático.

Los resultados obtenidos no solo validan la importancia de integrar tecnologías avanzadas y herramientas matemáticas en la agricultura moderna, sino que también establecen un marco útil para el diseño de sistemas agrícolas más sostenibles y adaptables. Este estudio ofrece un punto de partida sólido para continuar investigando y perfeccionando estrategias que combinen eficiencia, sostenibilidad y escalabilidad, respondiendo a las necesidades de un entorno cada vez más exigente.