



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MEXICO



INSTITUTO TECNOLÓGICO DE LA PAZ
DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN
MAESTRÍA EN SISTEMAS COMPUTACIONALES

AUTOMATIZACIÓN DE UN SISTEMA DE RIEGO DE CULTIVO AEROPÓNICO APLICANDO UN ENFOQUE DE CONTROL INTELIGENTE

TESIS

QUE PARA OBTENER EL GRADO DE
MAESTRO EN SISTEMAS COMPUTACIONALES

PRESENTA:
JESÚS GUILLERMO BERMÚDEZ ROJAS

DIRECTORES DE TESIS:
M.C. JORGE ENRIQUE LUNA TAYLOR
DR. FERNANDO DANIEL VON BORSTEL LUNA

LA PAZ, BAJA CALIFORNIA SUR, MÉXICO, AGOSTO 2024.

La Paz, B.C.S., **12/ AGOSTO /2024**

DEPI/150/2024

ASUNTO: Autorización de impresión

**C. JESÚS GUILLERMO BERMÚDEZ ROJAS,
ESTUDIANTE DE LA MAESTRÍA EN
SISTEMAS COMPUTACIONALES,
P R E S E N T E .**

Con base en el dictamen de aprobación emitido por el Comité Tutorial de la Tesis denominada: **“AUTOMATIZACIÓN DE UN SISTEMA DE RIEGO DE CULTIVO AEROPÓNICO APLICANDO UN ENFOQUE DE CONTROL INTELIGENTE”**, mediante la opción de tesis (Proyectos de Investigación), entregado por usted para su análisis, le informamos que se **AUTORIZA** la impresión.

ATENTAMENTE
Excelencia en Educación Tecnológica®

**JUDITH GUADALUPE MARTÍNEZ TIRADO,
JEFA DE LA DIV. DE ESTUDIOS DE POSGRADO E INV.**



c.c.p. Depto. de Servicios Escolares
c.c.p. Archivo.

JGMT/icl*



Boulevard de B.C.S. #4720, Col. 8 de octubre 1ra Sección, C.P. 23080, La Paz,
B.C.S. Tel. (612) 12 1-04-24 e-mail: depi_paz@tecnm.mx | www.lapaz.tecnm.mx





DICTAMEN DEL COMITÉ TUTORIAL

La Paz, B.C.S., **09/AGOSTO/ 2024**

**JUDITH GUADALUPE MARTÍNEZ TIRADO,
JEFA DE LA DIVISIÓN DE ESTUDIOS DE
POSGRADO E INVESTIGACIÓN,
P R E S E N T E.**

Por medio del presente, enviamos a usted dictamen del Comité Tutorial de tesis para la obtención del grado de Maestro, con los siguientes datos generales:

No. de Control M22310001	Nombre JESÚS GUILLERMO BERMÚDEZ ROJAS
Maestría en:	SISTEMAS COMPUTACIONALES
Título de la tesis: AUTOMATIZACIÓN DE UN SISTEMA DE RIEGO DE CULTIVO AEROPÓNICO APLICANDO UN ENFOQUE DE CONTROL INTELIGENTE	
DICTAMEN: Se autoriza el trabajo de investigación, en virtud de que realizó las correcciones correspondientes conforme a las observaciones planteadas por este Comité Tutorial.	

**Atentamente.
El Comité Tutorial**

DR. FERNANDO VON BORSTEL LUNA

DR. JESÚS ALBERTO SANDOVAL GALARZA

M.C. JORGE ENRIQUE LUNA TAYLOR

c.c.p. Coordinador de la Maestría.
c.c.p. Departamento de Servicios Escolares.
c.c.p. Estudiante.

ITLP-DEPI-RTT-08

Rev.1



Boulevard Forjadores de B.C.S. #4720, Col. 8 de octubre 1ra Sección, C.P. 23080, La Paz,
B.C.S. Tel. (612) 12 1-04-24 e-mail: depi_paz@tecnm.mx | www.lapaz.tecnm.mx



Dedicatoria

Quisiera dedicar esta tesis a todos aquellos que me apoyaron y motivaron significativamente durante este proceso. A mis padres, quienes me brindaron las facilidades y el tiempo para poder investigar; a mi hermana, que a pesar de la distancia siempre me alentó a seguir adelante; a mi novia, que estuvo a mi lado en los momentos más difíciles y nunca me dejó caer; a mis tíos, que depositaron su vocación científica en mí.

Agradecimientos

Quisiera dedicar un especial agradecimiento al CONACYT, por su invaluable apoyo, que me permitió solventar mis gastos y dedicarme por completo a mis estudios de maestría. Un agradecimiento a mis maestros, quienes me ayudaron a progresar correctamente y transmitieron su conocimiento, a los miembros del comité de tesis, al Maestro Jorge Enrique Luna Taylor, al Doctor Fernando Von Borstel Luna y al Doctor Jesús Alberto Sandoval Galarza, que se mantuvieron atentos a mi progreso, motivándome a seguir adelante. Al Técnico Miguel Díaz Ramírez del Programa de Agricultura de Zonas Áridas del CIBNOR La Paz, por su apoyo en la elaboración de experimentos y en brindar información práctica para el cultivo de lechuga.

Resumen

Dada la escasez de agua y la degradación de los suelos de cultivo, la agricultura en México enfrenta importantes desafíos para poder cubrir la creciente demanda de alimentación en el país. Una solución potencial para abordar esta problemática, es la implementación de técnicas agrícolas modernas, como la aeroponía, que hace un uso más eficiente del agua y puede ser desarrollada en invernaderos adaptados para producir durante todas las estaciones del año. Sin embargo, la implementación de esta técnica de cultivo es difícil de controlar de manera precisa para obtener un rendimiento óptimo de cultivo. Para atender este problema, se requiere de sistemas de control inteligentes que permitan, además del desarrollo adecuado de las plantas, un uso más eficiente de los insumos agrícolas necesarios para el cultivo.

En este trabajo de tesis se propone un sistema de control de riego basado en técnicas de la Inteligencia Artificial, para el cultivo tipo aeropónico de la lechuga romana. Este consiste en un Sistema Difuso que determina la frecuencia y el tiempo de riego, basado en la temperatura y humedad del entorno aeropónico, y en el nivel de estrés hídrico de las plantas inferido por una Red Neuronal Convolucional. Para esto, se generó una base de datos de imágenes de las plantas en diferentes niveles de estrés hídrico, con la cual se entrenó el modelo de red neuronal.

Los experimentos con el modelo de red generado muestran una precisión y sensibilidad superior al 94% en la inferencia del nivel de estrés hídrico real de las plantas. En cuanto a las pruebas del sistema de control difuso, se realizaron experimentos con diferentes condiciones de temperaturas. Bajo temperaturas idóneas para la lechuga romana, el sistema mantuvo condiciones de humedad adecuadas para las plantas, requiriendo únicamente 14 segundos de riego por hora, equivalente al 0.4% del tiempo que duró el experimento. Bajo condiciones de temperaturas extremas para la lechuga romana cercanas a los 28 °C, el sistema reaccionó incrementando el tiempo de riego a 6.6 minutos por hora, logrando mantener estables las condiciones de estrés y de humedad de las plantas.

Abstract

Given the scarcity of water and the degradation of crop soils, agriculture in Mexico faces relevant challenges in meeting growing demand for food in the country. A potential solution to address this problem is the implementation of modern agricultural techniques, such as aeroponics, which makes more efficient use of water and can be developed in greenhouses adapted to produce during all seasons of the year. However, implementing this crop technique is difficult to control precisely to obtain optimal culture yield. For this, intelligent control systems are required to allow, in addition to the proper development of the plants, a more efficient use of the agricultural inputs necessary for cultivation.

An irrigation control system is proposed based on Artificial Intelligence techniques for aeroponic cultivation of romaine lettuce. It consists of a Fuzzy System that determines the frequency and time of irrigation based on the temperature and humidity of the aeroponic environment and the level of water stress of the plants inferred by a Convolutional Neural Network. For this, a images database of plants at different levels of water stress was generated, with which the neural network model was trained.

Experiments with the neural network show an accuracy and sensitivity of the model above 94% in correctly inferring the level of plants water stress. Regarding the tests of the fuzzy control system, there were carried out with different temperature conditions. Under ideal temperatures for romaine lettuce, the system maintained adequate humidity conditions for the plants, requiring only 14 seconds of irrigation for each hour of control, equivalent to 0.4% of the time the experiment lasted. Under extreme temperature conditions for romaine lettuce close to 28 °C, the system reacted by increasing the irrigation time to 6.6 minutes per hour, managing to keep the stress and humidity conditions of the plants stable.

Índice general

Índice general	VII
Índice de figuras	IX
Índice de tablas	XI
1. Introducción	1
1. 1. Antecedentes	1
1. 2. Descripción del problema	3
1. 3. Hipótesis	3
1. 4. Objetivos	4
1. 4.1. Objetivo general	4
1. 4.2. Objetivos específicos	4
1. 5. Justificación	4
1. 6. Alcance y limitaciones	5
2. Marco teórico	6
2. 1. Trabajos previos	6
2. 2. Aeroponía	12
2. 3. Lechuga	13
2. 4. Control Inteligente	14
2. 5. Redes Neuronales Artificiales (ANN)	15
2. 6. Redes Neuronales Convolucionales (CNN)	18
2. 7. Sistemas Difusos	20

3. Metodología	21
3. 1. Prototipo del sistema aeropónico	22
3. 2. Implementación del sistema de riego	25
3. 3. Cultivo de las plantas de lechuga romana	27
3. 4. Generación de la base de datos de imágenes	29
3. 5. Arquitectura y entrenamiento de la CNN	33
3. 6. Sistema Difuso para el control de riego aeropónico	37
3. 6.1. Conjuntos difusos de las variables de entrada	37
3. 6.2. Conjuntos difusos para las variables de salida	40
3. 6.3. Reglas de inferencia difusas	42
4. Resultados	44
4. 1. Resultados de las pruebas de inferencia del nivel de estrés hídrico de las plantas a través de la CNN.	44
4. 1.1. Experimentos con el primer modelo de CNN	44
4. 1.2. Experimentos con el segundo modelo de CNN.	47
4. 2. Resultados de las pruebas de control de riego aeropónico a través del Sistema Difuso.	49
4. 2.1. Experimentos en un ambiente controlado con temperatura idónea para la lechuga romana.	49
4. 2.2. Experimentos en un ambiente controlado con temperatura alta extrema para la lechuga romana.	51
4. 2.3. Experimentos en el exterior sin control de la temperatura ambiente.	52
5. Conclusiones y trabajo futuro	55
5. 1. Conclusiones	55
5. 2. Trabajo futuro	56
Bibliografía	57

Índice de figuras

2.1. Mapeo y resaltado de zonas infectadas en cítricos.	8
2.2. Mapeo y resaltado de zonas dañadas en hojas.	8
2.3. Ejemplos de imágenes de hojas con diferentes tipos de enfermedades.	9
2.4. Secuencia de procesamiento aplicado para obtener la segmentación de una planta.	10
2.5. Tubo para sistema de cultivo aeropónico en vertical.	10
2.6. Tubo para sistema de cultivo aeropónico en horizontal.	11
2.7. Diagrama de bloques de un sistema aeropónico recirculante de baja presión.	11
2.8. Ejemplo de siembra en tubos de cultivo aeropónico.	12
2.9. Imágenes de plantas de Lechuga Romana.	13
2.10. Representación de la estructura típica de una Red Neuronal.	15
2.11. Representación de la función de propagación aplicando la bias y una función de activación.	16
2.12. Representación del error o costo de entrenamiento y el efecto de ajustar los pesos de la red para minimizar el error, a través del método del descenso del gradiente.	18
2.13. Representación de la estructura de una CNN para segmentación de imágenes.	19
2.14. Representación de la estructura de una CNN para clasificación de imágenes.	19
2.15. Representación de diferentes funciones de pertenencia para la definición de conjuntos difusos.	20
3.1. Diagrama de bloque del sistema de control de riego propuesto.	21
3.2. Etapas del desarrollo del proyecto	22
3.3. Prototipo de tubo de cultivo aeropónico para la lechuga romana	23
3.4. Aspersor de regado colocado al interior del tubo de riego.	24
3.5. Conexión de mangueras	24

3.6. Prototipo del sistema de cultivo aeropónico dentro del invernadero.	25
3.7. Sistema gestor de encendido y apagado de las válvulas.	26
3.8. Bomba de agua de membrana para el riego.	26
3.9. Charola germinadora de plántulas de lechuga romana.	27
3.10. Luz artificial utilizada para el desarrollo de las plántulas.	28
3.11. Trasplante de las plantas de lechuga romana al tubo aeropónico.	29
3.12. Escenario montado para adquisición de imágenes de la lechuga romana.	31
3.13. Interfaz para la adquisición de imágenes	31
3.14. Imágenes de plantas de lechuga romana en los cinco niveles (0-4) de estrés hídrico.	32
3.15. Arquitectura de la CNN utilizada para inferencia del nivel de estrés hídrico.	34
3.16. Conjuntos difusos para la variable de entrada “Temperatura”.	38
3.17. Conjuntos difusos para la variable de entrada “Nivel de Estrés Hídrico”.	39
3.18. Conjuntos difusos para la variable de entrada “Humedad”.	40
3.19. Conjuntos difusos para la variable de salida “Riego”.	41
3.20. Conjuntos difusos para la variable de salida “Tiempo de Riego”.	42
4.1. Mapa de calor Etapa uno	45
4.2. Mapa de calor de las pruebas de inferencia de estrés hídrico con el segundo modelo CNN.	48
4.3. Resultados de las pruebas de control de riego difuso en un ambiente controlado con temperatura ideal para la lechuga romana.	50
4.4. Resultados de las pruebas de control de riego difuso en un ambiente controlado con temperatura alta extrema para la lechuga romana.	52
4.5. Resultados de las pruebas de control de riego difuso en el exterior sin control de la temperatura ambiente.	53

Índice de tablas

3.1. Intervalos de horas después del último riego considerado para cada nivel de estrés hídrico para la primera base de datos de imágenes.	32
3.2. Intervalos de horas después del último riego considerado para cada nivel de estrés hídrico para la segunda base de datos de imágenes.	33
3.3. Distribución de imágenes de entrenamiento por nivel de estrés hídrico para el primer modelo de red.	35
3.4. Distribución de imágenes de entrenamiento por nivel de estrés hídrico para el segundo modelo de red.	35
3.5. Parámetros de entrenamiento de la CNN para inferencia de estrés hídrico.	37
3.6. Equipo de cómputo utilizado para el entrenamiento de la CNN.	37
3.7. Definición de las reglas de inferencia del sistema difuso	43
4.1. Distribución de imágenes de prueba por nivel de estrés hídrico para el primer modelo CNN.	45
4.2. Estadísticas de inferencia del nivel de estrés hídrico con el primer modelo CNN.	46
4.3. Estadísticas de inferencia del nivel de estrés hídrico con una tolerancia de un nivel con el primer modelo CNN.	47
4.4. Distribución de imágenes de prueba por nivel de estrés hídrico para el segundo modelo CNN.	47
4.5. Estadística de las pruebas de inferencia de estrés hídrico de las plantas de lechuga romana para el segundo modelo CNN.	48

Capítulo 1

Introducción

1. 1. Antecedentes

La desertificación es un problema a nivel global, causado por diversos factores climáticos y la actividad humana. Es un proceso de degradación del suelo donde poco a poco se van perdiendo tierras fértiles para cultivar alimentos. En México, la desertificación afecta a más del 92% del territorio, abarcando gran parte del norte y centro del país. Si bien la causa de este problema va más allá de la sobreexplotación del agua, de no tomar medidas al respecto, las consecuencias serán la falta de agua potable en un futuro (CONAFOR et al., 2013). Por ejemplo, la agricultura intensiva y la utilización de fertilizantes son actividades humanas que decrementan la capacidad del suelo para capturar nutrientes, disminuyendo las tierras fértiles. Aún más, debido a la intensa actividad agrícola que utiliza fertilizantes y productos fitosanitarios, se ha incrementado la producción y utilización de estos químicos, lo que produce contaminación del aire, suelo y agua (Fasciolo et al., 2023).

Siendo el agua y el suelo insumos agrícolas importantes, una propuesta para disminuir esta problemática es lograr un mejor control del uso de agua en los cultivos, evitando la evaporación excesiva, el riego continuo y desmedido, así como el creciente uso de agroquímicos contaminantes. Para esto, se han desarrollado nuevas técnicas de siembra como la hidroponía y la aeroponía, con las que se logra un ahorro sustancial de agua en los cultivos y una disminución en el uso de agroquímicos, además de no utilizar el suelo como sustrato para las plantas. Estudios recientes muestran que los sistemas aeropónicos logran un mayor aprovechamiento del agua en comparación con la hidroponía (Prieto, 2021). Asimismo, la NASA ha demostrado que la

aeroponía puede reducir el uso de agua en hasta un 98 %, el uso de fertilizantes en un 60 %, y el uso de pesticidas en un 100 %, incrementando la producción de los cultivos (Priyanka et al., 2020).

Los sistemas aeropónicos permiten cultivar plantas sin suelo en estructuras de soporte donde la raíz queda expuesta y suspendida en el aire en una cámara cerrada. Estos sistemas se basan en el rociado intermitente de agua con nutrientes directamente sobre la raíz de las plantas. La frecuencia del rociado de solución nutritiva sobre las raíces depende de muchos factores para funcionar de manera óptima. Esta frecuencia depende de la etapa de crecimiento de las plantas, grado de deshidratación, nivel de humedad, temperatura, pH, iluminación, nutrientes, etc. (Andrade-Piedra et al., 2015). Los sistemas aeropónicos tienen más ventajas que los hidropónicos en términos de rociar alto contenido de aire junto con la solución nutritiva para proveer oxígeno a las raíces de las plantas, estimulando el crecimiento, y ayudando en la prevención de la formación de patógenos (Idris and Sani, 2012). Asimismo, se tiene un completo control de la concentración y administración de nutrientes sobre las raíces de las plantas, lo que permite prevenir infecciones y enfermedades que provienen del suelo, lo que implica una mayor producción y un uso eficiente del agua e insumos agrícolas (Lakhiar et al., 2018).

En este contexto, la aeroponía es considerada como una técnica de cultivo adecuada para la seguridad alimentaria y la sustentabilidad; sin embargo, enfrenta diversos problemas y desafíos asociados con el crecimiento de las plantas, y que incluyen la prevención de posibles fallas en el sistema de irrigación, el control de la irrigación y el monitoreo de parámetros fisicoquímicos, la definición de la frecuencia y el tiempo de rocío, entre otras. Estos problemas y desafíos pueden ser atendidos utilizando técnicas modernas de automatización con inteligencia artificial. Dos de estas técnicas son el aprendizaje profundo y los sistemas difusos, técnicas que pueden ser combinadas y utilizadas para optimizar el rendimiento de los sistemas aeropónicos.

La implementación de modelos de redes neuronales convolucionales y control difuso, pueden mejorar la eficiencia de los sistemas aeropónicos, mediante el monitoreo continuo de sensores y cámaras para analizar y detectar signos de deterioro en la salud de las plantas, pudiendo clasificarlos en niveles que permitan definir y ejecutar las acciones pertinentes para cada nivel, mediante el ajuste automatizado de los parámetros asociados al control de la irrigación.

Por lo que en este proyecto se propone el diseño de un sistema basado en técnicas de control inteligente, para determinar la frecuencia y el tiempo de rociado de un sistema aeropónico,

utilizando información de sensores de humedad y temperatura. Para este control, también se considera el nivel de estrés hídrico de las plantas, inferido a través de métodos de aprendizaje profundo, a partir del análisis de imágenes de las plantas tomadas en tiempo real.

1. 2. Descripción del problema

La escasez de agua y el espacio de siembra, así como la degradación de los suelos propicios para la producción de alimentos, son las principales limitaciones para un buen desarrollo de la agricultura a nivel mundial (FAO, 2023). La agricultura protegida en ambientes controlados, como los sistemas de cultivo tipo aeropónicos, han sido propuestos como una solución a esta problemática. Sin embargo, la implementación de este tipo de cultivos es difícil de controlar manualmente y regularmente conlleva un alto consumo energético. Para esto, se requiere de sistemas de control que permitan, además del desarrollo adecuado de las plantas, un uso más eficiente de los recursos.

A pesar de que en la localidad se han desarrollado esfuerzos importantes por implementar sistemas de control de riego autónomos para el cultivo aeropónico, por parte de investigadores del CIBNOR, aún quedan algunos retos por superar, como la implementación de un sistema capaz de responder de forma autónoma de acuerdo a las condiciones de humedad y temperatura del entorno en el que se encuentran las plantas, además de prescindir del monitoreo presencial por parte del personal para identificar las condiciones de estrés de las plantas, requerido para determinar las acciones de control de riego correspondientes.

1. 3. Hipótesis

La aplicación de modelos de control inteligente que tomen en cuenta la información adquirida por sensores e imágenes de las plantas, para analizar y detectar signos de deshidratación, clasificándolos en niveles de estrés que permitan definir y ajustar los parámetros asociados a la irrigación automática de las plantas, pueden mejorar la eficiencia de un sistema aeropónico para el cultivo de lechuga romana.

1. 4. Objetivos

1. 4.1. Objetivo general

Diseñar e implementar un sistema de control inteligente para la automatización de un modelo de riego aeropónico para la lechuga romana.

1. 4.2. Objetivos específicos

1. Crear un sistema aeropónico vertical para el cultivo de plantas de lechuga romana.
2. Generar una base de datos de imágenes de plantas de lechuga romana en diferentes niveles de estrés hídrico.
3. Inferir el nivel de estrés hídrico de las plantas a través de imágenes aplicando métodos de aprendizaje profundo.
4. Diseñar e implementar un sistema difuso para el control automático de riego aeropónico, basado en información de sensores de temperatura, humedad e imágenes de las plantas.
5. Evaluar el desempeño del sistema de control a partir de datos obtenidos durante su funcionamiento en tiempo real.

1. 5. Justificación

El gasto desmedido del agua y su consecuente escasez es un problema que ha crecido con el paso de los años. Uno de los mayores desperdicios de agua a nivel mundial se tiene en la agricultura tradicional, en esta el agua es arrojada a los campos de siembra donde las plantas aprovechan un bajo porcentaje del agua regada y la gran mayoría de esta se pierde por evaporación y filtración.

Una propuesta para abordar esta problemática es la aplicación de sistemas de cultivos más eficientes en el uso del agua e incluso del espacio de siembra. Ejemplos de este tipo de cultivos son la hidroponía y la aeroponía. Estudios recientes han mostrado que la aeroponía es aún más eficiente en el uso del agua que la hidroponía, sin embargo, la implementación de este tipo de sistemas sigue siendo costosa y difícil de controlar de forma manual (Valdivia, 2010). Estas

propuestas tratan directamente con el problema del desabasto del agua, sin embargo no se llega a considerar el alto consumo eléctrico que es posible generar con los sistemas de monitoreo y de control que se suelen utilizar.

Uno de los retos en los sistemas de cultivo aeropónicos es controlar de forma óptima los intervalos y cantidades de riego de las plantas. Un mal control del riego puede llegar a provocar que las plantas se pudran por exceso de agua o se deshidraten por la falta de esta.

En este proyecto se propone construir un sistema de control automatizado de bajo costo, para abordar esta problemática. En esta propuesta se consideran las variables de humedad, temperatura y aspectos visibles que presentan las plantas como variables de entrada, con la intención de lograr un buen control del sistema de irrigación. Con este trabajo se pretende contribuir en el desarrollo de este tipo de sistemas de cultivo a nivel regional y nacional.

1. 6. Alcance y limitaciones

Para el desarrollo de este proyecto es necesario contar con una base de datos con suficientes imágenes de las plantas en diferentes niveles de estrés hídrico. Debido a la escasa cantidad de imágenes e información encontrada en la literatura, es necesario crear una base de datos propia. Para crear esta base de datos y para realizar las pruebas del sistema propuesto, es necesario construir un prototipo de cultivo aeropónico que corresponda al entorno y condiciones reales de este tipo de sistemas. El sistema debe incluir los sensores para monitorear la temperatura y la humedad del ambiente donde se encuentran las plantas, así como obtener las imágenes de las plantas para detectar su grado de deshidratación. Con esta información, el sistema determinará la cantidad de riego para las plantas en el momento de tomar los datos.

Los periodos recomendables para la siembra de la lechuga romana son durante el otoño e invierno, ya que las bajas temperaturas y la escasa lluvia favorecen a este tipo de plantas. Por lo que los experimentos realizados en otras fechas del año se realizarán en un entorno con temperatura e iluminación controlada. Además, dado que los tiempos de riego y otras condiciones varían significativamente entre familias de plantas, los experimentos y los resultados obtenidos en este proyecto aplicarán únicamente para la lechuga romana.

Capítulo 2

Marco teórico

2. 1. Trabajos previos

Atendiendo la problemática del uso del agua en los campos de cultivo, en el Centro de Investigaciones Biológicas del Noroeste (CIBNOR) se diseñó un sistema aeropónico de bajo costo, con una distribución vertical con capacidad de 24 plantas (Márquez, 2020). Se diseñó e implementó un sistema automatizado para realizar una amplia caracterización del sistema bajo diferentes condiciones. Para esto, se consideraron como variables más relevantes medir la temperatura, la humedad, la iluminación, la conductividad eléctrica y el pH, e incluyeron como elementos controlables la activación de las bombas de agua y la temperatura. Para el control del sistema, se desarrolló un módulo electrónico de irrigación programable utilizando tarjetas comerciales, con teclado y pantalla LCD, que permite configurar las irrigaciones de forma inmediata y amigable para el usuario, con un amplio espectro de configuración del temporizador.

Por otro lado, existe un gran número de trabajos que utilizan técnicas de visión artificial y/o métodos de aprendizaje máquina, para atender diferentes problemáticas en los sistemas de cultivo. Por ejemplo, en (Sharif et al., 2018) se aplicó un método híbrido de visión computacional y procesamiento de imágenes para la detección y clasificación de enfermedades en los frutos y hojas de plantas de cítricos. En (Tian et al., 2019) se propuso un sistema de identificación de enfermedades en las hojas de plantas de tomate mediante la segmentación de imágenes utilizando un algoritmo K-means adaptativo.

Asimismo, se han presentado diversas propuestas motivadas por los recientes desarrollos en aprendizaje profundo, que utilizan las redes neuronales convolucionales (CNN, por su abreviatu-

ra en inglés) para realizar una clasificación precisa de enfermedades y plagas mediante imágenes. Por ejemplo, en (Arsenovic et al., 2019) se propone un modelo de CNN para detectar enfermedades en los árboles de manzana a través del análisis de imágenes de sus hojas. Con este modelo de red se obtuvo una precisión del 98.54%. En el mismo, se presentan las limitaciones y deficiencias de los recientes modelos propuestos para la detección de enfermedades en las hojas de árboles, además de una gran base de datos con imágenes de hojas con diferentes características, realizada con métodos tradicionales y de vanguardia, para aumentar el número de imágenes. Un método de entrenamiento de dos fases para una pequeña CNN diseñada para dispositivos móviles fue propuesto en (Rahman et al., 2020) para realizar la identificación de enfermedades y plagas en plantas de arroz, con una precisión del 93.3%. Finalmente, una reciente revisión del estado del arte en cuanto a trabajos de investigación que utilizan técnicas de procesamiento de imágenes y aprendizaje automático para la detección automática de enfermedades y plagas en cultivos agrícolas es descrita en (Ngugi et al., 2020). Como se puede observar, la mayoría de los trabajos relacionados que utilizan CNN para la identificación de problemas en las plantas, se han desarrollado enfocados hacia la detección de enfermedades y plagas.

Existen otros trabajos relacionados con el estrés de las plantas por la falta de agua. Por ejemplo, en (Concepcion II et al., 2020) se realizó un estudio que integró visión computacional y aprendizaje automático utilizando una red neuronal recurrente optimizada para detectar el contenido de humedad y el espesor de agua equivalente como medidas del estrés por falta de agua en hojas de plantas de lechuga, cultivadas en un sistema acuapónico. En (Kamarudin and Ismail, 2022) se propone un modelo ligero adecuado para dispositivos móviles, que puede ser aplicado en el campo para detectar las plantas estresadas por la falta de agua debido a la sequía, llegando hasta una precisión de 88.12% y 88.97% en imágenes con luz visible y cercano al infrarrojo, respectivamente. Asimismo, en (Aversano et al., 2022) se describe un modelo para la clasificación plantas de tomate con estrés por agua, utilizando imágenes térmicas y ópticas capturadas por un vehículo aéreo autónomo. Cabe mencionar, que estos dos últimos trabajos utilizan imágenes con diferentes espectros de luz, obtenidas de bases de datos reconocidas o capturadas de manera aérea en campos de cultivo agrícolas tradicionales.

Los resultados con el uso de técnicas de aprendizaje automático para el análisis del estado de las plantas es muy variado. Por ejemplo, en (Hasan et al., 2020) presentan una amplia revisión de métodos para el reconocimiento de enfermedades en plantas y frutas. En las Figuras 2.1 y

2.2 se muestran ejemplos de imágenes de cítricos y hojas con la identificación y resaltado de zonas dañadas. Los mejores resultados en el reconocimiento de las enfermedades se obtuvieron con máquinas de vectores de soporte (MVS) y con CNN. La diferencia entre ambas técnicas fue mínima, pero las CNN presentaron una mayor sencillez de implementación.



Figura 2.1: Mapeo y resaltado de zonas infectadas en cítricos. Fuente: (Hasan et al., 2020).




Figura 2.2: Mapeo y resaltado de zonas dañadas en hojas. Fuente: (Hasan et al., 2020).

En (Chowdhury et al., 2021) se realiza el reconocimiento y clasificación de diferentes enfermedades de plantas utilizando CNN. La red que se utilizó fue *EfficientNet*, la cual se seleccionó entre los mejores resultados de redes previamente probadas. Esta se modificó en sus capas externas para obtener un alto porcentaje de aciertos. Las imágenes tuvieron un tratamiento previo para ajustar el tamaño y la calidad, utilizando más de 18,000 imágenes de entrenamiento y 10 subclases de clasificación. En la Figura 2.3 se muestran ejemplos de las imágenes utilizadas.

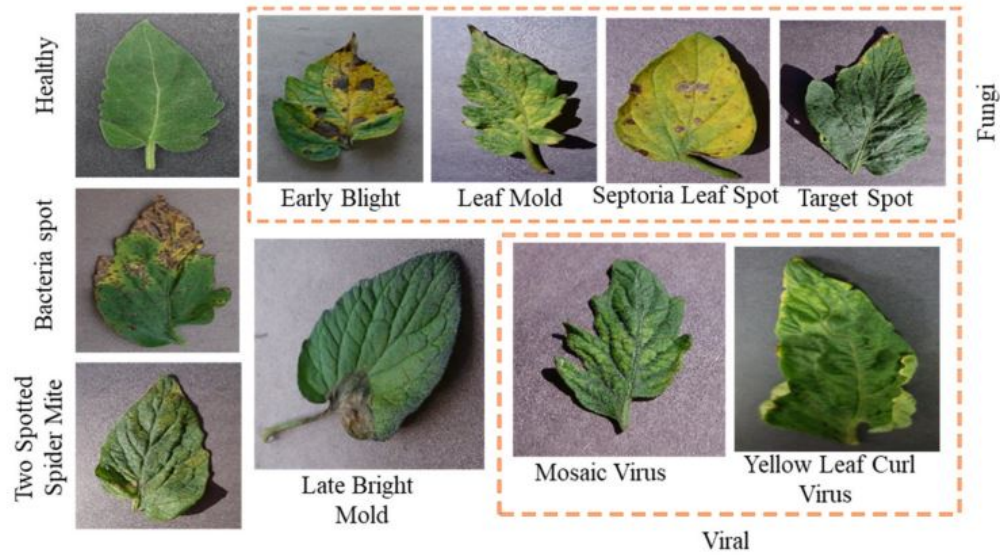


Figura 2.3: Ejemplos de imágenes de hojas con diferentes tipos de enfermedades. Fuente: (Chowdhury et al., 2021).

Por otro lado, existen diferentes propuestas para detectar formas y niveles de color en las hojas en diferentes plantas debido a la necesidad de humedad u otro tipo de estrés que puedan experimentar. Por ejemplo, en (Concepcion II et al., 2020) se estima el estrés por falta de agua en hojas de lechuga, basado en características termo-visibles usando redes neuronales recurrentes optimizadas por estrategias evolutivas. Se estudia el grado de deshidratación que pueden experimentar las lechugas, entrenando una red neuronal con imágenes de laboratorio de plantas con diferentes formas y texturas. En la Figura 2.4 se muestra una imagen de la secuencia de procesamiento que aplicaron para obtener la segmentación de las plantas.

Aunque el sistema de cultivo aeropónico es relativamente nuevo, existen trabajos en la literatura donde presentan propuestas de diseño de las estructuras físicas para la siembra, estas pueden ser verticales (ver Figura 2.5) u horizontales (ver Figura 2.6). Así mismo, se encuentran en la literatura algunas propuestas para el control automatizado para este tipo de cultivo.




Figura 2.4: Secuencia de procesamiento aplicado para obtener la segmentación de una planta.
 Fuente: (Concepcion II et al., 2020).



Figura 2.5: Tubo para sistema de cultivo aerónico en vertical.



Figura 2.6: Tubo para sistema de cultivo aeropónico en horizontal.

Por ejemplo, en (Márquez, 2020) presentan el diseño y caracterización de un sistema aeropónico recirculante de baja presión para el cultivo de *Stevia Rebaudiana*. Con este fin, se desarrolló un sistema automático de irrigación y módulos de medición de variables abióticas utilizando software y hardware libre. En la Figura 2.5 se muestra el diagrama de bloques del sistema propuesto.

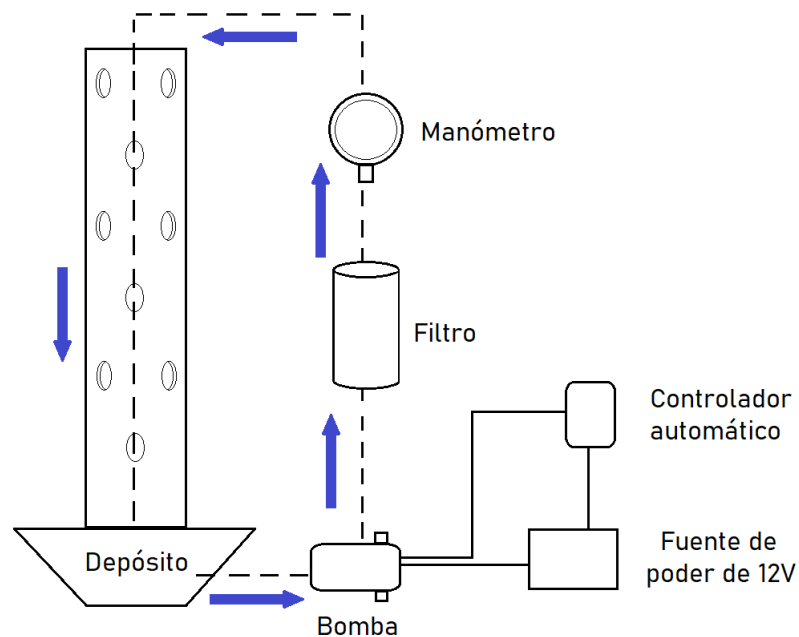


Figura 2.7: Diagrama de bloques de un sistema aeropónico recirculante de baja presión. Fuente: (Márquez, 2020).

Por otro lado, se han propuesto sistemas automatizados aeropónicos basados en tarjetas de desarrollo embebidas de bajo costo y software libre, como es la plataforma Arduino (Montoya

et al., 2017), (Lucero et al., 2020). Otros en la plataforma Raspberry Pi (Mithunesh et al., 2015), (Kerns and Lee, 2017), las cuales permiten desarrollar sistemas combinados con dispositivos actuadores y sensores con tecnología basada en Internet de las Cosas (IoT, por su abreviatura en inglés). Ambas plataformas ofrecen recursos limitados de cómputo y memoria. Sin embargo, al ser la plataforma Raspberry Pi un ordenador monoplaca con un sistema operativo basado en GNU/Linux, junto con su cámara para la captura de imágenes, permite la implementación de CNN ligeras que se pueden aplicar en tareas de clasificación de imágenes en tiempo real.

2. 2. Aeroponía

La aeroponía nació en Italia en la Universidad de Pia, propuesta por el Dr. Franco Massantini, quien diseñó los primeros tubos de cultivo aeropónico, con los cuales inició su investigación. Este es un sistema de riego donde no se requiere de suelo fértil para sembrar las plantas. La manera en la que se siembra es comúnmente en un entorno cerrado, en el cual se mantiene un nivel de humedad y temperatura estables. Las plantas se colocan en tubos con un diseño especial (ver Figura 2.8), dentro de los cuales se rocía una solución nutritiva a las raíces, principalmente por medio de aspersores o nebulizadores. Las ventajas de este medio de cultivo es su escalabilidad, su alta eficiencia y mayor rendimiento por área de cultivo que los cultivos tradicionales. Las desventajas es su alto costo de instalación y exigencias de calidad.



Figura 2.8: Ejemplo de siembra en tubos de cultivo aeropónico.

Este tipo de cultivo consta de tubos con orificios o canastillas donde se colocan las plántulas,

dejando colgar la raíz hacia el interior de este. Al ser un sistema sellado este permite conservar la humedad y la temperatura dentro de él. En el interior del tubo se colocan aspersores, nebulizadores o pulverizadores de agua. Estos suministran el líquido directamente a la raíz de una plántula y aplican una solución rica en nutrientes constantemente. Este sustrato contiene los componentes necesarios para poder alimentar a la planta durante su etapa de crecimiento. Al no tener competencia por los nutrientes, las plantas se desarrollan mejor que en cultivos tradicionales (Morales, 2015).

2. 3. Lechuga

La lechuga, de nombre científico *Lactuca sativa*, es una hortaliza de grandes hojas que se caracteriza por su alto nivel de agua y cantidad de vitaminas. De la familia asteráceas y del género lactuca, se dividen en 2 grandes ramas, Romana y Arrepollada. Siendo la lechuga romana (*Lactuca sativa* L. var. *longifolia*) con la que se experimentará en este proyecto (ver Figura 2.9). Esta planta es muy susceptible a los cambios de temperatura, humedad y plagas, debido a esto se debe tener cuidado con ellas, siendo esta de las más cosechadas en todo el mundo.



Figura 2.9: Imágenes de plantas de Lechuga Romana.

Las temporadas de siembra de la lechuga romana varían, pero generalmente es en climas templados a fríos donde se aclimata mejor, y necesita una gran cantidad de agua para su crecimiento. En estas plantas la fertilización es muy importante debido que su ausencia puede afectar el crecimiento del centro de la lechuga. Se recomienda utilizar un complemento 15-15-15. En esta

especie, se recomiendan temperaturas que no rebasen los 25 grados centígrados y no disminuyan de 5 grados. Los riegos que se recomiendan dependerán de la temperatura de la planta y de su etapa de desarrollo (Quintero, 1997).

En este trabajo se seleccionó a la lechuga romana ya que es uno de los cultivos de alta importancia económica, debido a su valor nutricional y consumo extendido en el mundo, por lo cual puede alcanzar altos precios en el mercado nacional e internacional (Majid et al., 2021).

2. 4. Control Inteligente

El control inteligente comprende una serie de técnicas, tomadas fundamentalmente de la inteligencia artificial, con las que se pretenden resolver problemas de control inabordables por los métodos clásicos. El control clásico consta esencialmente de tratamiento de información en un nivel numérico y actuación sobre el mundo, no apareciendo en él actividades cognoscitivas de alto nivel de abstracción. Es por ello que en muchos casos se debe añadir a este tipo de controles la supervisión de un ser humano. El término Control Inteligente se utiliza para hacer referencia a un control en el que las actividades cognoscitivas tienen especial importancia. Dentro de este tipo de problemas, son de especial importancia los derivados de los comportamientos impredecibles, como los ocasionados por el mal funcionamiento de los sistemas a controlar (Galán et al., 2000).

Las técnicas más utilizadas dentro de esta área son:

1. Redes neuronales.
2. Lógica difusa.
3. Algoritmos genéticos.
4. Sistemas expertos.

En este trabajo de investigación, se utilizarán las dos primeras técnicas: las redes neuronales y la lógica difusa, para proponer un modelo de control inteligente para ajustar la frecuencia y tiempo de irrigación en un sistema aeropónico para evitar el estrés hídrico en las plantas de lechuga romana.

2. 5. Redes Neuronales Artificiales (ANN)

Las redes neuronales artificiales (ANN, por sus siglas en inglés) forman parte de las técnicas de aprendizaje máquina en el campo de la inteligencia artificial, y están basadas en el modelo biológico del cerebro humano. las ANN aprenden a través de ajustar los pesos y las *bias* (entradas de sesgo) dentro de la red para mejorar la subsecuente precisión de la red. La manera en que las ANN aprenden es reduciendo el error o la diferencia entre el valor actual y el valor previsto. Para la medición de la tasa de error se define una *función de costo*, la cual se evalúa rigurosamente durante la fase de aprendizaje de la red. Las ANN están formadas por varias capas: la *capa de entrada*, que recibe los datos de entrada; las *capas ocultas*, donde se realiza el proceso de extracción de características, aprendizaje, y entrenamiento; y la *capa de salida*, que acepta las salidas de las capas ocultas y realiza el proceso final de clasificación o regresión (ver Figura 2.10). Dichas capas están construidas con neuronas y pueden contener más de una. (Verdhan, 2021).




Figura 2.10: Representación de la estructura típica de una Red Neuronal. Fuente: (Verdhan, 2021).

Una neurona es la pieza fundamental de las redes neuronales, recibe entradas de datos crudos o de información procesada por capas previas, y realiza el procesamiento de la información de entrada y comparte una salida. La neurona combina la entrada con su propio estado interno y alcanza un valor utilizando una *función de activación*, y subsecuentemente, una salida es

generada utilizando una *función de salida*. La entrada a una neurona es recibida desde la salida de sus predecesoras y sus respectivas conexiones. La entrada recibida es calculada como una sumatoria de pesos, y un término de *bias* es generalmente añadido, a esto se le denomina como la *función de propagación*. Por ejemplo, la entrada de datos de entrenamiento pueden ser imágenes crudas o procesadas, estas imágenes serán alimentadas a la capa de entrada. Los datos pasarán a las capas ocultas donde todos los cálculos se realizan por las neuronas de cada capa. La salida será la tarea que deba realizar la red, por ejemplo, la identificación de un objeto o una imagen. Las neuronas pueden tener múltiples conexiones de entrada y salida, así también las conexiones de salida sirven de entrada para las neuronas de la siguiente capa. A cada conexión se le asigna un peso, el cual es representativo de su respectiva importancia. Entre las entradas de la neuronas está el *bias* que funciona como la adición de un valor de intersección o término constante en una ecuación lineal $y = mx + c$. Donde, si el término $c = 0$, entonces la ecuación pasará por el origen $(0,0)$, y si c existe, podemos esperar tener un modelo de aprendizaje más adecuado. Por lo que el *bias* nos permite ajustar la salida a lo largo de la sumatoria de pesos de las entradas (ver Figura 2.11).




Figura 2.11: Representación de la función de propagación aplicando la bias y una función de activación. Fuente: (Verdhan, 2021).

Las ANN pueden extraer la información por ellas mismas, pero se necesitan definir varios parámetros que permiten iniciar el proceso de entrenamiento de la red. Estos parámetros se denominan *hiperparámetros*. Estos hiperparámetros son aquellas variables y atributos que determinan la estructura de la red neuronal y las variables necesarias para entrenarla. Los hiperparámetros se deben definir antes de entrenar a la red, por ejemplo: la tasa de aprendizaje, la función de activación, el número de capas ocultas en la red, número de neuronas por capa, el número de épocas, el tamaño del lote (*batch*), abandono (*dropout*), y la inicialización de los pesos en la red,

entre otros. Por ejemplo, la tasa de aprendizaje definirá el tamaño de los pasos de corrección que toma un modelo para reducir los errores. Una alta tasa de aprendizaje tiene poca precisión, pero un corto tiempo para entrenar, mientras que con una baja tasa de aprendizaje, a la red le tomará más tiempo para entrenar, pero tendrá una alta precisión. Por lo que se debe definir un valor óptimo para entrenar. Mientras que la función de activación permite decidir cuando, o cuando no, una neurona debería de dispararse. Esta función juega un rol central en el ajuste de gradientes durante el entrenamiento de la red en una etapa posterior. La función de activación también se le llama *función de transferencia*. El comportamiento no lineal de las funciones de transferencia permiten a las redes neuronales aprender comportamientos complejos. Existen múltiples funciones que se pueden aplicar al construir las redes neuronales, tales como: sigmoideal, tangente hiperbólica (tanh), unidad lineal rectificadora (ReLU), SoftMax, entre otras.

El entrenamiento de una red neuronal tiene como objetivo reducir el error en las predicciones de la red. Una vez que la red hace una predicción, se puede calcular el error, el cual es la diferencia entre el valor esperado y el valor predicho. Esto es llamado la *función de costo*. Basado en el valor de costo, la red neuronal entonces ajusta sus pesos y sesgos para obtener el valor más cercano al real, es decir, que minimice el error. Este proceso es realizado durante la retropropagación (*backpropagation*). Mientras que la tasa de aprendizaje define el tamaño de los pasos correctivos para reducir el error, la retropropagación se utiliza para ajustar los pesos de las conexiones. Estos pesos son actualizados hacia atrás basados en el error. Los errores son recalculados, el descenso en gradiente también, y los respectivos pesos de las conexiones son ajustados. Durante la retropropagación los parámetros de las conexiones son repetidamente e iterativamente actualizados y ajustados. El nivel de ajuste es determinado por el gradiente de la función de costo, con respecto a estos parámetros. Usando la regla de cadena, los gradientes son calculados para una capa por vez, iterando hacia atrás desde la última capa hasta la primera. La Figura 2.12 muestra una representación del método del descenso del gradiente aplicado para disminuir el error de entrenamiento de una ANN.

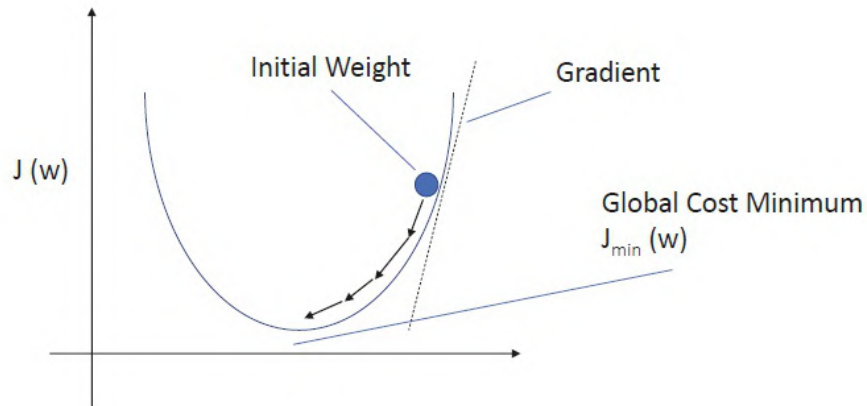


Figura 2.12: Representación del error o costo de entrenamiento y el efecto de ajustar los pesos de la red para minimizar el error aplicando el descenso del gradiente. Fuente: (Verdhan, 2021).

Para medir la precisión del aprendizaje máquina, se tiene que evaluar el rendimiento con dos conjuntos de datos, el conjunto de entrenamiento y el conjunto de prueba o validación. El conjunto de datos de prueba, son datos que no han sido utilizados en el entrenamiento de la red. Por otro lado, el propósito de una solución de aprendizaje máquina es encontrar el valor óptimo de error. Se desea decrementar la pérdida durante la fase de entrenamiento o mejor dicho maximizar la precisión. El descenso en gradiente ayuda para alcanzar ese propósito y es usado para encontrar el mínimo o máximo global. El descenso de gradiente estocástico es una técnica de optimización altamente utilizada para conjuntos de datos grandes.

2. 6. Redes Neuronales Convolucionales (CNN)

Las técnicas de aprendizaje profundo son un subconjunto de las técnicas de aprendizaje máquina. Las redes neuronales convolucionales (CNN) son redes profundas (por esto el nombre de aprendizaje profundo) las cuales permiten segmentar (ver Figura 2.13) y clasificar (ver Figura 2.14) imágenes.




Figura 2.13: Representación de la estructura de una CNN para segmentación de imágenes. Fuente: (Bandyopadhyay, 2024).




Figura 2.14: Representación de la estructura de una CNN para clasificación de imágenes. Fuente (Kumar, 2001).

La arquitectura de las CNN para clasificación incluye capas convolucionales, capas de agrupación y capas totalmente conectadas. Las capas de convolución y agrupación se utilizan para la extracción de características. Las capas de convolución son las encargadas de aplicar filtros para la detección de patrones, texturas y contornos, mientras que las capas de agrupación se emplean cuando hay instancias en las que la imagen no requiere todos los detalles de alta resolución o se necesita una salida con regiones más pequeñas extraídas por la CNN después de realizar la operación de reducción de resolución en los datos de entrada. La salida de las capas de convolución y agrupación alimenta a las capas completamente conectadas para su clasificación. Ejemplos de tareas de aprendizaje de clasificación en las que se utiliza CNN son la clasificación de imágenes, la detección de objetos y el reconocimiento facial (Kumar, 2001).

2. 7. Sistemas Difusos

Los sistemas difusos permiten modelar procesos no lineales, aprendiendo de los propios datos haciendo uso de determinados algoritmos de aprendizaje. A diferencia de las redes neuronales, los sistemas basados en lógica difusa permiten utilizar fácilmente el conocimiento de los expertos en un tema, bien directamente, o como punto de partida para optimización automática, al formalizar el conocimiento a veces ambiguo de un experto a una forma realizable. Además, gracias a la simplicidad de los cálculos necesarios, normalmente pueden aplicarse en sistemas económicos y rápidos (Benito and Duran, 2013).

Naturalmente se suele asociar que un objeto, rango o estado tiene una pertenencia a un Si o No, pero como se menciona en (Zadeh, 1965) los objetos pueden tener un grado de pertenencia, es decir, puede ser parte de un conjunto y a su vez pertenecer a otro. Esta pertenencia es gradual al conjunto que se mencione y puede variar dependiendo al estado en el que se analice.

En estos sistemas se utilizan variables lingüísticas para definir los rangos en las variables difusas, en estos rangos se establece una pertenencia de las variables del conjunto difuso. Este rango de pertenencia es definido por la información proporcionada por un experto del tema y la correcta creación de este es primordial para que el sistema difuso funcione correctamente.

Las variables difusas definen a los conjuntos difusos y su grado de pertenencia, generalmente se suelen utilizar patrones triangulares, senoidales, gaussianas y trapezoidales para definir esta relación (ver Figura 2.15)

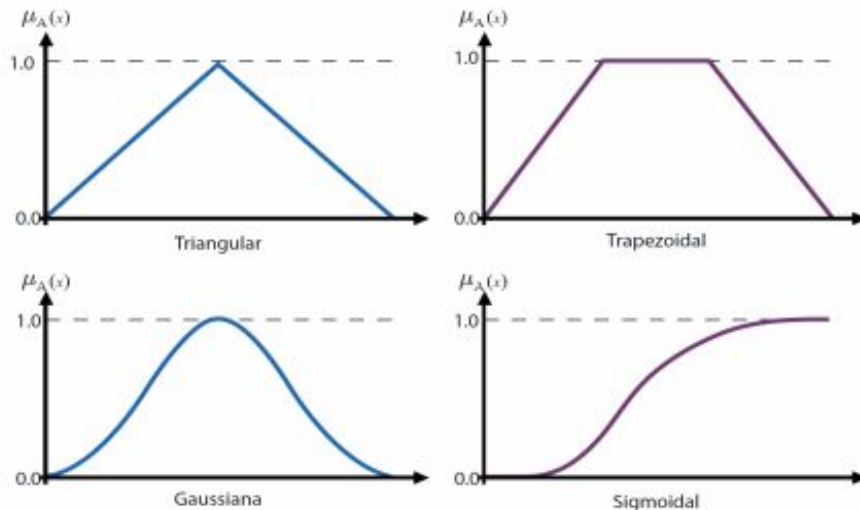


Figura 2.15: Representación de diferentes funciones de pertenencia para la definición de conjuntos difusos.

Capítulo 3

Metodología

El desarrollo de este proyecto consistió en el diseño, implementación y pruebas de un sistema de control de riego basado en técnicas de la Inteligencia Artificial, aplicado al cultivo tipo aeropónico de la lechuga romana. Como se muestra en la Figura 3.1, los componentes principales del sistema de control son: 1) una Red Neuronal Convolutiva (CNN) que recibe imágenes de las plantas de lechuga, con las cuales infiere el nivel de estrés hídrico de las mismas; y 2) un sistema basado en Lógica Difusa, que recibe como entradas la temperatura y el porcentaje de humedad dentro del tubo de cultivo, así como el nivel de estrés hídrico de las plantas, inferido por la CNN; y devuelve como salida la decisión de activar o no las bombas de riego, y en su caso, el tiempo de riego dado en segundos.

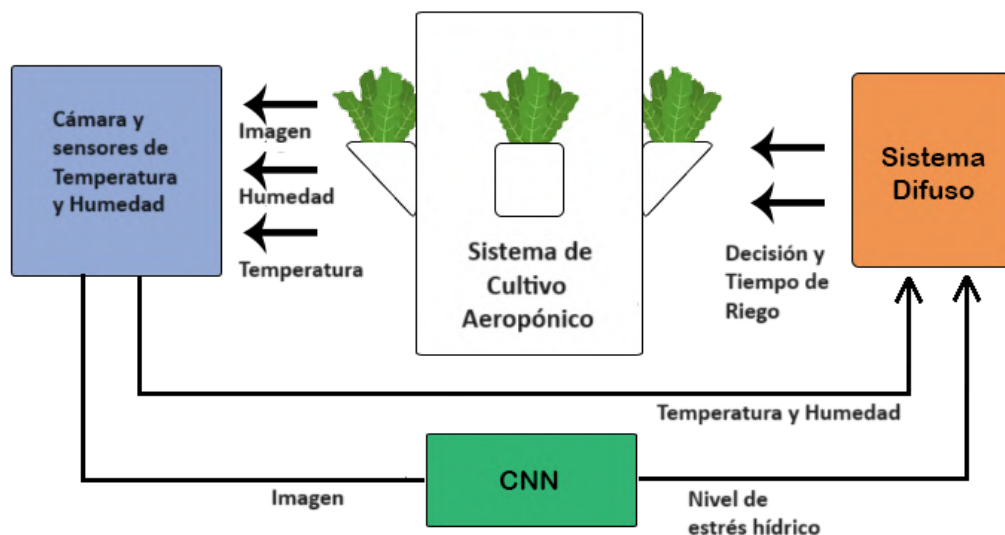


Figura 3.1: Diagrama de bloque del sistema de control de riego propuesto.

El desarrollo del proyecto se dividió en seis etapas (ver Figura 3.2). En la primera etapa se diseñó y construyó un prototipo para el cultivo aeropónico en vertical de la lechuga romana. En la segunda etapa se implementó el sistema de riego, incluyendo los componentes mecánicos y electrónicos del sistema. En la tercera etapa se llevó a cabo la siembra de semillas de lechuga romana en charolas germinadoras, para su posterior trasplante al tubo de cultivo aeropónico. En la cuarta etapa se generó una base de datos con imágenes de las plantas con diferentes niveles de estrés hídrico. En la quinta etapa se diseñó una Red Neuronal Convolutiva para el reconocimiento del nivel de estrés hídrico de la lechuga, y se entrenó con la base de datos de imágenes generada previamente. En la sexta y última etapa se diseñó e implementó un sistema difuso para el control automatizado del sistema de riego. A continuación se presenta con más detalle cada una de las etapas.




Figura 3.2: Etapas de desarrollo del proyecto.

3. 1. Prototipo del sistema aeropónico

Para implementar y realizar pruebas de control del sistema de riego, se requirió construir un prototipo de cultivo aeropónico (ver Figura 3.3). Para esto, se utilizó un tubo de PVC de 2 metros de largo por 20.32 cm de diametro, al cual se le adaptaron recipientes cónicos de 8 cm, donde posteriormente se colocarían las plantas. Estos recipientes se colocaron en siete niveles con separación de 20 centímetros entre cada uno, para evitar el rose entre las plantas. En cada nivel se insertaron cuatro recipientes, resultando en un total de 28 espacios de siembra para la lechuga. Finalmente, el tubo se lijó y pintó de color blanco para tener una superficie homogénea.



Figura 3.3: Prototipo de tubo de cultivo aeropónico para la lechuga romana.

Dentro del tubo de riego se colocó un sistema de nebulización, el cual consta de siete mangueras de riego independientes (una por nivel). En un extremo de cada manguera se colocó un aspersor tipo pulverizador focalizado a las canastillas de siembra (ver Figura 3.4). El otro extremo de las mangueras se conectó a las válvulas de regado, conectadas a su vez a la bomba de riego (ver Figura 3.5). De esta forma se logra un control de riego independiente por cada nivel del tubo.



Figura 3.4: Aspersor de regado colocado al interior del tubo de riego.



Figura 3.5: Mangueras conectadas a la bomba de riego

El tubo de cultivo se colocó dentro de una estructura tipo invernadero, con volumen aproximado de 12 m³, construido con mallasombra con filtro del 80% de la luz solar. En un inicio del proyecto se decidió utilizar esta estructura tipo invernadero para la germinación y desarrollo de las plantas, pero debido a las altas temperaturas que se presentan en el estado en ciertos meses del año, se decidió realizar el proceso de germinación dentro de un entorno con temperatura e

iluminación controladas, que de acuerdo a (Martínez, 2012) no debe superar temperaturas de 30 °C ni bajar de 10 °C. Por otro lado, para evitar las temperaturas bajas en los meses de invierno, se diseñó una caja de estructura rígida y paredes de poliestireno como aislante térmico, en las cuales se colocaron las charolas de siembra de las plantas.



Figura 3.6: Prototipo del sistema de cultivo aeropónico dentro del invernadero.

3. 2. Implementación del sistema de riego

Para la implementación del sistema de riego, se utilizó una tarjeta Arduino Uno con la función de activar y desactivar las válvulas de riego. Se conectaron y configuraron ocho relés a los pines de salida del Arduino, alimentados con una fuente de poder de 5 V a 12 A. Estos relés manejan voltajes de salida de 110 V/220 V a 5 A y son compatibles con voltajes de entrada de 3 V/5 V

(ver Figura 3.7).




Figura 3.7: Sistema gestor de encendido y apagado de las válvulas.

El riego se realiza a través de una bomba de membrana de 45 psi. Esta bomba suministra el líquido por las mangueras hasta llegar a las electroválvulas y los nebulizadores, para posteriormente ser rociado a la raíz de cada una de las plantas (ver Figura 3.8).



Figura 3.8: Bomba de agua de membrana para el riego.

3. 3. Cultivo de las plantas de lechuga romana

Para poder realizar los experimentos del sistema de riego, fue necesario sembrar y germinar plántulas de lechuga romana durante varios meses, con el fin de tener disponibles plantas en las etapas de crecimiento requeridas para las diferentes fases del proyecto. Para la germinación de las plántulas se utilizó una charola de plástico negro, en donde se sembraron las semillas en varias etapas para lograr distintas edades de las plantas. Se regaron constantemente para su buen desarrollo, y se mantuvieron dentro de un entorno con iluminación y temperatura controladas (ver Figura 3.9).



Figura 3.9: Charola germinadora de plántulas de lechuga romana.

Debido a las altas temperaturas que se presentan en la localidad en ciertos meses del año, se optó por mantener las charolas germinadoras en un entorno aún más controlado que el invernadero de mallasombra. Este entorno consistió en una habitación aislada con clima artificial, la cual se mantuvo a temperaturas entre 17 °C y 22 °C durante el día y la noche. Para sustituir la luz solar se instaló una fuente de iluminación artificial ultravioleta sobre las plántulas. La iluminación artificial cuenta con 163 leds rojos que ayudan a la floración, 58 leds azules que mejoran el crecimiento de la raíz y las hojas, y 4 leds de luz UV de espectro fucsia que incrementan los lúmenes absorbidos por las plántulas (ver Figura 3.10.)



Figura 3.10: Luz artificial utilizada para el desarrollo de las plántulas.

En cada siembra, las plántulas se dejaron crecer durante cuatro semanas, tiempo en el cual llegan a su etapa de trasplante. Durante ese tiempo se regaron en intervalos de 24 horas, utilizando en cada riego un litro y medio de agua potable para toda la charola. En cada riego se aplicaron 5 gramos de fertilizante triple 19 por litro de agua. Esta mezcla de fertilizante está compuesto por un 19% de Nitrógeno, 19% de Fósforo y 19% de Potasio, y el restante se divide entre

Manganeso, Boro, Cobre y Zinc. Después de las cuatro semanas de desarrollo, las plantas se trasplantaron al tubo aeropónico, colocadas dentro de rejillas con fibra absorbente que funciona como sostén y sustrato inerte para la raíz (ver Figura 3.11).



Figura 3.11: Trasplante de las plantas de lechuga romana al tubo aeropónico.

3. 4. Generación de la base de datos de imágenes

Con el objetivo de inferir el nivel de estrés hídrico de las plantas a partir de imágenes, se diseñaron y entrenaron dos modelos de CNN. El primer modelo, que se utilizó para probar la idea y evaluar su factibilidad, se entrenó con imágenes de las plantas trasplantadas en pequeñas macetas independientes. El segundo modelo de CNN utilizado finalmente junto con el sistema de control difuso, se entrenó con imágenes de las plantas trasplantadas en el tubo aeropónico. Ambos modelos se entrenaron con la capacidad de distinguir entre cinco niveles progresivos de estrés hídrico de las plantas. Esto requirió contar con un conjunto de imágenes digitales

etiquetadas bajo los cinco niveles de estrés hídrico. Dado que no se encontró información en la literatura sobre alguna base de datos de imágenes con las características requeridas en este proyecto, fue necesario crear una base de datos propia. A continuación se explica la generación de la base de datos para el primer modelo.

Para generar la primera de las dos bases de datos de imágenes, se utilizaron 20 plantas de lechuga romana elegidas al azar. Estas plantas se sometieron a diferentes niveles de estrés hídrico, capturando y etiquetando las imágenes resultantes. Se decidió iniciar el proceso de adquisición de imágenes después de la cuarta semana de crecimiento de las plantas. En esta etapa han brotado al menos las primeras cuatro hojas verdaderas y, aunque aún cuentan con algunas hojas de leche, dejan de considerarse plántulas y se reconocen como plantas. Se eligió esta etapa de crecimiento para el reconocimiento del nivel de estrés hídrico, ya que es una etapa en la que las plantas suelen ser trasplantadas a otro medio para su crecimiento, en el cual la frecuencia y cantidad de riego se trata de controlar de forma más precisa.

Para la adquisición de las imágenes se montó un escenario dentro de una habitación cerrada con fondo negro e iluminación artificial, utilizando una base fija para colocar las plantas a una distancia de 15 cm de la cámara (ver Figura 3.12). Para la toma de las imágenes se implementó una interfaz móvil que incluye como componentes principales: una tarjeta Raspberry Pi 3 con sistema operativo Raspbian versión 5.15, una cámara digital con resolución de ocho megapíxeles y una pantalla LCD de siete pulgadas (ver Figura 3.13). El script para la captura y almacenamiento de las imágenes se implementó en lenguaje Python versión 3.11.5. Las librerías más importantes que se utilizaron fueron torch V.1.9.0, numpy V.1.23.4 y scikit-fuzzy V.0.4.2.




Figura 3.12: Escenario montado para adquisición de imágenes de la lechuga romana.




Figura 3.13: Interfaz para la adquisición de imágenes.

La primera sesión de captura de las imágenes se realizó justo después de regar por última vez las plantas. A partir de ese momento se suspendió el riego y se continuó capturando imágenes en

intervalos de dos horas, durante las 102 horas siguientes (ver Tabla 3.1). En total se obtuvieron 860 imágenes, divididas en 172 imágenes por cada uno de los cinco niveles de estrés hídrico. El nivel de estrés de cada imagen se asignó de acuerdo a la hora en que se tomó la fotografía. Por ejemplo, se etiquetó como nivel "0" a las imágenes tomadas entre las cero y las primeras 16 horas después de que se dejó de regar. Estas plantas se encuentran en buen estado y tienen un alto nivel de humedad. Se asignó nivel "4" a las imágenes tomadas entre 80 y 102 horas después de la última irrigación, estas plantas están en peor estado y con muy bajo nivel de humedad. En la Figura 3.14 se muestran ejemplos de las plantas en los cinco niveles de estrés hídrico.

Tabla 3.1: Intervalos de horas después del último riego considerado para cada nivel de estrés hídrico para la primera base de datos de imágenes.

Nivel de estrés hídrico	Horas desde el último riego
0	0 a 16
1	16 a 38
2	38 a 62
3	62 a 80
4	80 a 102




Figura 3.14: Imágenes de plantas de lechuga romana en los cinco niveles (0-4) de estrés hídrico.

Con esta primera base de datos de imágenes se logró una primera aproximación al problema de la detección del nivel de estrés hídrico. Para obtener la segunda base de datos, utilizada en la versión final del modelo de CNN, se realizó una nueva captura de imágenes durante 75 horas, pero ahora con las plantas dentro del tubo de riego aeropónico. En esta ocasión se capturaron 5,024 imágenes de las plantas en los cinco niveles de estrés. El primer intervalo de captura, que corresponde al nivel "0" de estrés, fue desde el momento después del último riego hasta la hora 15, contando con 995 imágenes; el segundo intervalo (nivel "1") de la hora 15 hasta la hora 30, con un total de 999 imágenes; el tercer intervalo (nivel "2") de la hora 30 hasta la hora 45, con 1,001 imágenes; el cuarto intervalo (nivel "3") de la hora 45 hasta la hora 60, con 1,008 imágenes; y el último intervalo (nivel "4") con 1,021 imágenes, de la hora 60 hasta la hora 75 (ver Tabla 3.2).

Tabla 3.2: Intervalos de horas después del último riego considerado para cada nivel de estrés hídrico para la segunda base de datos de imágenes.

Nivel de estrés hídrico	Horas desde el último riego
0	0 a 15
1	16 a 30
2	31 a 45
3	46 a 60
4	61 a 75

3. 5. Arquitectura y entrenamiento de la CNN

En la Figura 3.15 se muestra la arquitectura de red neuronal utilizada para ambos modelos de inferencia de estrés hídrico en las plantas de lechuga romana. A continuación se explica brevemente cada una de las capas que la componen. La primera capa de la red recibe las imágenes con dimensiones de 320 x 240 píxeles con 3 canales de color. Posteriormente, se define una capa de Convolución con Kernel de 5 x 5, seguida de una capa de Pooling de 4 x 4, generando 20 mapas de características. En ambas capas se aplica la función de activación ReLU. A continuación, se repite la secuencia de capa de Convolución seguida de capa de Pooling, generando en este caso 30 mapas de características. Los mapas de características que resultan después de aplicar estas dos secuencias son de 18 x 13 neuronas. Finalmente, se definen dos capas lineales totalmente

conectadas, la primera de 100 neuronas y la segunda de 5 neuronas que corresponden a los 5 niveles de estrés hídrico en que se clasifican la plantas. La función de activación de la primera capa lineal es ReLU y la función de la última capa es Softmax logarítmica.

Esta arquitectura de CNN se diseñó bajo el criterio de generar un modelo-solución ligero, que pueda ser implementado de forma eficiente en una tarjeta embebida con limitaciones de procesamiento y memoria (por ejemplo la Raspberry Pi 3), pero que a la vez mantenga un nivel de precisión competitivo respecto al estado del arte. Para esto, se buscó limitar el número de capas convolucionales para la extracción de características de las imágenes, así como el número de capas totalmente conectadas para la clasificación final. De esta forma, a partir de una experimentación incremental en cuanto al número de capas, mapas de características y neuronas, se obtuvo una arquitectura con un número relativamente pequeño de parámetros y un buen nivel de predicción. Cabe mencionar que se probaron otras arquitecturas conocidas, como Resnet y GoogleNet, pero se descartaron debido a su alto costo de tiempo de procesamiento y espacio de almacenamiento, dado el número de capas ocultas y conexiones neuronales.

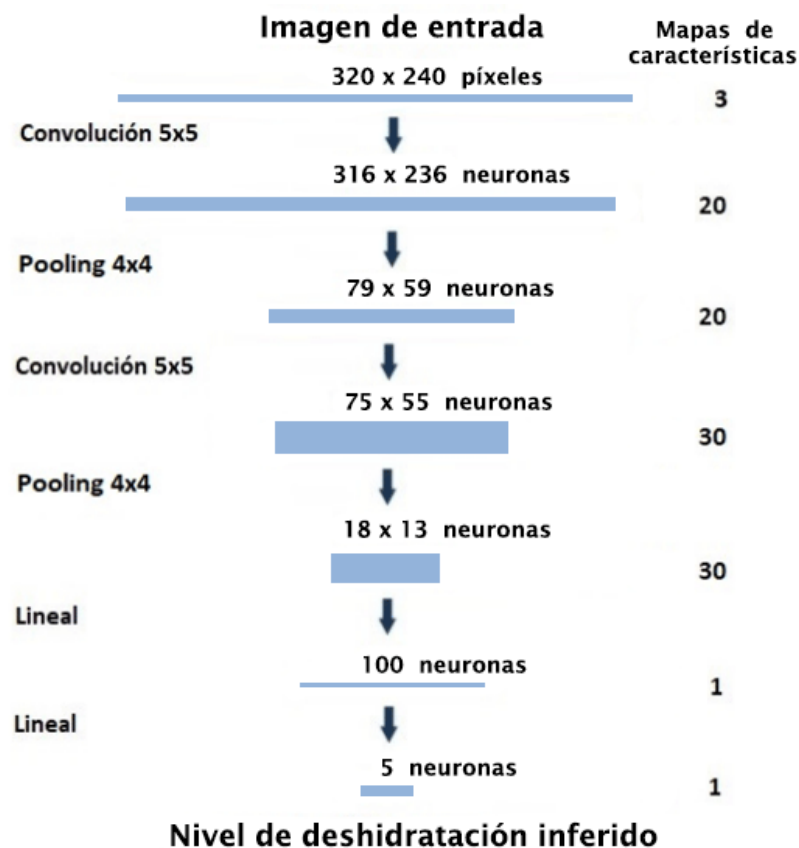


Figura 3.15: Arquitectura de la CNN utilizada para inferencia del nivel de estrés hídrico.

Para el entrenamiento del primer modelo de red se utilizaron 688 imágenes distribuidas en los cinco niveles de estrés hídrico, de acuerdo a como se muestra en la Tabla 3.3. Para el segundo modelo se utilizaron 5,024 imágenes distribuidas de acuerdo a como se muestra en la Tabla 3.4. En ambos casos las imágenes se agruparon de forma aleatoria en lotes de 10 para aplicar el modelo actual y ajustar los pesos de la red.

Tabla 3.3: Distribución de imágenes de entrenamiento por nivel de estrés hídrico para el primer modelo de red.

Imágenes de entrenamiento para el primer modelo					
Nivel de estrés hídrico	0	1	2	3	4
Cantidad de imágenes	141	136	140	136	135

Tabla 3.4: Distribución de imágenes de entrenamiento por nivel de estrés hídrico para el segundo modelo de red.

Imágenes de entrenamiento para el modelo final					
Nivel de estrés hídrico	0	1	2	3	4
Cantidad de imágenes	995	999	1,001	1,008	1,021

El Algoritmo 3. 5.1 corresponde al proceso de entrenamiento para ambos modelos de CNN. La parte central del algoritmo consiste en un bloque de cuatro funciones dentro del segundo ciclo for, donde: 1) se aplica el modelo actual (pesos y bias) de la red sobre cada lote de imágenes, obteniendo como salida la inferencia del nivel de estrés hídrico de las plantas que corresponden al lote de imágenes; 2) se aplica la función de pérdida para obtener el error logarítmico de la inferencia del modelo, respecto a los niveles reales recibidos como etiquetas; 3) se aplica la retropropagación del error calculado de la última capa hacia las capas previas de la red; 4) dado el error asociado a cada peso y bias calculado en la retropropagación, se aplica el ajuste atenuado con el factor o tasa de aprendizaje.

Algorithm 3. 5.1: Entrenamiento de la Red Neuronal

```
entrada: parámetros de entrenamiento  
salida : modelo de red neuronal entrenada  
1 modelo_red ← genera modelo de red neuronal inicial  
2 optimizador ← define función de optimización SGD  
3 menor_perdida ← 0  
4 for epoca in rango(1, total_epocas) do  
5     activa modo entrenamiento de modelo_red  
6     for imagenes, etiquetas in conjunto entrena do  
7         salida ← aplica modelo_red sobre imagenes  
8         perdida ← aplica función de pérdida NLL sobre salida vs etiquetas  
9         aplica retropropagación del error  
10        (perdida.backward())  
11        aplica actualización de pesos y bias  
12        (optimizador.step())  
13     activa modo evaluación de modelo_red  
14     perdida_prueba ← 0  
15     for imagen, etiqueta in conjunto de prueba do  
16         salida ← aplica modelo_red sobre imagen  
17         perdida_prueba += aplica función de pérdida NLL sobre salida vs etiqueta  
18     if perdida_prueba < menor_perdida then  
19         guarda modelo_red  
20         menor_perdida ← perdida_prueba
```

En la Tabla 3.5 se muestran los parámetros de entrenamiento. Los valores de estos parámetros se obtuvieron a través de experimentación, buscando un equilibrio entre el porcentaje de correcta clasificación y el tiempo de ejecución. Esto es, se mantuvo la arquitectura de la red lo más sencilla posible, sin perder más de dos puntos porcentuales en la precisión de la inferencia del nivel de estrés hídrico. En la Tabla 3.6 se muestran las características del equipo de cómputo utilizado para el entrenamiento y pruebas de la red.

Tabla 3.5: Parámetros de entrenamiento de la CNN para inferencia de estrés hídrico.

Tamaño del lote	10
Número de épocas	150
Tasa de aprendizaje	0.05
Función de pérdida	Negative Log-Likelihood
Función de optimización	Stochastic Gradient Descent

Tabla 3.6: Equipo de cómputo utilizado para el entrenamiento de la CNN.

Procesador	Intel i5 7th Gen
Tarjeta gráfica	Nvidia GTX 1050
Memoria RAM	16GB
Disco Duro	1.5TB
Sistema operativo	Windows 10

3. 6. Sistema Difuso para el control de riego aeropónico

Una vez inferido el nivel de estrés hídrico de las plantas por la CNN, a partir de imágenes de estas, y realizada la lectura de la temperatura y el porcentaje de humedad dentro del tubo aeropónico, estos datos son pasados al Sistema Difuso encargado de tomar la decisión de activar o no las bombas de riego y, en caso de activarlas, determinar el tiempo que deben permanecer activas. A continuación se muestra el diseño de los conjuntos de las variables difusas y las reglas de inferencia utilizadas en este proyecto.

3. 6.1. Conjuntos difusos de las variables de entrada

El sistema difuso recibe tres variables de entrada: 1) la temperatura dentro del tubo de riego aeropónico, 2) el nivel de estrés hídrico de las plantas, que se obtiene como salida de la CNN, y 3) la humedad relativa en la canastilla que sostiene la raíz de las plantas dentro del tubo.

3. 6.1.1. Conjuntos difusos para la variable de entrada “Temperatura”

La Figura 3.16 muestra los tres conjuntos difusos definidos para la variable de entrada “Temperatura”. Los dos criterios principales para sus definiciones son: 1) de acuerdo a (Quintero, 1997), para la especie de lechuga romana no se recomiendan temperaturas mayores a los 25 °C, ni por debajo de los 5 °C; y 2) los rangos de temperaturas extremas para el estado de

Baja California Sur pueden bajar de los 0 °C y superar los 35 °C (INEGI, 2019). Dada esta información, el primer conjunto, nombrado como “Temperatura Baja”, se definió en un rango que inicia en los 10 °C (una temperatura baja pero aún soportable por la lechuga) donde el nivel de pertenencia a este conjunto es cero, incrementándose el nivel de pertenencia gradualmente hasta llegar a uno (pertenencia máxima) en los 5 °C (una temperatura extrema para la lechuga), y a partir de los 5 °C, las temperaturas más bajas se consideran con pertenencia máxima al conjunto “Temperatura Baja”, en donde la planta ya no crecería. Para el segundo conjunto se definió un intervalo que va desde los 5 °C hasta los 25 °C, nombrado como “Temperatura Media”. Este intervalo corresponde a las condiciones de temperatura que más favorecen a la lechuga romana. Se definió como pertenencia máxima a este conjunto el rango de temperatura de 10 °C a los 20 °C, que es un rango de temperatura adecuado para el crecimiento de la lechuga romana. El tercer conjunto nombrado como “Temperatura Alta”, se definió en un intervalo que va desde los 20 °C hasta más de 35 °C. A partir de los 25 °C se considera que la temperatura tiene una pertenencia máxima a este conjunto, indicando que son temperaturas demasiado altas donde la lechuga no puede desarrollarse.




Figura 3.16: Conjuntos difusos para la variable de entrada “Temperatura”.

3. 6.1.2. Conjuntos difusos para la variable de entrada “Nivel de Estrés Hídrico”

La Figura 3.17 muestra los conjuntos difusos definidos para la variable “Nivel de Estrés Hídrico”. La definición de estos conjuntos se basa en la información que genera la red neuronal convolucional. Como se menciona en las secciones previas, la red es capaz de reconocer cinco niveles de estrés hídrico en las plantas, por lo que se definieron cinco conjuntos difusos, un conjunto por cada nivel de estrés: 1) conjunto “Sin estrés” con su grado máximo de pertenencia en el nivel cero de estrés, disminuyendo gradualmente el grado de pertenencia hasta llegar a cero en el nivel uno de estrés; 2) conjunto “Poco estrés”, con su grado máximo de pertenencia en el nivel uno de estrés, disminuyendo gradualmente en ambos extremos hasta llegar a cero en el nivel cero y nivel dos de estrés; 3) conjunto “Estrés”, con su grado de pertenencia máximo en el nivel dos de estrés; 4) conjunto “Estrés moderado”, con su grado máximo de pertenencia en el nivel tres de estrés; y 5) conjunto “Estrés alto”, con grado máximo de pertenencia en el nivel 4 de estrés.




Figura 3.17: Conjuntos difusos para la variable de entrada “Nivel de Estrés Hídrico”.

3. 6.1.3. Conjuntos difusos para la variable de entrada “Humedad”

La Figura 3.18 muestra los conjuntos difusos para la variable de entrada “Humedad”. Debido a que las plantas se encuentran en constante crecimiento y consumiendo líquido, la humedad del sistema tiende a descender gradualmente, por lo que se requiere de un riego eventual y oportuno

para mantener dicha humedad. Además, los nutrientes son suministrados por medio del riego, por lo que es necesario continuar con el mismo cada cierto intervalo, aunque la humedad se encuentre en un nivel alto. Para controlar esto, se diseñaron tres conjuntos difusos para la variable “Humedad”, la cual se maneja en un rango del 0% al 100%. El primer conjunto se nombró como “Poco húmedo”, con un intervalo de 0% al 40%, con su máximo nivel de pertenencia para valores menores o igual al 20% de humedad. El segundo conjunto se nombró como “Húmedo”, con un intervalo del 20% al 80%, con máximo nivel de pertenencia entre 40% y 60% de humedad. El tercer conjunto nombrado como “Muy húmedo”, se definió en un intervalo de 60% al 100% de humedad, con un nivel de pertenencia máximo a partir del 80% de humedad. Uno de los objetivos del sistema difuso es mantener esta variable en sus valores más altos posible.

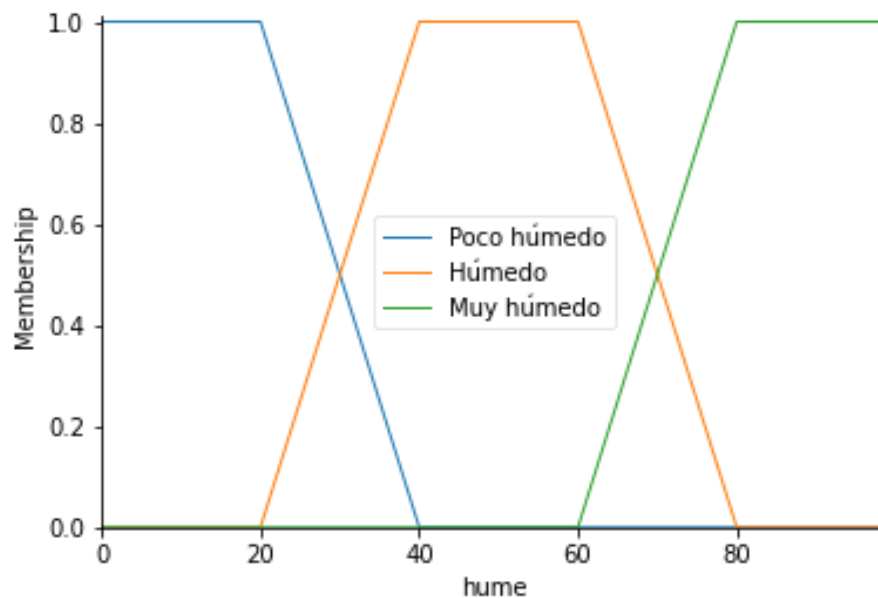


Figura 3.18: Conjuntos difusos para la variable de entrada “Humedad”.

3. 6.2. Conjuntos difusos para las variables de salida

El sistema difuso devuelve dos variables de salida: 1) la variable “Riego”, que define en cada intervalo de control si se enciende o no la bomba de agua, y 2) la variable “Tiempo de riego”, que determina el tiempo en segundos que se mantiene la bomba encendida.

3. 6.2.1. Conjuntos difusos para la variable de salida “Riego”

La Figura 3.19 muestra los conjuntos difusos para la variable de salida “Riego”. Para su definición, se considera que el sistema de control realiza cada cinco minutos la lectura de la temperatura, humedad y el nivel de estrés hídrico de las plantas. Con esta información como entrada, el sistema difuso determina si se debe de encender o no la bomba de agua en ese intervalo de tiempo. Este dato lo devuelve a través de la variable de salida “Riego”. Es decir, esta variable solo arroja dos posibles valores: Si o No se activa la bomba. Por lo tanto, para esta variable solo se requieren dos conjuntos difusos: 1) el conjunto “Si” y el conjunto “No”. Estos conjuntos se definieron de forma simétrica, con un punto de intersección en el valor 2.5. De tal manera que si el sistema de inferencia difuso devuelve un valor menor o igual a 2.5, se decide activar la bomba, en caso contrario se mantiene apagada. La definición del intervalo de estos conjuntos es arbitrario, lo cual no afecta el funcionamiento del sistema. Para utilizar estos conjuntos para una variable de decisión binaria, como se requiere en este proyecto, el único requisito es que sean conjuntos simétricos y presenten un punto de intersección conocido.




Figura 3.19: Conjuntos difusos para la variable de salida “Riego”.

3. 6.2.2. Conjuntos difusos para la variable de salida “Tiempo de Riego”

La Figura 3.20 muestra los conjuntos difusos para la variable de salida “Tiempo de Riego”. La definición de estos conjuntos considera el hecho de que las plantas están colocadas en las

canastillas y se sujetan con una esponja, la cual mantiene por más tiempo la humedad disponible para las plantas. La esponja, finalmente, es la encargada de suministrar el agua y los nutrientes a la raíz que en ella se encuentra, lo cual permite reducir el tiempo de riego y, a su vez, disminuir el consumo de energía eléctrica. Para esta variable se definieron cinco conjuntos difusos distribuidos de manera uniforme entre cero y los 45 segundos, con un traslape de 10 segundos entre cada uno, lo cual permite controlar de manera más fina el tiempo de regado de las plantas.




Figura 3.20: Conjuntos difusos para la variable de salida “Tiempo de Riego”.

3. 6.3. Reglas de inferencia difusas

Con base en los conjuntos de las variables de entrada y de salida, se definieron las reglas de inferencia difusas (ver Tabla 3.7). De acuerdo con la literatura, una de las formas más fiables de definir las reglas de un sistema difuso, es con el apoyo de un experto en el problema de interés; en este caso, correspondería a un agrónomo con experiencia en cultivo tipo aeropónico. Sin embargo, dado que en la entidad no se aplica este tipo de cultivo, no se logró contar con el apoyo de dicho experto. La opción más próxima fue entrevistar a un experto en cultivo en invernadero, lo cual consideramos algo similar al manejo de un sistema aeropónico, debido a que también se trata de controlar el riego de forma inteligente. Gracias al conocimiento proporcionado por este experto se generó una base para establecer las reglas de inferencia, y a partir de la experimentación se realizaron los ajustes correspondientes, hasta obtener resultados que consideramos aceptables.

Tabla 3.7: Definición de las reglas de inferencia del sistema difuso

Entradas			Salidas	
Temperatura	Humedad	Nivel de estrés hídrico	Tiempo riego	Regar
Media	Muy húmedo	Sin estrés	Muy poco	No
Media	Muy húmedo	Poco estrés	Muy poco	No
Media	Muy húmedo	Estrés	Muy Poco	Si
Media	Muy húmedo	Estrés moderado	Muy poco	Si
Media	Muy húmedo	Estrés alto	Poco	Si
Media	Húmedo	Sin estrés	Muy Poco	No
Media	Húmedo	Poco estrés	Muy Poco	No
Media	Húmedo	Estrés	Muy Poco	Si
Media	Húmedo	Estrés moderado	Poco	Si
Media	Húmedo	Estrés alto	Poco	Si
Media	Poco húmedo	Sin estrés	Muy poco	Si
Media	Poco húmedo	Poco estrés	Muy poco	Si
Media	Poco húmedo	Estrés	Poco	Si
Media	Poco húmedo	Estrés moderado	Poco	Si
Media	Poco húmedo	Estrés alto	Medio	Si
Baja	Muy húmedo	Sin estrés	Muy poco	No
Baja	Muy húmedo	Poco estrés	Muy poco	No
Baja	Muy húmedo	Estrés	Poco	Si
Baja	Muy húmedo	Estrés moderado	Medio	Si
Baja	Muy húmedo	Estrés alto	Medio	Si
Baja	Húmedo	Sin estrés	Muy Poco	Si
Baja	Húmedo	Poco estrés	Poco	Si
Baja	Húmedo	Estrés	Medio	Si
Baja	Húmedo	Estrés moderado	Alto	Si
Baja	Húmedo	Estrés alto	Alto	Si
Baja	Poco húmedo	Sin estrés	Muy poco	Si
Baja	Poco húmedo	Poco estrés	Poco	Si
Baja	Poco húmedo	Estrés	Medio	Si
Baja	Poco húmedo	Estrés moderado	Alto	Si
Baja	Poco húmedo	Estrés alto	Alto	Si
Alta	Muy húmedo	Sin estrés	Medio	Si
Alta	Muy húmedo	Poco estrés	Medio	Si
Alta	Muy húmedo	Estrés	Medio	Si
Alta	Muy húmedo	Estrés moderado	Alto	Si
Alta	Muy húmedo	Estrés alto	Alto	Si
Alta	Húmedo	Sin estrés	Medio	Si
Alta	Húmedo	Poco estrés	Alto	Si
Alta	Húmedo	Estrés	Alto	Si
Alta	Húmedo	Estrés moderado	Alto	Si
Alta	Húmedo	Estrés alto	Muy alto	Si
Alta	Poco húmedo	Sin estrés	Alto	Si
Alta	Poco húmedo	Poco estrés	Alto	Si
Alta	Poco húmedo	Estrés	Alto	Si
Alta	Poco húmedo	Estrés moderado	Muy alto	Si
Alta	Poco húmedo	Estrés alto	Muy alto	Si

Capítulo 4

Resultados

4. 1. Resultados de las pruebas de inferencia del nivel de estrés hídrico de las plantas a través de la CNN.

Para inferir el nivel de estrés hídrico de las plantas de lechuga romana a partir de imágenes, se entrenaron y evaluaron dos modelos de redes neuronales. El primer modelo se entrenó con un conjunto pequeño de imágenes, con las plantas colocadas en macetas individuales, en un ambiente controlado. Este primer modelo se utilizó principalmente para probar la idea y la estrategia planteada para inferir el nivel de estrés de las plantas. El segundo modelo se entrenó con un conjunto más amplio de imágenes, con las plantas trasplantadas en el tubo aeropónico. Este segundo modelo se utilizó finalmente como parte del sistema de control de riego difuso.

4. 1.1. Experimentos con el primer modelo de CNN

Las pruebas de inferencia del nivel de estrés con el primer modelo de red se realizaron con 172 imágenes, distribuidas en los cinco niveles de estrés hídrico de las plantas, de acuerdo a como se muestra en la Tabla 4.1. Estas 172 imágenes no se utilizaron para el entrenamiento de la red, es decir, son imágenes desconocidas por el modelo. Las pruebas consistieron en procesar las imágenes con el modelo de red para inferir el nivel de estrés que presentan las plantas en cada imagen, para posteriormente compararlas con el nivel de estrés real conocido.

Tabla 4.1: Distribución de imágenes de prueba por nivel de estrés hídrico para el primer modelo CNN.

Imágenes de Prueba					
Nivel de estrés hídrico	0	1	2	3	4
Cantidad de imágenes	31	36	30	36	39

La Figura 4.1 muestra el mapa de calor de los resultados de las pruebas. Las etiquetas de las filas del mapa corresponden a los niveles de estrés hídrico reales de las imágenes y las etiquetas de las columnas corresponde a los niveles inferidos por el modelo. Se puede observar en el mapa una tendencia clara de clasificación del nivel real de las imágenes, predominando la diagonal principal que representa los positivos verdaderos, seguida de las diagonales contiguas a esta, que representan la clasificación con un nivel de diferencia del real.




Figura 4.1: Mapa de calor de las pruebas de inferencias con el primer modelo CNN.

En la Tabla 4.2 se muestra la precisión (4.1) y la sensibilidad (4.2) del modelo. Se puede observar que el modelo obtuvo una menor precisión para el nivel “2” con el 72%, para el cual de las 29 imágenes inferidas en este nivel, solo 21 son correctas. Así mismo, para el nivel “2”

obtuvo la menor sensibilidad con 70 %, de las 30 imágenes que corresponden a este nivel logró inferir 21. Por otro lado, para los niveles extremos, el modelo obtuvo los mayores porcentajes de precisión y sensibilidad. Para el nivel “4”, logró la mayor precisión con el 91 %, resultando 34 clasificaciones correctas de las 37 inferidas. Para el nivel “0”, logró la mayor sensibilidad con el 90.3 %, clasificando correctamente 28 de las 31 imágenes reales de este nivel.

$$Precisión = \frac{TP}{TP + FP} \quad (4.1)$$

$$Sensibilidad = \frac{TP}{TP + FN} \quad (4.2)$$

Tabla 4.2: Estadísticas de inferencia del nivel de estrés hídrico con el primer modelo CNN.

Nivel de estrés hídrico	0	1	2	3	4	Total
Positivos verdaderos (TP)	28	29	21	31	34	143
Falsos positivos (FP)	3	7	8	8	3	29
Falsos negativos (FN)	3	7	9	5	5	29
Precisión (%)	90.3	80.5	72.4	79.5	91.9	83.1
Sensibilidad (%)	90.3	80.5	70	87.2	87.2	83.1

Como se muestra también en el mapa de calor (Figura 4.1), solo dos de las 172 imágenes de prueba se clasificaron en un nivel con más de una unidad de diferencia del nivel real. En el primer caso, una imagen se clasificó como nivel “2” siendo del nivel “4”. Esto es, en ambos casos el modelo infirió un nivel con dos unidades de diferencia del real. En la Tabla 4.3 se muestra la precisión y sensibilidad del modelo considerando una tolerancia de un nivel de diferencia entre el valor inferido y el nivel real. Como se puede observar, tanto la precisión como la sensibilidad, bajo esta tolerancia de un nivel resultan muy cercanas al 100 %.

Tabla 4.3: Estadísticas de inferencia del nivel de estrés hídrico con una tolerancia de un nivel con el primer modelo CNN.

Nivel de estrés hídrico	0	1	2	3	4	Total
Positivos verdaderos (TP)	31	36	29	36	38	170
Falsos positivos (FP)	0	0	1	0	1	2
Falsos negativos (FN)	0	0	1	0	1	2
Precisión (%)	100	100	96.7	100	96.7	98.8
Sensibilidad (%)	100	100	96.7	100	96.7	98.8

4. 1.2. Experimentos con el segundo modelo de CNN.

Las pruebas de inferencia del nivel de estrés con el segundo modelo de red se realizaron con 1,256 imágenes, distribuidas en los cinco niveles de estrés de las plantas, de acuerdo a como se muestra en la Tabla 4.4. Al igual que para el primer modelo, las pruebas consistieron en procesar las imágenes con el modelo de red para inferir el nivel de estrés hídrico que presentan las plantas en cada imagen, para compararlas posteriormente con el nivel real conocido.

Tabla 4.4: Distribución de imágenes de prueba por nivel de estrés hídrico para el segundo modelo CNN.

Imágenes de Prueba					
Nivel de estrés hídrico	0	1	2	3	4
Cantidad de imágenes	252	249	248	252	255

Como se puede observar en el mapa de calor de la Figura 4.2, la gran mayoría de las pruebas de inferencia del nivel de estrés caen en la diagonal principal, resultando una precisión promedio mayor al 94%. Un detalle importante a destacar, es que los casos en que no se obtuvo la inferencia correcta, casi en su totalidad solo tuvieron diferencia de un nivel de estrés respecto al nivel real, lo cual consideramos que no resulta crítico al momento de utilizar este dato en el sistema de control de riego. Únicamente en dos casos se obtuvo un error de dos unidades de diferencia respecto al nivel real, que representa el 0.16% del total de pruebas. Y no se obtuvo ningún caso con tres o cuatro niveles de diferencia respecto al real.

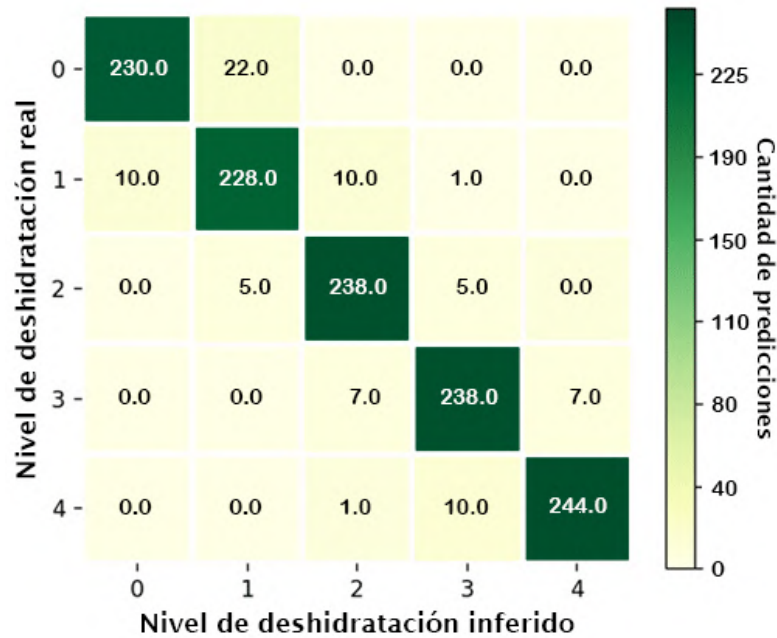


Figura 4.2: Mapa de calor de las pruebas de inferencia de estrés hídrico con el segundo modelo CNN.

La Tabla 4.5 muestra la precisión y sensibilidad obtenida con el segundo modelo CNN por cada nivel de estrés hídrico. Como se puede observar el promedio para ambas métricas es superior al 94 %, lo cual consideramos bastante aceptable. Por otro lado, se puede también observar un porcentaje mayor de ambas métricas en el nivel de estrés hídrico más alto. Nuestra hipótesis para este hecho, es que en este nivel de estrés al encontrarse las plantas en peores condiciones, presentan cambios más notables en las imágenes, lo cual no sucede en los primeros niveles de estrés.

Tabla 4.5: Estadística de las pruebas de inferencia de estrés hídrico de las plantas de lechuga romana para el segundo modelo CNN.

Nivel de deshidratación	0	1	2	3	4	Total
Positivos verdaderos (TP)	230	228	238	238	244	1256
Falsos positivos (FP)	10	27	18	16	7	78
Falsos negativos (FN)	22	21	10	14	11	78
Precisión (%)	95.8	89.4	92.9	93.7	97.2	94.1
Sensibilidad (%)	91.2	91.5	95.9	94.4	95.6	94.1

4. 2. Resultados de las pruebas de control de riego aeropónico a través del Sistema Difuso.

Una vez validado el modelo de red para la inferencia del nivel de estrés hídrico, se continuó con la implementación y pruebas del sistema difuso para el control de riego. Para esto, se realizaron tres experimentos diferentes: 1) pruebas dentro de un ambiente controlado con condiciones ideales de temperatura para la lechuga romana, 2) pruebas dentro del ambiente controlado con temperaturas de calor extremo para la lechuga, y 3) pruebas en el exterior sin control de la temperatura.

4. 2.1. Experimentos en un ambiente controlado con temperatura idónea para la lechuga romana.

Estas pruebas consistieron en trasplantar las plantas de lechuga romana, después de su cuarta semana de desarrollo, al tubo de siembra aeropónico. Después de ser trasplantadas las plantas, se esperó 24 horas para darles tiempo de adaptación. Una vez que se observó que las plantas se encontraban en buenas condiciones, se activó el sistema de control de riego difuso, manteniendo una temperatura ambiente de 20°C e iluminación artificial constante. A partir de ese instante se inició con la toma de datos y acciones de control en intervalos de cinco minutos. En cada intervalo de tiempo el sistema obtiene una imagen de cada planta, transfiere la imagen a la CNN, la cual infiere el nivel de estrés hídrico, realiza la lectura de la temperatura y humedad dentro del tubo, y envía estos datos al sistema difuso. Con estos datos el sistema difuso determina si se activa o no la bomba de riego, y en su caso, determina el tiempo de riego en segundos.

En este primer experimento se realizaron un total de 48 tomas de datos y acciones de control, equivalente a cuatro horas continuas de funcionamiento del sistema. La gráfica de la Figura 4.3 muestra las variables de entrada: “Temperatura” dada en grados centígrados, “Humedad” en porcentaje de humedad relativa, y “Nivel de Estrés Hídrico” en un rango de cero a cuatro; y las variables de salida: “Riego” con dos posibles valores: “1” encendido de la bomba, y “0” apagado de la bomba, y “Tiempo de Riego” dado en segundos.




Figura 4.3: Resultados de las pruebas de control de riego difuso en un ambiente controlado con temperatura ideal para la lechuga romana.

Como se puede observar en la gráfica, la variable “Temperatura”, que es leída al interior del tubo, se logra mantener casi constante en los 20°C, coincidiendo con la temperatura ambiente al exterior del tubo. Por otro lado, la variable “Humedad” que inicia por debajo de 70% al arrancar el experimento, presenta un incremento constante en las primeras muestras, debido a que el sistema activa y mantiene encendida la bomba mientras la humedad no llega al 100% y el nivel de estrés de la planta no baja de dos. Ocurre lo opuesto del intervalo 10 a la 33, donde la humedad disminuye gradualmente mientras la bomba se mantiene apagada.

Además, se puede observar que la variable “Riego” se corresponde muy estrechamente con la variable “Nivel de Estrés Hídrico”. Consideramos que lo anterior sucede así, dado que al mantener una temperatura propicia para las plantas, y mientras el porcentaje de humedad se mantiene por arriba de cierto umbral, el factor determinante para encender o no la bomba es el nivel de estrés de las plantas. A su vez, se puede observar que el nivel de estrés presenta una tendencia a mantenerse, para eventualmente disminuir, mientras se mantiene encendida la bomba, y en ningún caso se incrementa mientras no se apague la bomba.

Durante todo el experimento la variable de salida “Tiempo de Riego” se mantuvo en un

valor bajo aproximado de cuatro segundos. Es decir, en los casos en que se activó la bomba, solo duró prendida cuatro segundos. Y dado que durante las cuatro horas que duró este primer experimento se activó la bomba 14 veces, el tiempo total que estuvo encendida es solo de 56 segundos; lo cual fue suficiente para mantener la humedad dentro del tubo por arriba del 80 % y el nivel de estrés hídrico de las plantas se mantuvo igual o por debajo del nivel en que inició.

4. 2.2. Experimentos en un ambiente controlado con temperatura alta extrema para la lechuga romana.

A diferencia del primer experimento, durante el segundo experimento se mantuvo una temperatura ambiente aproximada de 28 °C, lo cual es una temperatura alta extrema para el desarrollo de las plantas de lechuga romana. En este experimento se realizaron 28 tomas de muestras y acciones de control en intervalos de cinco minutos, con un total de dos horas con 20 minutos de funcionamiento continuo del sistema. Como se puede observar en la gráfica de la Figura 4.4, la temperatura al interior del tubo se mantuvo similar a la temperatura ambiente. Por otro lado, la bomba se activó en cada intervalo de control, con tiempos de riego por arriba de los 30 segundos, lo que mantuvo la humedad en un 100 % durante todo el experimento.

En el caso del nivel de estrés hídrico, durante casi todo el experimento se mantuvo en el nivel dos. Solo en los intervalos 21 y 23 el nivel de estrés subió a tres. Para lo cual el sistema reaccionó con un incremento de tiempo de riego por arriba de los 40 segundos. En total la bomba se mantuvo activa durante 15.45 minutos, equivalente al 11 % del tiempo que duró el experimento. A pesar de las condiciones de temperaturas extremas que se mantuvieron, el sistema logró mantener un nivel estable de humedad y de estrés de las plantas.

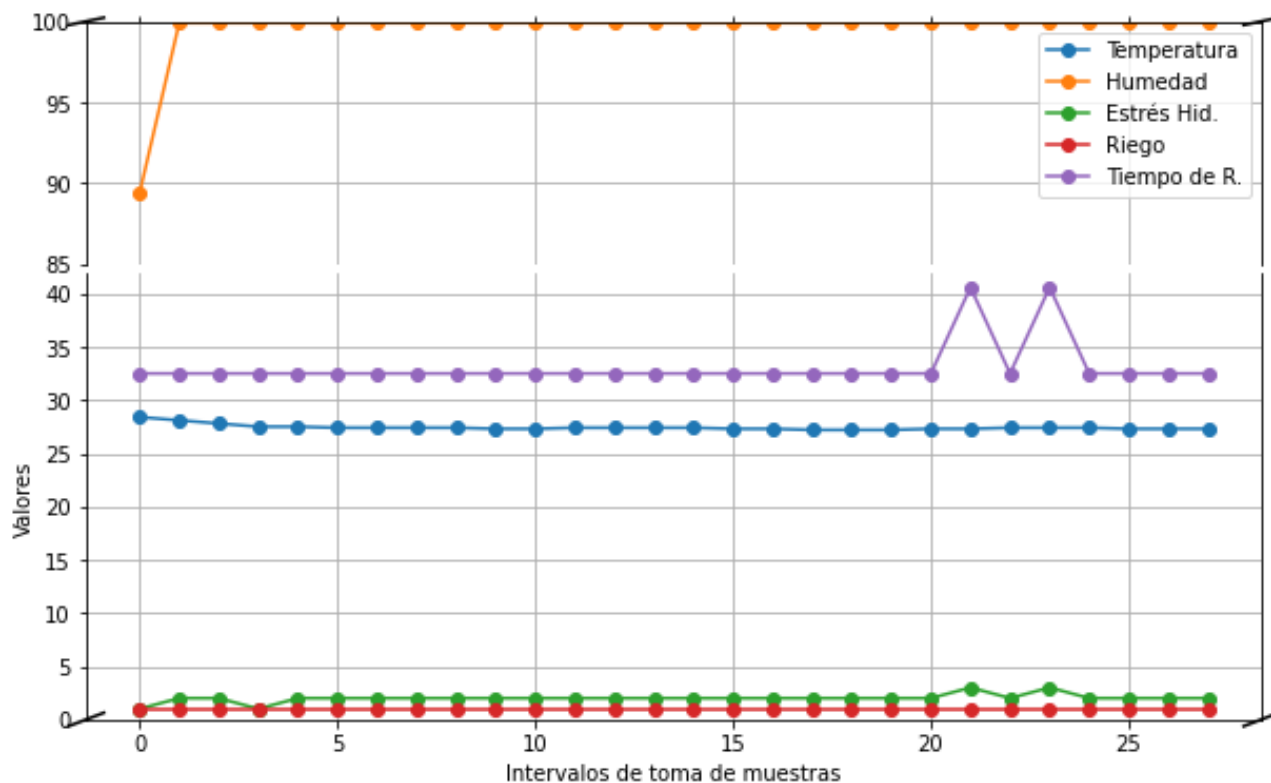


Figura 4.4: Resultados de las pruebas de control de riego difuso en un ambiente controlado con temperatura alta extrema para la lechuga romana.

4. 2.3. Experimentos en el exterior sin control de la temperatura ambiente.

El tercer experimento inició aplicando el mismo procedimiento de trasplantar las plantas en el tubo aeropónico, pero una vez que se adaptaron las plantas dentro del entorno controlado, se colocó el sistema aeropónico al exterior, sin un control especial de la temperatura, y se inició con la toma de muestras y acciones de control. Las pruebas iniciaron a las 6:10 horas de la mañana y concluyeron a las 13:35 horas del medio día, es decir, se mantuvo en funcionamiento ininterrumpido por siete horas con 25 minutos. Como se puede observar en la gráfica de la Figura 4.5, la temperatura del sistema se incrementó casi de forma constante, adaptándose a la temperatura ambiente al exterior del tubo.




Figura 4.5: Resultados de las pruebas de control de riego difuso en el exterior sin control de la temperatura ambiente.

Se puede observar que la humedad se mantuvo al máximo durante los primeros seis intervalos, equivalentes a la primera media hora del experimento, incluso con la bomba apagada. Posteriormente descendió del intervalo 7 al 12, reaccionando el sistema con el encendido de la bomba. Con una sola acción de riego la humedad se incrementó de nuevo al 100 %, por lo que se apagó la bomba. Del intervalo 16 al 27 ocurre un patrón similar de disminución de la humedad con la bomba apagada, hasta el intervalo 28 donde se activa de nuevo la bomba como respuesta al decremento de humedad y al incremento de temperatura cercana a los 25 °C. A partir de que la temperatura rebasó los 25 °C la bomba se activó constantemente en cada intervalo de control, manteniendo la humedad en 100 %.

Por otro lado, se puede observar que al iniciar el experimento el tiempo de riego se mantuvo bajo, cercano a los cinco segundos, mientras la temperatura no rebasó los 25 °C. A partir de ese punto, el tiempo de riego tuvo algunas transiciones a la alta y a la baja, debido cambios simultáneos en las lecturas de la temperatura, humedad y nivel de estrés; hasta mantenerse constante en los 33 segundos a partir del intervalo 38. Ese tiempo de riego solo se incrementó

una vez, hasta los 40 segundos, cuando el sistema detectó por única vez un nivel tres de estrés de las plantas. Esto último ocurrió aproximadamente siete horas después de iniciado el experimento, en pleno medio día con temperaturas cercanas a los 35 °C, las cuales son demasiado extremas para el cultivo de la lechuga romana.

Capítulo 5

Conclusiones y trabajo futuro

5. 1. Conclusiones

Debido al incremento de la temperatura a nivel global y al desabasto de agua, cada vez tomará mayor importancia la implementación de sistemas de cultivo basados en riego inteligente. En este proyecto se propone un sistema de control de riego de cultivo tipo aeropónico para la lechuga romana, basado en técnicas de la Inteligencia Artificial. Específicamente, se propone un sistema de control basado en Lógica Difusa, apoyado por una Red Neuronal Convolutiva para la inferencia del nivel de estrés hídrico de las plantas.

Como parte de los experimentos, el sistema se probó en un entorno controlado con temperatura ambiente de 20 °C, la cual se considera idónea para el desarrollo de la lechuga romana. Bajo estas condiciones, el sistema fue capaz de mantener estables las condiciones de estrés y humedad de las plantas, requiriendo un consumo muy bajo de agua y de energía. Esto es, de las cuatro horas que se mantuvo funcionando el sistema de forma ininterrumpida, solo se encendió la bomba de agua durante 56 segundos; es decir, aproximadamente 14 segundos por cada hora de funcionamiento del sistema.

Por otro lado, bajo temperaturas consideradas extremas para la lechuga romana, de alrededor de los 28 °C, el sistema reaccionó incrementando el tiempo de riego a 33 segundos por cada intervalo de control de cinco minutos, activando la bomba de agua un total de 6.6 minutos por cada hora de funcionamiento del sistema. A pesar de estas temperaturas extremas, el sistema fue capaz de mantener estables las condiciones de estrés y de humedad de las plantas.

De acuerdo a los resultados de los experimentos, consideramos factible la implementación

de los Sistemas Difusos, apoyados con Redes Neuronales Convolucionales, para el control automatizado de sistemas de riego de cultivos de tipo aeropónico. Sobre todo, considerando que, además de mantener en buenas condiciones las plantas, uno de los retos más importantes en la implementación del riego inteligente es requerir de un consumo reducido de agua y de energía.

5. 2. Trabajo futuro

Es importante mencionar algunas de las limitaciones de este proyecto, que dan lugar al planteamiento de nuevos objetivos como trabajo a futuro:

1. El sistema se diseñó específicamente para las condiciones de las plantas de lechuga romana, por lo que adaptar el sistema para otro tipo de cultivo, requiere volver a entrenar la red neuronal a partir de un nuevo conjunto de imágenes. Así mismo, se requiere diseñar nuevos conjuntos y reglas difusas para el control del riego.
2. Las imágenes de las plantas utilizadas para el entrenamiento de la red neuronal, se tomaron en un ambiente con iluminación controlada y con una posición fija de la cámara. Utilizar imágenes con diferentes condiciones de iluminación y desde diferentes ángulos, permitiría generar un modelo de red neuronal más robusto para la inferencia del nivel de estrés hídrico de las plantas.
3. El proyecto consideró únicamente el control de riego para la etapa de crecimiento que presentan las plantas de lechuga cuatro semanas después de su siembra, que es el momento en que se trasplantaron al sistema aeropónico. Consideramos que es factible ampliar el control de riego para las demás etapas de desarrollo de la lechuga.
4. Finalmente, el sistema de riego implementado no realiza un control de los nutrientes y la calidad del agua utilizada. Consideramos que es posible incluir este tipo control en un sistema de riego inteligente.

Bibliografía

- [Andrade-Piedra et al., 2015] Andrade-Piedra, J., Barona, D., Benítez, J., huquillanqui, C., García, M., Kromann, P., Mateus-Rodríguez, J., Montesdeoca, F., Otazú, V., and Potosí, B. (2015). *Manual para la Producción de Semilla de Papa usando Aeroponía: Diez años de Experiencias en Colombia, Ecuador y Perú*. Centro Internacional de la Papa (CIP), Instituto Nacional de Investigaciones Agropecuarias (INIAP), Corporación Colombiana de Investigación Agropecuaria (CORPOICA). Quito, Ecuador. 268 p.
- [Arsenovic et al., 2019] Arsenovic, M., Karanovic, M., Sladojevic, S., Anderla, A., and Stefanovic, D. (2019). Solving current limitations of deep learning based approaches for plant disease detection. *Symmetry*, 11(7):939.
- [Aversano et al., 2022] Aversano, L., Bernardi, M. L., and Cimitile, M. (2022). Water stress classification using convolutional deep neural networks. *JUCS - Journal of Universal Computer Science*, 28(3):311–328.
- [Bandyopadhyay, 2024] Bandyopadhyay, H. (2024). Autoencoders in Deep Learning: Tutorial and Use Cases [2024]. <https://optigarden.es/blog/que-son-los-lumenes-cultivo-interior>.
- [Benito and Duran, 2013] Benito, T. and Duran, M. I. (2013). Lógica borrosa. <https://ingtecnologia.wordpress.com/wp-content/uploads/2011/06/logica-difusa2pdf.pdf>.
- [Chowdhury et al., 2021] Chowdhury, M. E. H., Rahman, T., Khandakar, A., Ayari, M. A., Khan, A. U., Khan, M. S., Al-Emadi, N., Reaz, M. B. I., Islam, M. T., and Ali, S. H. M. (2021). Automatic and reliable leaf disease detection using deep learning techniques. *AgriEngineering*, 3(2):294–312.

- [CONAFOR et al., 2013] CONAFOR, SEMARNAT, and UACH (2013). Línea base nacional de degradación de tierras y desertificación, informe final y anexos i y ii. <https://apps1.semarnat.gob.mx:8443/dgeia/informe15/tema/cap3.html>.
- [Concepcion II et al., 2020] Concepcion II, R., Lauguico, S., Almero, V. J., Dadios, E., Bandala, A., and Sybingco, E. (2020). Lettuce leaf water stress estimation based on thermo-visible signatures using recurrent neural network optimized by evolutionary strategy. In *2020 IEEE 8th R10 Humanitarian Technology Conference (R10-HTC)*, pages 1–6.
- [FAO, 2023] FAO (2023). El estado mundial de la agricultura y la alimentación 2023. <https://openknowledge.fao.org/items/9016b195-c4de-4a8e-a42f-af83861c420b>.
- [Fasciolo et al., 2023] Fasciolo, B., Awouda, A., Bruno, G., and Lombardi, F. (2023). A smart aeroponic system for sustainable indoor farming. *Procedia CIRP*, 116:636–641. 30th CIRP Life Cycle Engineering Conference.
- [Galán et al., 2000] Galán, R., Jiménez, A., Sanz, R., and Matía, F. (2000). Control inteligente. *Inteligencia Artificial. Revista Iberoamericana de Inteligencia Artificial*, pages 1137–3601.
- [Hasan et al., 2020] Hasan, R. I., Yusuf, S. M., and Alzubaidi, L. (2020). Review of the state of the art of deep learning for plant diseases: A broad analysis and discussion. *Plants*, 9(10).
- [Idris and Sani, 2012] Idris, I. and Sani, M. (2012). Monitoring and control of aeroponic growing system for potato production. In *Proceedings of 2012 IEEE Conference on Control, Systems and Industrial Informatics, ICCSII 2012*, pages 120–125.
- [INEGI, 2019] INEGI (2019). Clima, territorio de baja california sur. Monografía del INEGI. <https://www.cuentame.inegi.org.mx/monografias/informacion/bcs/territorio/clima.aspx>.
- [Kamarudin and Ismail, 2022] Kamarudin, M. and Ismail, Z. H. (2022). Lightweight deep cnn models for identifying drought stressed plant. In *IOP Conference Series: Earth and Environmental Science*, volume 1091, page 012043. IOP Publishing.
- [Kerns and Lee, 2017] Kerns, S. C. and Lee, J.-L. (2017). Automated aeroponics system using iot for smart farming. In *8th International Scientific Forum, ISF*, pages 7–8.

- [Kumar, 2001] Kumar, A. (2001). Cnn basic architecture for classification and segmentation. Extracción de la revista Data Analytics. <https://vitalflux.com/cnn-basic-architecture-for-classification-segmentation>.
- [Lakhiar et al., 2018] Lakhiar, I., Gao, J., Syed, T., Chandio, F. A., and Buttar, N. (2018). Modern plant cultivation technologies in agriculture under controlled environment: a review on aeroponics. *Journal of Plant Interactions*, 13.
- [Lucero et al., 2020] Lucero, L., Lucero, D., Ormeno-Mejia, E., and ollaguazo, G. (2020). Automated aeroponics vegetable growing system. case study lettuce. In *2020 IEEE ANDESCON*, pages 1–6.
- [Majid et al., 2021] Majid, M., Khan, J. N., Ahmad Shah, Q. M., Masoodi, K. Z., Afroza, B., and Parvaze, S. (2021). Evaluation of hydroponic systems for the cultivation of lettuce (*lactuca sativa* l., var. *longifolia*) and comparison with protected soil-based cultivation. *Agricultural Water Management*, 245:106572.
- [Martínez, 2012] Martínez, J. C. (2012). Propagación y técnicas de cultivo de la lechuga (*lactuca sativa*). *Revista vinculando*, 10(2). <https://vinculando.org/mercado/agroindustria/propagacion-y-tecnicas-de-cultivo-de-la-lechuga-lactuca-sativa.html>.
- [Mithunesh et al., 2015] Mithunesh, P., Gupta, K., Ghule, S., and Hule, P. (2015). Aeroponic based controlled environment based farming system. *IOSR Journal of Computer Engineering (IOSR-JCE)*, 17(6):55–58.
- [Montoya et al., 2017] Montoya, A. P., Obando, F. A., Morales, J. G., and Vargas, G. (2017). Automatic aeroponic irrigation system based on arduino’s platform. *Journal of Physics: Conference Series*, 850(1):012003.
- [Morales, 2015] Morales, N. (2015). ¿qué es la aeroponía? <https://agriculturers.com/que-es-la-aeroponia/>.
- [Márquez, 2020] Márquez, F. (2020). *Diseño y caracterización de sistema aeropónico automatizado para el cultivo de Stevia rebaudiana*. PhD thesis, Centro de Investigaciones Biológicas del Noroeste.

- [Ngugi et al., 2020] Ngugi, L., Abelwahab, M., and Abo-Zahhad, M. (2020). Recent advances in image processing techniques for automated leaf pest and disease recognition - a review. *Information Processing in Agriculture*, 8.
- [Prieto, 2021] Prieto, S. S. (2021). Aeroponía: cultivo sin tierra. *+Ciencia*, (27):26–27.
- [Priyanka et al., 2020] Priyanka, B. J., Sharm, R., Somanna, A. G., Sathyamurthy, S. K., and Aruna, M. (2020). Digital farming using aeroponics. *Journal of Emerging Technologies and Innovative Research (JETIR)*, 7(10):17–24.
- [Quintero, 1997] Quintero, J. J. (1997). La lechuga. 1(1077):1–20.
- [Rahman et al., 2020] Rahman, C. R., Arko, P. S., Ali, M. E., Iqbal Khan, M. A., Apon, S. H., Nowrin, F., and Wasif, A. (2020). Identification and recognition of rice diseases and pests using convolutional neural networks. *Biosystems Engineering*, 194:112–120.
- [Sharif et al., 2018] Sharif, M., Khan, M. A., Iqbal, Z., Azam, M. F., Lali, M. I. U., and Javed, M. Y. (2018). Detection and classification of citrus diseases in agriculture based on optimized weighted segmentation and feature selection. *Computers and Electronics in Agriculture*, 150:220–234.
- [Tian et al., 2019] Tian, K., Li, J., Zeng, J., Evans, A., and Zhang, L. (2019). Segmentation of tomato leaf images based on adaptive clustering number of k-means algorithm. *Computers and Electronics in Agriculture*, 165:104962.
- [Valdivia, 2010] Valdivia, H. E. (2010). *Efecto de dos sistemas de riego, goteo y gravedad, sobre el rendimiento del algodonoero*. PhD thesis, Universidad Autonoma de Baja California.
- [Verdhan, 2021] Verdhan, V. (2021). *Computer Vision Using Deep Learning, Neural Network Architectures with Python and Keras*. Apress.
- [Zadeh, 1965] Zadeh, L. (1965). Fuzzy sets. *Information and Control*, 8(3):338–353.