

Universidad de Lima
Facultad de Ingeniería
Carrera de Ingeniería de Sistemas



SISTEMA DE RIEGO AUTOMATIZADO PARA SOLANUM LYCOPERSICUM CON IOT Y MODELOS PREDICTIVOS PARA EL AHORRO DE AGUA EN ENTORNOS URBANOS

Tesis para optar el Título Profesional de Ingeniero de Sistemas

Sebastian Santiago Hermosa Caceres

Código 20182701

Jesus Alejandro Anci Yep

Código 20180084

Asesor

Edwin Manuel Alvarez Valdivia

Lima – Perú

Junio de 2025

Sistema de riego automatizado para *Solanum lycopersicum* con IoT y modelos predictivos para el ahorro de agua en entornos urbanos

Sebastián Hermosa Cáceres
20182701@aloe.ulima.edu.pe
Universidad de Lima

Alejandro Anci Yep
20180084@aloe.ulima.edu.pe
Universidad de Lima

Resumen: La presente investigación desarrolla un sistema automatizado para la irrigación inteligente de cultivos de tomate (*Solanum lycopersicum* var. *cerasiforme*) basado en el Internet de las Cosas (IoT) y algoritmos de predicción, con el fin de optimizar el uso de agua en la agricultura urbana de Lima Metropolitana. El sistema utiliza sensores inalámbricos para medir la humedad del suelo y la temperatura del ambiente, datos que son almacenados en la nube mediante Firestore. Con esta información, se realizan simulaciones y cálculos de riego, además de aplicar modelos predictivos como ARIMA y Random Forest para predecir la temperatura y humedad, respectivamente. Posteriormente, el sistema activa una bomba que riega el cultivo de acuerdo con los resultados obtenidos. La implementación del sistema logró una mejora del 20% en verano y 25% en invierno en la eficiencia del uso del agua, reduciendo el desperdicio asociado a las técnicas tradicionales de riego. Los resultados demuestran que la integración de IoT y algoritmos de predicción ofrece una solución viable para la agricultura sostenible en entornos urbanos.

Palabras Clave: Vida en ecosistemas terrestres, agua limpia y saneamiento, riego urbano, internet de las cosas, aprendizaje máquina

Abstract: This research develops an automated system for the intelligent irrigation of tomato crops (*Solanum lycopersicum* var. *cerasiforme*) based on the Internet of Things (IoT) and predictive algorithms, aimed at optimizing water use in urban agriculture in Metropolitan Lima. The system employs wireless sensors to measure soil moisture and ambient temperature, with the data being stored in the cloud using Firestore. This information is used for simulations and irrigation calculations, while predictive models like ARIMA and Random Forest are applied to forecast water needs. Subsequently, the system activates a pump to irrigate the crops according to the results obtained. The implementation of the system achieved a 20% improvement in water use efficiency during the summer and a 25% improvement during the winter, reducing waste associated with traditional irrigation techniques. The results demonstrate that the integration of IoT and predictive algorithms offers a viable solution for sustainable agriculture in urban environments.

Keywords: Life on land ecosystems, clean water and sanitation, urban irrigation, internet of things (IoT), machine learning.

1. INTRODUCCIÓN

El uso eficiente del agua es un desafío creciente, especialmente en áreas urbanas donde los recursos hídricos son limitados y la demanda sigue aumentando. En el sector agrícola, que utiliza aproximadamente el 70% del agua disponible a nivel mundial, las prácticas tradicionales de irrigación han demostrado ser ineficaces, generando un importante desperdicio de agua (Khan et al., 2018). Este problema se acentúa en las ciudades, donde los cultivos urbanos y jardines suelen recibir más agua de la necesaria debido al desconocimiento de las necesidades hídricas de las plantas, lo que no solo incrementa el gasto económico, sino que también afecta la sostenibilidad del agua (Zhang et al., 2022).

Lima Metropolitana, una ciudad ubicada en un desierto, enfrenta este problema de manera aguda. Los patrones de consumo de agua son alarmantes, superando los 200 litros de agua potable por persona en distritos como San Isidro, La Molina y Miraflores (Gestión, 2022), muy por encima de los niveles recomendados. En un contexto donde la agricultura urbana está en crecimiento, se hace evidente la necesidad de sistemas más eficientes que permitan optimizar el uso de agua para el riego de plantas, como el *Solanum lycopersicum* o tomate, uno de los cultivos más comunes en jardines y huertos urbanos.

El problema central de esta investigación se enfoca en el desperdicio de agua en la agricultura urbana y cómo las técnicas de irrigación actuales no responden adecuadamente a las condiciones específicas de las plantas y el entorno. El uso excesivo de agua para el riego no solo afecta la disponibilidad de este recurso vital, sino que también puede comprometer la salud de las plantas, especialmente cuando no se monitorizan factores como la humedad del suelo o la temperatura ambiente (Parkash et al., 2020).

En respuesta a este problema, el objetivo de este estudio es desarrollar un sistema automatizado de irrigación inteligente que, mediante el uso de sensores inalámbricos y algoritmos de predicción basados en el Internet de las Cosas (IoT), permita optimizar el uso del agua en cultivos urbanos. El sistema propuesto medirá en tiempo real la humedad y la temperatura, almacenando estos datos en la nube para realizar el cálculo de riego. Posteriormente, el sistema ajustará el riego de manera automática, utilizando una bomba para aplicar la cantidad exacta de agua que el cultivo necesita, reduciendo así el desperdicio. Por último, se generan predicciones precisas sobre la cantidad de agua necesaria para el riego del siguiente día que se utilizarán para medir si el agua restante en el depósito es suficiente para regar el siguiente día.

En este trabajo, se describen los antecedentes del uso de IoT y algoritmos predictivos en la agricultura urbana, así como los componentes tecnológicos empleados en la investigación. Finalmente, se discuten los resultados obtenidos a partir de la implementación del sistema en cultivos de tomate en Lima Metropolitana, evaluando su impacto en la eficiencia del uso del agua y la salud de los cultivos.

2. ESTADO DEL ARTE

2.1 SISTEMA DE INTERNET DE LAS COSAS

El Internet de las Cosas (IoT) ha demostrado ser una herramienta fundamental en la optimización de procesos agrícolas, especialmente en la automatización del riego y la gestión eficiente del agua. Diferentes estudios han abordado el impacto del IoT en la agricultura desde diversas perspectivas, lo que permite identificar avances, coincidencias y vacíos en la investigación actual.

Shafi et al. (2020) centraron su estudio en la modernización del monitoreo agrícola en Pakistán mediante sensores IoT y drones, destacando que la integración de redes neuronales profundas permitió alcanzar una precisión del 98.4% en la evaluación de la salud de los cultivos. Sin embargo, su enfoque estaba dirigido a grandes extensiones de terreno, lo que limita su aplicabilidad en entornos urbanos. Por otro lado, Zhang et al. (2022) desarrollaron un sistema de riego basado en IoT con tecnología LoRaWAN para optimizar la producción de tomate en plasticultura. Sus resultados evidenciaron una reducción del 22.1% en el consumo de agua sin afectar la producción, lo que evidencia la eficiencia del IoT en la gestión hídrica. A diferencia de Shafi et al., este estudio se enfocó en cultivos específicos y en la optimización del consumo de agua.

Ambos estudios coinciden en que el IoT permite una gestión más eficiente de los cultivos al reducir la dependencia del monitoreo manual. No obstante, presentan diferencias en sus enfoques tecnológicos: mientras que Shafi et al. priorizan la precisión mediante el uso de drones y modelos de aprendizaje profundo, Zhang et al. enfatizan la eficiencia en la transmisión de datos mediante redes de baja potencia.

A pesar de estos avances, aún persisten desafíos en la implementación de sistemas IoT en entornos urbanos. Munusamy et al. (2021) presentaron un sistema de riego automatizado basado en sensores de humedad y temperatura, destacando la importancia de la conectividad a través de módulos como el Arduino Mega 2560. Sin embargo, su enfoque no considera la predicción del consumo de agua, lo que limita la optimización del recurso. Por otro lado, Xue y Wang (2021) abordaron la eficiencia energética en redes de sensores IoT para la agricultura inteligente, proponiendo mejoras en los protocolos de enrutamiento y algoritmos de posicionamiento. Aunque lograron aumentar la precisión del monitoreo, su estudio no abarcó la automatización del riego basada en predicciones.

2.2 HUMEDAD RELATIVA Y CRECIMIENTO DEL TOMATE

El crecimiento del tomate (*Solanum lycopersicum*) está influenciado por diversos factores ambientales, siendo la humedad relativa uno de los más determinantes en su desarrollo y en la optimización del riego. Estudios previos han analizado el impacto de la humedad en la fisiología del tomate, proponiendo distintos enfoques para evaluar el estrés hídrico y mejorar la eficiencia en el uso del agua.

Concepción II et al. (2020) utilizaron visión por computadora y redes neuronales recurrentes para predecir el contenido de humedad en lechugas, logrando estimaciones precisas del estrés hídrico en tiempo real. Sin embargo, su estudio se enfocó en hortalizas de rápido crecimiento y no en cultivos como el tomate, que presenta un ciclo fenológico más prolongado y requiere ajustes en la estrategia de riego. Por otro lado, Parkash et al. (2020) evaluaron la eficacia de distintos indicadores de estrés hídrico, concluyendo que las mediciones basadas en la planta son más precisas que aquellas basadas únicamente en la humedad del suelo. A diferencia de Concepción II et al., quienes emplearon un enfoque de predicción automatizado, Parkash et al. sugieren la necesidad de combinar técnicas de medición en la planta con modelos de aprendizaje automático para lograr estimaciones más precisas.

Desde un enfoque más tradicional, Swalls y O'Leary (1975) demostraron que la alta humedad relativa favorece el crecimiento del tomate al incrementar la biomasa, aunque con el efecto adverso de reducir la absorción de calcio en las raíces y tallos. Este hallazgo sigue siendo relevante en la actualidad, ya que explica por qué un exceso de humedad puede afectar la salud de la planta. Sin embargo, este estudio no consideró cómo la variabilidad climática actual podría influir en estos efectos, lo que abre la necesidad de desarrollar sistemas de monitoreo en tiempo real.

Si bien estos estudios han avanzado en la comprensión del impacto de la humedad en los cultivos, aún existen desafíos en su aplicación en agricultura urbana, donde los microclimas y la disponibilidad de agua son factores clave. Huang et al. (2018) analizaron la evapotranspiración del tomate en función de su desarrollo radicular y determinaron que el coeficiente de cultivo varía significativamente según la fase de crecimiento. Esto sugiere que los sistemas de riego deben ser dinámicos y adaptarse a cada etapa del cultivo. No obstante, su estudio no consideró la integración de tecnologías como el IoT para ajustar el riego de manera automatizada.

2.3 HERRAMIENTAS PARA PREDICCIÓN DE RIEGO

El riego eficiente es un factor crítico en la agricultura urbana, y los modelos de predicción han demostrado ser herramientas clave para optimizar el consumo de agua en cultivos. Distintos enfoques han sido utilizados para predecir la cantidad de agua necesaria para el riego, desde algoritmos tradicionales hasta técnicas avanzadas de aprendizaje automático.

El estudio de Michalis et al. (2023) evalúa la viabilidad económica de una explotación hidropónica de tomates en Grecia, destacando la importancia de la gestión eficiente del agua y la energía en la agricultura urbana. Aunque no aborda directamente el uso de modelos ARIMA (AutoRegressive Integrated Moving Average) en la predicción de series temporales agrícolas, su enfoque en la agricultura urbana resalta la necesidad de adaptar herramientas analíticas, como ARIMA, para mejorar la precisión en entornos urbanos donde las condiciones microclimáticas son más variables. Por otro lado, Jingxin Yu et al. (2020) propusieron una variante de redes neuronales, el modelo ResBiLSTM, que combina redes residuales y memoria a largo plazo para predecir el contenido de agua en el suelo. Este modelo logró una mejora del 14% en la precisión con respecto a modelos tradicionales, como las LSTM estándar, alcanzando un error cuadrático medio (MSE) promedio de solo 0.59% y un R^2 de 98.86% para predicciones de tres días. A diferencia de ARIMA, este modelo puede capturar relaciones no lineales, lo que lo hace más flexible ante cambios en las condiciones climáticas.

El estudio de Fernández Fernández (2023) explora técnicas avanzadas de regresión para estimar parámetros agronómicos en cultivos de cereales, destacando la eficacia de la regresión polinómica para capturar relaciones no lineales entre variables climáticas y rendimiento de cultivos. En particular, se observa que la regresión polinómica de segundo grado alcanzó un coeficiente de determinación R^2 de hasta 0.89 y un error cuadrático medio (RMSE) reducido en un 18% en comparación con modelos lineales simples, lo que evidencia una mejora sustancial en la capacidad predictiva. Este enfoque permite mejorar la precisión de las estimaciones, pero el estudio también subraya que la elección del grado del polinomio es crucial: grados demasiado altos pueden llevar a problemas de sobreajuste, disminuyendo la capacidad de generalización del modelo y afectando negativamente su rendimiento en datos no vistos. Por otro lado, el estudio de Dhillon et al. (2023) demuestra la eficacia del modelo Random Forest en la predicción del rendimiento de cultivos agrícolas mediante la integración de datos climáticos y de teledetección. Aunque su enfoque principal es la predicción del rendimiento de trigo de invierno y colza, los resultados confirman que Random Forest maneja mejor la variabilidad de los datos y minimiza el sobreajuste en comparación con otros métodos tradicionales, haciéndolo más robusto en entornos con alta incertidumbre. A diferencia de la regresión polinómica, este enfoque maneja mejor la variabilidad de los datos y reduce el impacto del sobreajuste gracias a su estructura basada en múltiples árboles de decisión, lo que lo hace más robusto en entornos con alta incertidumbre. Finalmente, la regresión lineal múltiple sigue siendo una herramienta ampliamente utilizada en estudios agrícolas. Palominos-Rizzo et al. (2022) implementan este modelo para estimar la humedad del suelo en Llano Brenes, Costa Rica, utilizando variables como temperatura y precipitación. Aunque su simplicidad permite interpretaciones claras y rápidas, su capacidad predictiva es limitada cuando las relaciones entre variables son no lineales o presentan interacciones complejas. En comparación con modelos como Random Forest, la regresión lineal puede no captar la complejidad de los datos ambientales, pero sigue siendo una opción viable en contextos donde la transparencia del modelo es prioritaria.

En cuanto a enfoques híbridos, Shilpa Chandra et al. (2021) diseñaron un sistema automático de riego para cultivos de tomate en India, combinando sensores de humedad con el algoritmo K-Nearest Neighbors (KNN) para predecir cuándo regar. Además, emplearon la ecuación de Blaney-Criddle para calcular la evapotranspiración y determinar la cantidad de agua necesaria en cada ciclo de riego. Los resultados mostraron un ahorro significativo de agua en comparación con métodos tradicionales, pero el estudio no consideró la implementación de sistemas IoT para la automatización completa del riego.

A pesar de estos avances, aún existen desafíos en la integración de modelos de predicción con sensores IoT. Munusamy et al. (2021) presentaron un sistema de riego automático basado en sensores múltiples y Arduino, pero sin incorporar modelos predictivos avanzados. Por su parte, Xue y Wang (2021) optimizaron protocolos de comunicación en redes de sensores IoT, pero sin enfocarse en la predicción del consumo de agua.

3. MARCO TEÓRICO

3.1 FACTORES AMBIENTALES Y TÉCNICAS DE CULTIVO EN LA PRODUCCIÓN AGRÍCOLA

Dentro de los factores ambientales que influyen en el desarrollo vegetal, la temperatura juega un papel clave, ya que afecta el ritmo de crecimiento y la formación de hojas y tallos. Cuando la temperatura se incrementa dentro de un rango óptimo, los procesos fisiológicos de las plantas se aceleran. Sin embargo, mientras que las temperaturas elevadas pueden ser manejadas mediante estrategias agrícolas, el impacto de las temperaturas bajas, especialmente las heladas, es más difícil de contrarrestar (FAO, 2020).

Otro factor fundamental es la humedad del suelo, que influye en los ciclos de agua, energía y carbono. Esta humedad es esencial tanto para la agricultura como para la vegetación natural, ya que determina la disponibilidad de agua para la evapotranspiración y regula la infiltración y escorrentía, lo que impacta directamente en el suministro de agua subterránea y en la distribución de nutrientes (Palominos et al., 2022). En el contexto agrícola, el agua es un recurso indispensable para el crecimiento de los cultivos, y su disponibilidad proviene de diversas fuentes como la lluvia, los ríos, los lagos y los acuíferos subterráneos. Además de ser crucial para la fotosíntesis y la absorción de nutrientes, el agua también se usa para proteger las plantas contra heladas y mejorar la estructura del suelo (Pedrozo, 2022). Un ejemplo de la interacción entre el ambiente y la producción agrícola es el cultivo del tomate, el cual se adapta bien a climas cálidos y templados. Sin embargo, su desarrollo se ve afectado por factores como la altitud, la humedad y las condiciones climáticas. Durante la temporada de lluvias, las enfermedades son más comunes, mientras que en épocas secas, las plagas representan la principal amenaza. Para minimizar estos problemas, es fundamental aplicar estrategias agrícolas adecuadas, como técnicas de manejo y control fitosanitario, que garantizan una cosecha exitosa (Chemonics Inc., 2008).

3.2 INTERNET DE LAS COSAS

El Internet de las Cosas (IoT) es una tecnología que permite la interconexión de dispositivos físicos a través de redes digitales, facilitando la recopilación y el análisis de datos en tiempo real. En el ámbito agrícola, el IoT ha demostrado ser una herramienta clave para optimizar el uso de recursos, mejorar la eficiencia en la producción y reducir el desperdicio de agua mediante sistemas automatizados de riego (Atzori et al., 2010).

En la agricultura de precisión, los sensores IoT recopilan datos sobre humedad del suelo, temperatura ambiental y otros parámetros críticos, permitiendo la toma de decisiones automatizada. Según Verdouw et al. (2016), la combinación de IoT con modelos de predicción y aprendizaje automático puede mejorar significativamente la eficiencia hídrica, minimizando el uso innecesario de agua en los cultivos.

3.2.1 COMPONENTES DE HARDWARE EN EL SISTEMA IOT

Para la implementación del sistema de riego automatizado, se emplearon diversos dispositivos IoT que permiten capturar datos ambientales, procesarlos y tomar decisiones en tiempo real. A continuación, se detallan los principales componentes utilizados en la investigación:

El HW-103A es un sensor de humedad de suelo ampliamente utilizado en la agricultura para medir la cantidad de agua en el sustrato. Su funcionamiento se basa en dos electrodos que funcionan como un condensador, y el suelo circundante hace las veces de material dieléctrico que almacena la carga (Duarte-Gonzales, 2020). En esta investigación, el sensor se conecta al ESP8266, permitiendo la transmisión de datos a la nube y la activación automática del riego cuando los niveles de humedad descienden por debajo del umbral establecido.

Tabla 3.1*Características del sensor de humedad de tierra, HW-103A*

Característica	Descripción
Modelo	Sensor HW-103A
Voltaje	3.3V~5V
Dimensiones	Approx. 3cm x 1.5cm
Longitud del Cable	Approx. 21cm
Dimensiones del Sensor	Approx. 6cm x 3cm
VCC	3.3V~5V
GND	GND
DO	Interfaz de salida digital (0 y 1)
AO	Interfaz de salida analógica

El DHT11 es un sensor digital ampliamente utilizado en el monitoreo de temperatura y humedad en aplicaciones agrícolas. Según Gutiérrez et al. (2022), este sensor es de bajo costo y facilidad de integración en sistemas automatizados de riego. Ha sido empleado en diversos estudios, como los de Gutiérrez et al. (2021) y González et al. (2019), para optimizar el riego en cultivos urbanos, permitiendo una precisión de hasta 95%. En esta investigación, su integración con Firebase Cloud facilita el almacenamiento y análisis de datos en tiempo real, mejorando la toma de decisiones para la gestión hídrica.

Tabla 3.2*Característica sensor de humedad y temperatura del ambiente, DHT11*

Característica	Descripción
Modelo	DHT11
Voltaje nominal	3V-5V DC
Rango de temperatura	0 a 50 °C
Presión de medición	±2.0 °C
Rango de humedad	20% a 90% RH.
Presión de humedad	4% RH.

El módulo relé de 5V es un componente clave en sistemas de automatización agrícola, ya que permite activar dispositivos de mayor voltaje a partir de señales de bajo consumo. Robles et al. (2023) explican que los módulos relé se utilizan en sistemas de riego automatizado para controlar bombas de agua de manera eficiente. En este estudio, el

ESP8266 envía señales al relé cuando se detectan niveles bajos de humedad en el suelo, permitiendo la activación automática del riego. Esto garantiza que el agua sea suministrada solo cuando es necesaria, evitando desperdicios.

Tabla 3.3

Característica módulo relay 1CH 5VDC

Característica	Descripción
Modelo	Relay 1CH 5VDC
Señal de control	(3.3V o 5V)
N° Relay	1CH
Capacidad máxima	10A/250 VAC, 10A/30VDC
Corriente máxima	10A (NO), 5A (NC)
Tiempo de acción	10 ms / 5ms

Las mini bombas de agua sumergibles de 6V son ampliamente utilizadas en la automatización del riego en agricultura urbana debido a su eficiencia energética y facilidad de integración con sistemas IoT (Penagos-Figueredo y Velasco-Olarte, 2023). Estas permiten ajustar el volumen de agua suministrado a los cultivos mediante el uso de relés y microcontroladores. En la presente investigación, la bomba se activa únicamente cuando los niveles de humedad del suelo caen por debajo de un umbral predefinido, lo que optimiza el consumo de agua y evita el riego innecesario.

Tabla 3.4

Características de la mini bomba de agua 5V

Característica	Descripción
Modelo	Mini Bomba de Agua Sumergible 5v
Voltaje DC	2.5-6V
Caudal	80-120 L/H
Potencia	0.4-1.5W
Corriente	800mA

El HC-SR04 es un sensor ultrasónico utilizado en sistemas de riego automatizado para medir la distancia entre el sensor y la superficie del agua, funcionando mediante la emisión de pulsos ultrasónicos que rebotan en la superficie y midiendo el tiempo que tarda en recibir el eco (Fierro Muñiz, 2023). Su capacidad de detección de distancias permite monitorear el volumen de agua restante y activar alertas cuando es necesario rellenar el contenedor. Este sensor se ha integrado en diversas soluciones de monitoreo de recursos hídricos, facilitando la gestión eficiente

del agua en entornos agrícolas. En este estudio, el HC-SR04 está vinculado al ESP8266, permitiendo la recopilación de datos en tiempo real y su análisis en la nube.

Tabla 3.5

Características del Sensor ultrasónico HC-SR04

Característica	Descripción
Modelo	HC-SR04 Ultrasonic Module
Voltaje	DC 5V
Frecuencia	40 KHz
Rango	2 – 400 cm
Corriente	15mA

El ESP8266 es un microcontrolador ampliamente utilizado en aplicaciones IoT debido a su conectividad WiFi, bajo consumo energético y compatibilidad con múltiples sensores (Kodali y Mahesh, 2016). Según Saptadi (2014), su implementación en sistemas de riego permite la automatización del proceso mediante la recopilación de datos en tiempo real y la activación remota de dispositivos. En esta investigación, se emplearon tres módulos ESP8266 para la captura de datos, el control del riego y el monitoreo del nivel de agua.

Tabla 3.6

Características del microcontrolador NodeMCU ESP8266

Característica	Descripción
Modelo	NodeMCU ESP8266
Voltaje	3.3V
Voltaje de Ingreso	7-12V
Pin Digital	16
Pin Analog Input	1
Pin GND	4
Velocidad	80 MHz

3.3 APRENDIZAJE MÁQUINA

El machine learning es la ciencia de desarrollo de algoritmos y modelos estadísticos que utilizan los sistemas de computación con el objetivo de ejecutar instrucciones explícitas, en vez de basarse en patrones e inferencias. A partir de esta ciencia, podemos realizar procesos complejos y optimizar procesos. Es una técnica de análisis de datos que predice el valor de datos desconocidos (variable dependiente) usando el valor de datos relacionados y conocidos (variables independientes). Destaca por su sencilla aplicación y se usa principalmente para convertir datos sin procesar de forma confiable y predecible.

Para la predicción de la temperatura se utilizó el modelo predictivo ARIMA. Este modelo es un enfoque sistemático para la modelación predictiva de series temporales tanto estacionarias como no estacionarias. La expresión general de un modelo ARIMA se describe como una función lineal múltiple de los datos históricos de períodos anteriores y los errores de predicción pasados (Michalis et al., 2023).

Para obtener la reducción de la humedad según intervalo de tiempo se utilizó la regresión lineal múltiple. La regresión lineal múltiple es una técnica estadística utilizada para modelar la relación entre una variable dependiente y múltiples variables independientes. En el estudio de Palominos-Rizzo et al. (2022), esta técnica se empleó para predecir la humedad del suelo en una finca cafetalera en Llano Brenes, Costa Rica, utilizando variables meteorológicas como temperatura, precipitación y humedad relativa. El uso de la regresión lineal múltiple en la agricultura permite optimizar el uso del agua y mejorar la productividad de los cultivos mediante decisiones basadas en datos. Este enfoque es especialmente relevante en zonas donde la disponibilidad de agua es un factor limitante para la producción agrícola.

Además, se utilizó la regresión polinómica para capturar relaciones no lineales entre variables climáticas y la predicción del rendimiento de cultivos. A diferencia de la regresión lineal, la regresión polinómica permite modelar interacciones más complejas entre temperatura, humedad y otras variables meteorológicas. Fernández Fernández, A. (2023) demostró que este enfoque mejora la precisión de las predicciones en comparación con modelos lineales simples, aunque su desempeño depende de la selección adecuada del grado del polinomio. Un grado demasiado alto puede generar sobreajuste, afectando la capacidad de generalización del modelo.

Por otro lado, Random Forest Regression fue utilizado para mejorar la robustez de las predicciones, especialmente en la estimación de temperatura y humedad. Dhillon et al. (2023) demuestran la eficacia del modelo Random Forest en la predicción del rendimiento de cultivos agrícolas mediante la integración de datos climáticos y de teledetección. La ventaja de Random Forest radica en su capacidad para manejar grandes volúmenes de datos con menor riesgo de sobreajuste, gracias a su estructura basada en múltiples árboles de decisión, lo que lo hace ideal para entornos con alta variabilidad climática.

Asimismo, se incorporó el modelo de redes neuronales LSTM (Long Short-Term Memory), una variante de las redes neuronales recurrentes diseñada para capturar relaciones temporales en datos secuenciales. Este enfoque ha demostrado ser altamente efectivo en la predicción de series temporales agrícolas, como el contenido de humedad del suelo y la evapotranspiración. Jingxin Yu et al. (2020) implementaron el modelo ResBiLSTM, una combinación de redes residuales y LSTM, logrando un aumento del 14% en la precisión de la predicción del contenido de agua en el suelo respecto a métodos tradicionales. La capacidad de LSTM para retener información de largo plazo en secuencias temporales la hace una herramienta valiosa para modelar el comportamiento dinámico de variables agrícolas, como la humedad y la demanda de riego.

3.4 EVOTRANSPIRACIÓN

La evapotranspiración es el proceso que combina la evaporación del agua desde superficies como el suelo o masas de agua, y la transpiración de agua desde las plantas. Es un componente clave del ciclo del agua, crucial para entender los balances de humedad en diferentes ecosistemas y para la gestión de los recursos hídricos, especialmente en la agricultura y la hidrología. (Rungee et al., 2021)

De acuerdo con Shilpa Chandra et al. (2021), la fórmula utilizada para calcular la evapotranspiración es: $ET_0 = p (0.46 T_{mean} + 8)$, donde T_{mean} representa el promedio de temperatura diario y p es el promedio diario de las horas de luz. A continuación, se aplica la fórmula $ET_{crop} = ET_0 * K_c$, donde K_c es un coeficiente que incorpora las características y efectos específicos del suelo. El valor calculado para el tomate varía según la fase de desarrollo, siendo 0.45 en la fase inicial, 0.75 durante el desarrollo del cultivo, 1.15 en la media estación y 0.80 en la estación tardía. La humedad en los cultivos o macetas se puede dividir en tres subzonas; en este caso, se trabaja en la subzona de evapotranspiración, cuyo límite está dado por la profundidad de las raíces del cultivo, que en el caso del tomate varía entre 30 y 60 cm (Huang et al., 2018). Para calcular el promedio diario de horas de luz, es necesario tener en cuenta la latitud, ya que las horas de luz cambian según el mes. Lima, ubicada a los 12° de latitud sur, presenta una variabilidad estacional en la cantidad de luz solar disponible (Sánchez, 2022).

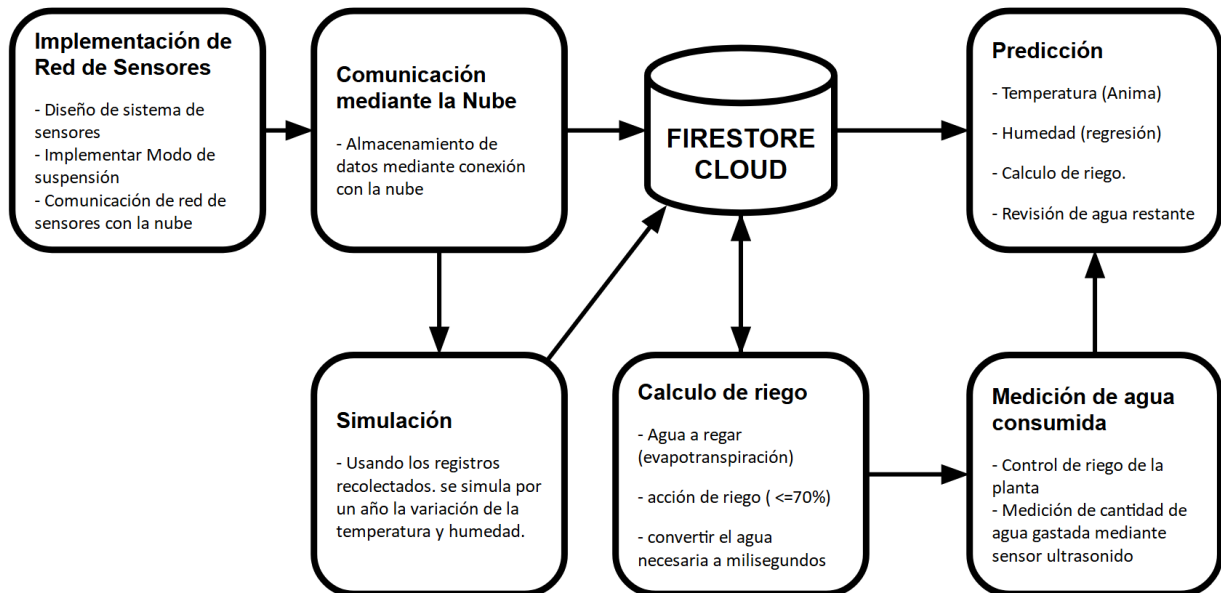
4. METODOLOGÍA

Para el desarrollo de la presente investigación, se establecieron las siguientes fases metodológicas: implementación de la red de sensores, comunicación mediante la nube, almacenamiento en la base de datos Firestore Cloud, simulación de datos, cálculo del riego, medición del consumo de agua y predicción de requerimientos hídricos, como se ilustra en la Figura 4.1. Estas fases se desarrollan de manera secuencial y estructurada para garantizar la funcionalidad del sistema.

El proceso inicia con la instalación de sensores diseñados para capturar datos ambientales y del suelo, los cuales son enviados a la base de datos Firestore a través de la nube. Durante la fase inicial del proyecto, se implementó una simulación para generar datos con el fin de alimentar el modelo de predicción. A medida que se acumulan datos reales, la relevancia de los datos simulados disminuye progresivamente. Posteriormente, se lleva a cabo el cálculo de los requerimientos hídricos con base en las mediciones recopiladas. A continuación, se ejecuta el proceso de predicción, que emplea tanto los datos capturados en tiempo real como los datos históricos almacenados en la base de datos, con el propósito de determinar si el riego será necesario en el día siguiente y cuánta agua se requerirá. Finalmente, los resultados del análisis son extraídos desde la nube para activar el sistema de riego de manera automatizada. En la Figura 4.1 podemos observar el orden del proceso metodológico.

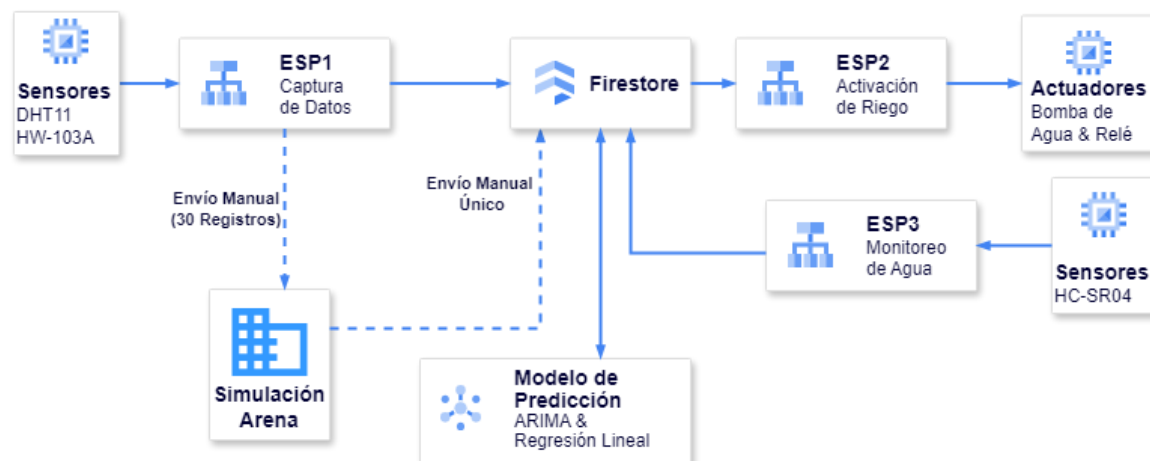
Figura 4.1

Flujo de la metodología propuesta



El sistema de riego automatizado se diseñó utilizando dispositivos IoT basados en el microcontrolador ESP8266, los cuales permiten la captura, el almacenamiento y el procesamiento de datos en la nube mediante la plataforma Firebase. La arquitectura del sistema se compone de tres módulos principales: ESP1, ESP2 y ESP3. Los datos recolectados por los sensores son enviados a Firestore, donde se almacenan y procesan para la toma de decisiones automatizada. La Figura 4.2 muestra la arquitectura general del sistema.

Figura 4.2
Arquitectura del Sistema




Nota. Arquitectura del sistema de riego automatizado con IoT. Elaboración Propia

El módulo ESP1 está encargado de la recolección de datos ambientales y del suelo. Para ello, se emplea un sensor de humedad HW-103A y un sensor de temperatura DHT11, los cuales proporcionan mediciones periódicas de las condiciones del entorno. Estos datos son enviados a Firestore cada día en tres horarios establecidos (08:00, 14:00 y 20:00) utilizando el módulo Wi-Fi integrado en el ESP8266.

El almacenamiento en Firestore sigue una estructura organizada en la colección "Datos_capturados", donde cada registro incluye una marca temporal (timestamp) y un identificador único. Además, el sistema incorpora una EEPROM en el ESP8266 para evitar la sobrescritura de datos en caso de reinicio. En la Figura 4.3 se puede observar el diseño del módulo 1, que incluye el NodeMCU8266 y los sensores DHT11 y HW-103A.


Figura 4.3
Módulo ESP1



El segundo módulo, ESP2, gestiona la activación del riego de forma automatizada. Se conecta a Firestore y recupera los valores de tiempo de riego almacenados en la colección "Datos_riego". Según estos parámetros, el ESP8266 activa un relé que controla una bomba de agua de 6V con un caudal de 120 L/h (0.033 ml/ms).

El sistema de riego opera en los mismos tres horarios definidos para la recolección de datos. A las 08:10, 14:10 y 20:10, el ESP2 consulta Firestore para obtener el tiempo de riego necesario y activa la bomba durante el periodo determinado. Esta automatización permite optimizar el consumo de agua y mantener condiciones óptimas para el cultivo. En la Figura 4.4 se puede observar el diseño de dicho módulo 2, el cual incluye el NodeMCU 8266, el relé, la fuente de energía y la bomba de agua.


Figura 4.4
Módulo ESP2



Para garantizar el suministro de agua, se implementó un tercer módulo basado en el ESP8266, que supervisa el nivel de agua en el contenedor de riego. Este módulo emplea un sensor ultrasónico HC-SR04 para medir la distancia entre la superficie del agua y la parte superior del depósito.

Cada día, en los mismos horarios programados (08:15, 14:15 y 20:15), el sensor ultrasónico mide la distancia y convierte este valor en mililitros de agua restantes. Esta información se almacena en la colección "Registro_agua_esp3" de Firestore. Si el nivel de agua es insuficiente, el sistema genera una alerta para la reposición del depósito. En la Figura 4.5 se observa el diseño del módulo 3, que incluye el NodeMCU 8266 y el sensor ultrasónico HC-SR04.

Figura 4.5
Módulo ESP3



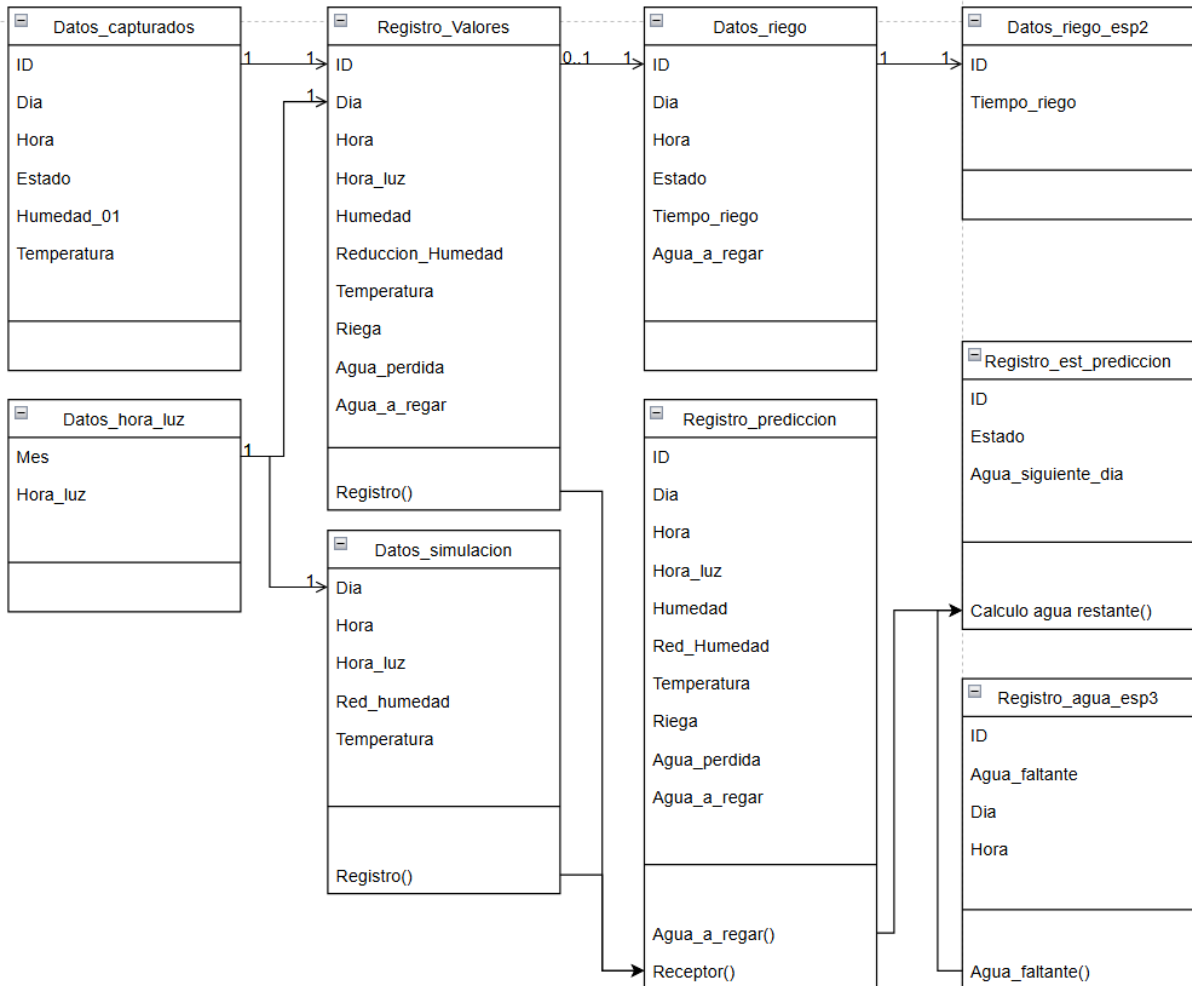
Para la comunicación y almacenamiento de datos en la nube, se empleó Firebase Firestore, una base de datos NoSQL que permite la estructuración de la información en documentos y colecciones. La elección de Firestore se basó en su capacidad de escalabilidad y en su compatibilidad con dispositivos IoT de bajo consumo como el ESP8266. De acuerdo con Zambrano et al. (2021), Firebase Firestore es una solución efectiva para sistemas IoT debido a su arquitectura NoSQL, que permite manejar grandes volúmenes de datos con baja latencia y una sincronización eficiente en tiempo real. Además, Firestore ha demostrado ser altamente compatible con plataformas embebidas como ESP8266, ya que su API RESTful facilita la comunicación mediante solicitudes HTTP, lo que minimiza el consumo de recursos y optimiza el rendimiento del microcontrolador. Otro aspecto clave es la integración nativa de Firebase con herramientas de análisis de datos y machine learning en la nube, lo que permite a los desarrolladores implementar modelos predictivos sin necesidad de infraestructura adicional (Zambrano et al., 2021). Esta característica es particularmente útil en aplicaciones de riego inteligente, donde se requiere la recolección, procesamiento y almacenamiento de datos ambientales para la toma de decisiones automatizada.

Los datos capturados por los sensores se envían a Firestore utilizando solicitudes HTTP POST en formato JSON. Cada registro se asocia a una marca temporal, lo que permite un seguimiento detallado de las condiciones

ambientales a lo largo del tiempo. La información recopilada se organizó en nueve colecciones dentro de la nube, cómo se muestra en la Figura 4.6.

Figura 4.6

Lista de colecciones de la base de datos



El proceso inicia con la colección "Datos_capturados", donde se almacenan todos los datos recopilados por el sistema de sensores. Estos datos, junto con la información sobre las horas de luz solar por mes contenida en la colección "Datos_hora_luz", alimentan la lógica del registro, a partir de la cual se calculan el agua perdida, la cantidad de agua a regar y la acción de riego. Toda esta información se almacena en la colección "Registro_valores".

Los registros cuya acción de riego sea igual a uno se transfieren a la colección "Datos_riego", desde donde el ESP2 los recupera para ejecutar el riego con la cantidad de agua indicada. Una vez realizado el riego, el ESP2 almacena el tiempo de riego en la colección "Datos_riego_esp2", completando así el proceso de riego.

Por otro lado, el proceso de predicción se basa en las colecciones "Registro_valores" y "Datos_simulados". La colección "Datos_simulados" contiene los resultados de una simulación ejecutada con los primeros 30 registros, los cuales fueron cargados manualmente. Estos datos alimentan los modelos de predicción, cuyos resultados son almacenados en la colección "Registro_predicción".

Cuando un registro en "Registro_predicción" tiene la acción de riego igual a uno, el valor de "agua_a_regar" se ingresa en la lógica de predicción. Junto con el último registro de la colección "Registro_agua_esp3", que almacena la cantidad de agua restante en el depósito, se calcula si el agua disponible será suficiente para el día siguiente. Finalmente, este resultado, junto con el estado del depósito (es decir, si es necesario rellenarlo o no), se almacena en la colección "Registro_est_predicción".

La función de la simulación es crear una gran cantidad de datos usando los primeros registros capturados con los sensores, estos datos poco a poco perderán valor según la cantidad de registros reales capturados, similar a lo

utilizado en (INIFAP, 2022). Por ejemplo, el valor de los datos simulados tendrá un peso de 0.80 a los 50 registros reales, mientras que a los 200 registros tendrán un peso de 0.20. Estos datos se utilizaron en la predicción. Para ello se creó un modelo en Arena con el objetivo de simular la temperatura, y la reducción de humedad en el transcurso de las horas. Primero, se realizó el análisis de los registros capturados obteniendo la distribución triangular de la temperatura y la ecuación lineal de la reducción de humedad. Para ello, los intervalos de tiempo se dividieron igual que en la captura de datos: 08:00-14:00-20:00, y por estaciones. En cuanto a la reducción de la humedad, se incorporó una variable independiente denominada “horas de luz diarias”, que corresponde a la cantidad de horas de luz solar en el transcurso del día, esto varía según el mes. En cuanto a la simulación, se decidió hacer un promedio de horas luz por estación. El resultado es un conjunto de 365 días de registros de la temperatura y la reducción de la humedad por intervalos de horas.

El cálculo de riego se procesa cada vez que el sistema de captura de sensores envía su registro a la nube, según el intervalo horario. El objetivo es registrar la reducción de humedad, la acción de riego, el agua perdida y el agua a regar. La condición principal es que, si la humedad es menor al 70%, se activa la acción de riego; de lo contrario, la acción se mantiene en 0.

El proceso inicia con el cálculo de la reducción de humedad, restando el valor de la humedad actual del valor de la humedad anterior. Posteriormente, se calcula la temperatura media, que es el promedio entre la temperatura anterior y la actual. Con estos valores, se determina el agua perdida utilizando la ecuación de evapotranspiración de Blaney-Criddle utilizado por Landeros-Sánchez et. al. (2016), la cual proporciona la cantidad de metros cúbicos de agua que ha perdido el tomate. Finalmente, el agua a regar corresponde a la cantidad de agua que el tomate ha perdido hasta el momento en que se activa la acción de riego.

La predicción se entrena utilizando los registros obtenidos, tanto capturados como simulados. En primer lugar, se calcula la temperatura del día siguiente empleando el modelo ARIMA, siguiendo la metodología propuesta por Michalis et al. (2023). Posteriormente, los datos se segmentan en intervalos horarios, lo que permite realizar una predicción específica para cada intervalo de tiempo. Con esta información, junto con el tiempo de luz solar mensual, se procede a estimar la humedad mediante un modelo de Random Forest, de acuerdo con la metodología utilizada por Dhillon et al. (2023). En este análisis, las variables independientes son la hora, la temperatura y las horas de luz, mientras que la variable dependiente corresponde a la reducción de la humedad. Finalmente, al resultado obtenido se le aplica el cálculo de riego previamente descrito, lo que permite generar el registro de humedad para el día siguiente.

5. EXPERIMENTACIÓN

5.1 CARACTERÍSTICAS ÓPTIMAS DEL OBJETO DE ESTUDIO


El objeto de estudio para esta investigación es el tomate cherry (*Solanum lycopersicum* var. *cerasiforme*), una planta de fruto ampliamente cultivada en climas templados y tropicales. La muestra experimental consistió en 1 maceta de 35 cm de diámetro, ubicada en condiciones estándar de tierra y riego. La maceta fue colocada en un balcón de un departamento, lo que permitió la exposición natural a la luz solar y a la humedad ambiental. Este balcón está ubicado en el distrito de Pueblo libre, en la provincia de Lima, Perú.

Según el Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI), el clima de Lima es árido y templado, con alta humedad durante todo el año; en verano la temperatura máxima promedio es de 26°C, y en invierno baja a 14°C, con lloviznas ocasionales (2020). Adicionalmente, se tiene en consideración que Lima está situada entre las coordenadas geográficas de 10°16'18" y 13°19'16" de latitud sur, y entre 75°30'18" y 77°53'02" de longitud oeste del meridiano de Greenwich.

Este entorno climático y las características del suelo proporcionan un escenario adecuado para el cultivo de tomate cherry en condiciones controladas, permitiendo analizar las variables clave relacionadas con el consumo de agua, la humedad del suelo y el crecimiento de las plantas a lo largo del tiempo. En la Figura 5.1, se observa la maceta del tomate cherry empleada en la experimentación.

Figura 5.1

Objeto de estudio



5.2 INTERNET DE LAS COSAS

La fase experimental se llevó a cabo durante 14 meses, desde el 1 de junio de 2023 hasta el 31 de julio de 2024, con el propósito de evaluar el rendimiento del sistema de riego automatizado basado en IoT. A lo largo de este período, se implementaron progresivamente los módulos del sistema y se recopilaban datos en diferentes condiciones climáticas.

5.2.1 IMPLEMENTACIÓN DE IOT Y FUNCIONAMIENTO DE LOS MÓDULOS

La experimentación se estructuró en tres fases, en las cuales se incorporaron y probaron los módulos ESP1, ESP2 y ESP3, que permitieron la automatización del riego en función de los datos ambientales y del nivel de agua disponible.

La primera fase consistió en la recolección de datos, esta duró desde Julio 2023 hasta enero 2024. Durante esta primera etapa se implementó el módulo ESP1, encargado de la recolección de datos ambientales y del suelo. Este módulo capturó información sobre la humedad del suelo y la temperatura ambiente utilizando los sensores HW-103A y DHT11, enviando los datos a Firestore en los horarios establecidos (08:00, 14:00 y 20:00).

Dado que el sistema de riego automatizado aún no estaba en funcionamiento, el riego se realizó manualmente utilizando una jarra medidora para controlar la cantidad de agua suministrada. Se estableció un régimen de riego basado en la temporada del año:

- Verano: Se aplicó 1 litro de agua por día.
- Invierno: Se redujo la cantidad a 800 ml por día.

Estos valores fueron determinados con base en el manual de cultivo del tomate (Chemonics International Inc., 2008) y ajustados a una maceta de 35 cm de diámetro, en la cual se realizó la prueba.

El propósito de esta fase fue generar un conjunto de datos iniciales para analizar el comportamiento de la planta y establecer una base de referencia para la posterior automatización del riego.

A partir del 1 de febrero de 2024, se añadieron nuevas funcionalidades al sistema, con el objetivo de mejorar la capacidad de predicción y automatización del riego. Durante esta segunda fase, se integraron dos nuevos módulos:

- ESP2: Responsable del control del riego automatizado.
- ESP3: Encargado del monitoreo del nivel de agua en el depósito.

Estos módulos permitieron la automatización del riego en función de los datos recopilados y las predicciones generadas. El ESP2 activaba la bomba de agua según los parámetros almacenados en Firestore, mientras que el ESP3 supervisaba el nivel de agua restante en el depósito y enviaba alertas en caso de baja disponibilidad.

El sistema comenzó a operar con los siguientes horarios de riego:

- 08:10, 14:10 y 20:10 → Activación del riego según los datos de Firestore.
- 08:15, 14:15 y 20:15 → Medición del nivel de agua restante en el depósito.

En esta etapa, los tres módulos funcionaron de manera conjunta, permitiendo recopilar datos en tiempo real y ejecutar el riego con base en las necesidades hídricas de la planta. Sin embargo, el 15 de marzo de 2024, se produjo un fallo en el microcontrolador ESP1, lo que provocó una interrupción en la recolección de datos. Debido a que el módulo de control de riego ESP2 dependía de los valores enviados por ESP1, el sistema dejó de funcionar correctamente y el riego automatizado se detuvo. Durante este período de inactividad (15 de marzo - 30 de abril de 2024), se suspendió la recopilación de datos y se reanudó el riego manual.

A partir del 1 de mayo de 2024, se inició la tercera y última fase, en la cual se restableció el funcionamiento de los módulos ESP1, ESP2 y ESP3, permitiendo la recolección de datos y la automatización del riego nuevamente. Durante esta fase, el sistema operó sin interrupciones hasta el 31 de julio de 2024, completando la etapa experimental con éxito.

Se realizaron ajustes menores en los tiempos de riego para optimizar el consumo de agua, basados en los datos históricos recopilados en Firestore. Estos ajustes permitieron mejorar la eficiencia del sistema, asegurando un suministro adecuado de agua sin desperdicio.

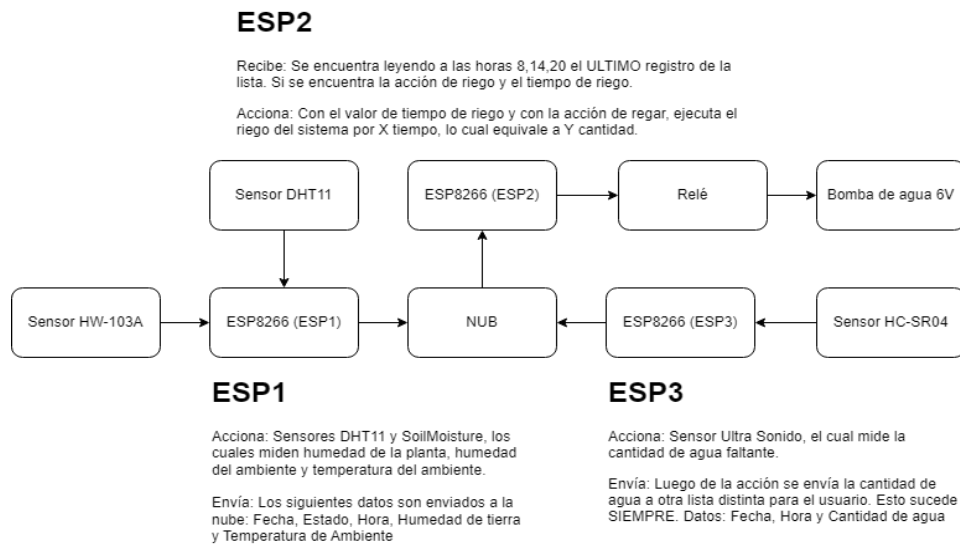
5.2.2 SINCRONIZACIÓN DE DATOS Y FLUJO DEL SISTEMA

La sincronización de los tres módulos con Firestore asegura que el sistema funcione de manera integrada.

- **ESP1** sube los datos ambientales (humedad del suelo y temperatura), que son utilizados para calcular los tiempos de riego.
- **ESP2** ejecuta el riego según los valores predichos y almacenados en Firestore.
- **ESP3** supervisa el nivel de agua en el depósito y envía alertas si el nivel es insuficiente.

La estructura de Firestore permite que cada módulo acceda a rutas específicas dentro de la base de datos, lo que evita conflictos en la gestión de datos y asegura una comunicación eficiente entre los diferentes componentes del sistema. Podemos observar mayor detalle en la Figura 5.2, donde se detalla el flujo de los tres módulos.

Figura 5.2
Diagrama de flujo de los microcontroladores ESP8266



5.2.3 PROBLEMAS TÉCNICOS Y ESTRATEGIAS DE MITIGACIÓN

Durante la fase experimental, se presentaron diversos desafíos técnicos que afectaron la operatividad del sistema de riego automatizado. Uno de los principales problemas fue el sobrecalentamiento de los módulos ESP8266, lo que provocaba fallos en la transmisión de datos y la ejecución de tareas programadas. Para mitigar este inconveniente, se reemplazó la versión NodeMCU 0.9 por la NodeMCU 1.0, la cual ofrece una mejor eficiencia energética, logrando así mayor estabilidad en el funcionamiento del sistema.

Asimismo, se detectaron pérdidas de conectividad intermitente entre los módulos y la base de datos en la nube, lo que afectaba la sincronización de datos y la ejecución oportuna del riego. Para solucionar esta situación, se implementó un algoritmo de reconexión automática que permitió a los módulos restablecer la conexión sin intervención manual, asegurando la continuidad en la recolección y procesamiento de datos.

Otro desafío identificado fue la imprecisión en las mediciones de humedad del suelo, ya que los sensores HW-103A presentaban lecturas inconsistentes que activaban el riego de manera innecesaria. Para mejorar la precisión, se realizó una calibración manual de los sensores y se incorporaron filtros en el código de procesamiento de datos, lo que permitió descartar valores atípicos y optimizar la toma de decisiones del sistema.

A pesar de estas optimizaciones, el sistema experimentó un periodo de inactividad de aproximadamente un mes y medio debido a problemas térmicos persistentes en los módulos. La solución progresiva de estos problemas evidenció la importancia de un diseño optimizado del hardware y la integración de mecanismos de autogestión en sistemas IoT, particularmente en aplicaciones agrícolas donde la estabilidad y precisión de las mediciones son fundamentales para la eficiencia del riego automatizado.

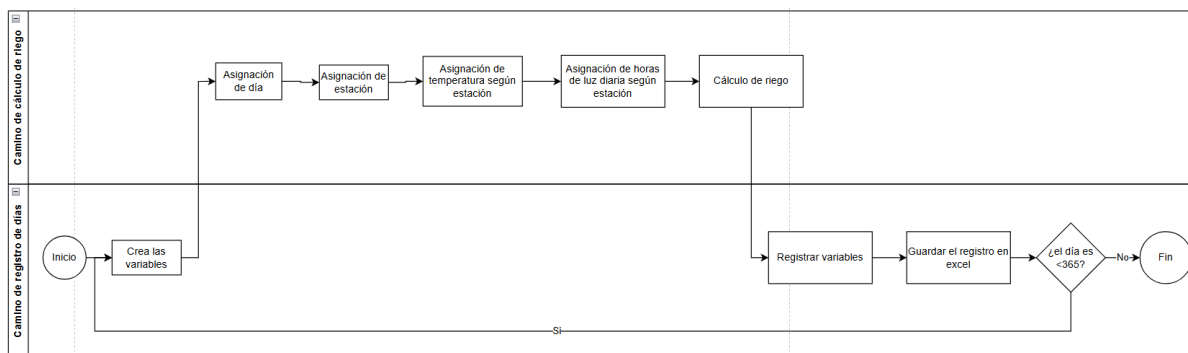
5.3 SIMULACIÓN

Se realizó una simulación de 365 días, equivalente a un año completo, en la cual se obtuvo la temperatura y la reducción de humedad de la planta en intervalos. Los registros se llevaron a cabo a las 08:00, 14:00 y 20:00 horas, replicando los horarios en que nuestro sistema de sensores captura los datos. Para cada horario, se realizaron tres simulaciones, cada una con valores distintos de temperatura y reducción de humedad, según la estación y el horario.

5.3.1 RUTAS DE LA SIMULACIÓN

Como se observa en la Figura 5.3, se establecieron dos rutas dentro del modelo en Arena. En primer lugar, se crean las variables dentro del registro de días. Luego, inicia el proceso de cálculo del riego, en el cual se asignan los días, la estación, la temperatura y las horas de luz diaria. Tanto la temperatura como las horas de luz diaria se determinan según la estación del año. Finalmente, se calcula la reducción de humedad utilizando la ecuación de evapotranspiración propuesta por Landeros-Sánchez et al. (2016). Una vez definidas todas las variables, estas se registran en la ruta de registro de días y posteriormente se almacenan en un archivo de Excel.

Figura 5.3
Flujo de la simulación



Nota. Flujo fue realizado en el software Arena de los datos simulados para la primera carga de nuestro sistema.

5.3.2 ASIGNACIÓN DE VARIABLES DE TEMPERATURA Y HORAS DIARIAS DE LUZ SOLAR

Cuando la señal se activa, a la entidad se le asignan los atributos de temperatura, día y horas diarias de luz solar. Con respecto a la temperatura, usamos los valores de la captura de datos para obtener la distribución triangular. Para ello, primero separamos los registros de temperatura por estación y por hora. Por ejemplo, en la siguiente ecuación se filtra el data frame (df) por el horario de las 08:00 y por las fechas tentativas de la estación de otoño:

$$df[(df['Hora'] == 8) \& (df['Dia'] >= '2023-03-21') \& (df['Dia'] <= '2023-06-21')] \tag{1}$$

Seguidamente, tomamos los valores dentro de los cuantiles 0.05 y 0.95 para eliminar los valores inusuales. Por último, obtenemos el mínimo, máximo y la moda de los registros de temperatura, que corresponden a los valores de la distribución triangular. La otra variable son las horas diarias de luz solar, y utilizando la tabla de horas máximo de luz solar (Sánchez, 2022), calculamos un promedio diario según cada estación para obtener las horas diarias de luz solar por estación. Para definir exactamente qué valor deben tomar la temperatura y las horas de luz solar, usamos los días de las estaciones astronómicas en el Perú. Las fechas de las estaciones en 2023 son: 20 de marzo para otoño, 21 de junio para invierno, 23 de septiembre para primavera y 21 de diciembre para verano (SENAMHI, 2023).

Usando esas fechas, obtenemos los días exactos entre cada estación. Si comenzamos el 1 de enero, del día 1 al 78 corresponde a verano, del 79 al 171 a otoño, del 172 al 265 a invierno, del 266 al 354 a primavera y los días restantes nuevamente a verano, esto permitió realizar una simulación realista. Por ejemplo, en invierno a las 20:00, los valores de temperatura oscilan entre 14 °C y 24 °C, con una moda de 20 °C.

5.3.3 ASIGNACIÓN DE VARIABLE DE REDUCCIÓN DE HUMEDAD

La última variable que se simuló fue la reducción de la humedad. Esta se obtiene a partir de los datos capturados en ese momento. Para ello, se realizó el cálculo de la reducción siguiendo estos pasos. Primero, se ordenaron los registros por día y horario, de menor a mayor. Segundo, se creó una nueva columna donde se restaría la humedad del registro anterior. Esto se realizó bajo las siguientes condiciones:

- La humedad base es del 90%.
- Si es el primer registro, la reducción de humedad es 0.
- Si el registro actual se riega, el siguiente restará su humedad con respecto a la humedad base.
- Si el registro no se riega, restará su humedad con respecto a la humedad anterior.

Con la nueva columna creada, se aplicó el cálculo para obtener la ecuación lineal de la reducción de humedad. Las variables utilizadas fueron la temperatura media y las horas diarias de luz solar. La ecuación para la temperatura media es la siguiente:

$$\text{Temp media} = (X+Y)/2 \quad (2)$$

Donde:

- **X**: Es la temperatura del registro anterior.
- **Y**: Es la temperatura del registro actual.

Luego, en Python, utilizando la librería sklearn, se obtuvo la ecuación lineal con el siguiente formato:

$$y=mx+nz+b \quad (3)$$

Donde:

- **x**: Es la temperatura media.
- **z**: Son las horas diarias de luz solar.

Por ejemplo, la ecuación 3 muestra la ecuación lineal resultante para el horario 08:00:

$$y=0.23840477268176413x+0.8184802639141906z + (-10.274132115958224) \quad (4)$$

5.4 CÁLCULO DE RIEGO

El cálculo de riego se ejecuta cada vez que se realiza la captura de datos. Inicialmente, se realizó el cálculo utilizando la data capturada desde el inicio de la fase de experimentación el 1 de junio de 2023 hasta el 31 de enero del 2024. A continuación, se empezó a aplicar el cálculo diariamente a por cada horario a partir del 1 de febrero del 2024.

5.4.1 REGISTRO DE LOS DATOS CAPTURADOS

Primero, buscamos en la colección “datos capturados”, los documentos que tengan el campo “Estado” igual a “E”, que significa enviado. A continuación, los guardamos en un dataframe y actualizamos el estado de los documentos a “R”, que significa registrado. De este modo, evitamos que en la siguiente ejecución del cálculo de riego se utilicen los mismos datos. Además, el sistema está diseñado para procesar uno o varios registros. En caso de que no se ejecute en el horario programado, se procesarán todos los registros pendientes en el siguiente horario.

5.4.2 LÓGICA DEL CÁLCULO

Para el cálculo, necesitamos extraer el último registro de la colección "registro_valores" e identificar el "ID" más alto para almacenarlo en un dataframe.

Del dataframe de captura de datos, solo utilizamos las columnas Día, Temperatura, Hora y Humedad_01. Guardamos los datos de esas columnas en otro dataframe llamado "X". Además, añadimos las columnas: reducción de humedad, riego, agua perdida, agua a regar y horas de luz, todas con valor inicial de 0. Se almacenan la temperatura, hora, agua a regar y humedad del último registro en variables individuales. Si el riego en el último registro fue 1, el agua a regar se establece en 0 y la humedad en 90, indicando que el riego ocurrió inmediatamente después. De lo contrario, se toman los valores del último registro. A continuación, procedemos a llenar las columnas añadidas. Primero, el riego: si la humedad es menor al 70%, el riego se establece en 1. Segundo, la reducción de humedad: es la diferencia entre la humedad actual y la del registro anterior (si el riego en el registro anterior fue 1, la reducción se calcula restando 90). Tercero, el agua perdida se calcula usando una ecuación adaptada de la evapotranspiración, cómo se observa en la ecuación número 5:

$$\text{AguaPerdida} = (X / 24) * ((0.46 * Y + 8) / 10) * Z \quad (5)$$

Donde:

- **X**: Son las horas de luz para cada franja horaria. De 08:00 a 14:00, las horas de luz siempre serán 6, mientras que de 14:00 a 20:00 y de 20:00 a 08:00 dependerán de las horas de luz mensuales. Cuantas más horas de luz, más prolongados serán en esos horarios. Además, si el horario es de 14:00 a 20:00. El valor se multiplica por 0.7. Si el horario es de 20:00 a 08:00 el valor se multiplica por 0.3. Porque en esos horarios el clima es más frío y húmedo. Lo que significa que la reducción de humedad no tiene la misma intensidad que el horario de 08:00 a 14:00.
- **Y**: Es el promedio entre la temperatura actual y la anterior.
- **Z**: Es el área de la maceta. Debido a que la superficie de la maceta es circular, su área superficial es el área de un círculo ($\pi * r^2$).

Con esto, calculamos la cantidad de mililitros de agua que se pierde en determinadas horas, según el horario establecido.

Finalmente, el agua a regar es la cantidad de agua que pierde el cultivo hasta que se realiza el riego. Es decir, se acumula el agua perdida hasta que el riego sea 1; en ese momento, el siguiente cálculo comenzará desde 0. Con el dataframe "X" completo, se guarda en la base de datos en la nube, en la colección "registro_valores", asignándole el ID correspondiente según el último registro.

5.4.3 ALERTA DE RIEGO

Usando el dataframe "X", verificamos si el registro requiere riego. De ser así, se crea un dataframe con los datos de día, hora y agua a regar del registro que necesita riego. Luego, este se envía a la base de datos en la nube, en la colección "datos_riego", con el estado "N", indicando que está pendiente de riego, junto con la cantidad de tiempo que se debe regar y el ID, generado concatenando el día y la hora.

5.5 VALIDACIÓN Y COMPARACIÓN DE MODELOS DE PREDICCIÓN

Para la evaluación y validación del desempeño de los modelos de predicción utilizados para la temperatura en este estudio, implementamos dos enfoques distintos: el modelo ARIMA (AutoRegressive Integrated Moving Average) y una red neuronal LSTM (Long Short-Term Memory). En el caso del primer enfoque, de acuerdo con Michalis et al. (2023) el modelo autorregresivo integrado permite captar patrones estacionales y tendencias en parámetros de temperatura. Por otro lado, en el segundo enfoque, Jingxin Yu et al. (2020), nos indica que una red neuronal puede ser empleada para realizar predicciones de temperatura en estudios relacionados a la agricultura. Ambos modelos fueron evaluados utilizando métricas estadísticas estándar para medir la precisión de sus predicciones: el Error Cuadrático Medio (MSE), la Raíz del Error Cuadrático Medio (RMSE) y el Error Absoluto Medio (MAE). El MSE nos permitió medir el error promedio al elevar las diferencias al cuadrado, penalizando así los errores más grandes. La RMSE, derivado del MSE, facilitó la interpretación de los resultados al mantener la misma escala que los datos originales. Finalmente, el MAE representó la magnitud promedio de los errores en las predicciones sin considerar su dirección, proporcionando una medida intuitiva de precisión. Ambos modelos fueron entrenados y probados en la misma serie de datos obtenidos a través de los sensores, permitiendo una comparación directa basada en estas métricas de error.

En cuanto a la predicción de la humedad en el estudio, se evaluó la precisión de los 3 modelos de regresión utilizados en estudios previos: Según Palominos-Rizzo et al (2022), se tomó en consideración la regresión lineal múltiple para el caso de estudios de agricultura; Del lado de Fernández Fernández, A. (2023), se evaluó la regresión polinómica para mediciones de la humedad en un estudio similar al utilizado; y finalmente, Dhillon et al (2023) menciona que el uso de Random Forest es una opción viable para estudios en agricultura. La validación de estos modelos se realizó mediante dos métricas clave: la Raíz del Error Cuadrático Medio (RMSE) y el coeficiente de determinación (R^2 Score). El RMSE nos permitió medir la magnitud promedio del error de predicción, siendo valores más bajos indicativos de un mejor ajuste del modelo. Por otro lado, el R^2 Score evaluó qué proporción de la variabilidad de los datos era explicada por el modelo, con valores más cercanos a 1 indicando un mejor desempeño predictivo. Todos los modelos fueron entrenados con el mismo conjunto de datos, permitiendo una comparación equitativa de su rendimiento.

5.6 PREDICCIÓN DE RIEGO DEL DÍA SIGUIENTE

A partir de los resultados obtenidos de los algoritmos de predicción, se calcula el agua a regar de los registros cuyo valor de riego es igual a 1. De la colección "registro_agua_esp2", obtenemos la cantidad de agua restante en el recipiente. Con estos datos, calculamos la cantidad de agua restante en el recipiente menos los registros con riego 1, como se muestra en la siguiente ecuación:

$$\text{Alerta a rega pred} = Y - \text{sum}(X) \quad (6)$$

Donde:

- **Y**: es el agua faltante del último registro
- **X**: el agua a regar solo cuando el riego sea 1.

Según el resultado, hay dos opciones:

- Si el agua restante es menor o igual a la "alerta a regar pred", se registra en la colección "Registro_estado_prediccion" que el agua al siguiente día será "0" y su estado como "Urgente".
- Si el agua restante es mayor a la "alerta a regar pred", se registra en la colección "Registro_estado_prediccion" se registrará que el agua disponible al día siguiente será igual a la diferencia entre el agua restante y el umbral de alerta", y su estado como "Quedan X ml de agua".

6. RESULTADOS

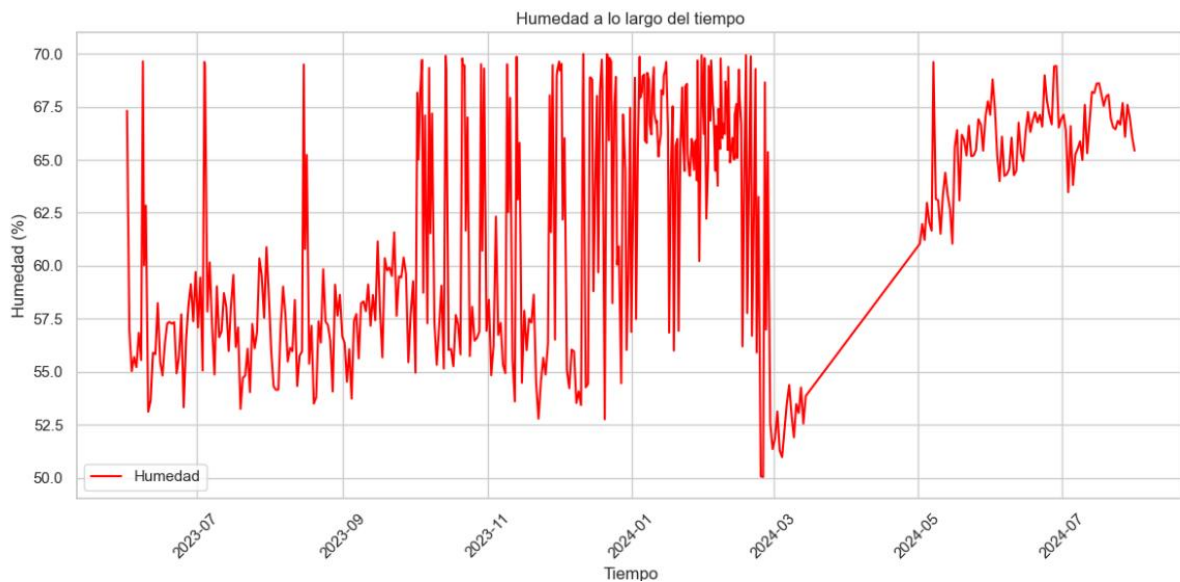
6.1 MEDICIÓN DE DATOS Y COMPORTAMIENTO DEL SISTEMA

Durante un total de 285 días, desde el 1 de junio de 2023 hasta el 31 de enero de 2024, se llevó a cabo el monitoreo de una planta de tomate cherry utilizando un sistema IoT basado en el microcontrolador ESP8266. Durante este periodo, se registraron datos de humedad del suelo y temperatura ambiental mediante el módulo ESP1. Posteriormente, entre el 1 de febrero de 2024 y el 14 de marzo de 2024, se expandió el sistema con la adición de los módulos ESP2 y ESP3, encargados del control del riego y la medición del nivel de agua, respectivamente, junto con la implementación de un sistema de cálculo y predicción de riego. A raíz de una avería en el ESP1, la recolección de

datos se interrumpió desde el 15 de marzo de 2024 hasta el 30 de abril de 2024, cuando el sistema fue reparado y se retomaron las mediciones. A partir del 1 de mayo de 2024, se reanudó el monitoreo, manteniéndose hasta el 31 de julio de 2024. El sistema demostró su capacidad para ajustar automáticamente los tiempos de riego en función de las condiciones ambientales, incrementando la frecuencia de riego durante los días más cálidos y reduciéndose en días más frescos, optimizando así el consumo de agua. Se puede observar la data registrada de acuerdo a la humedad del suelo en la Figura 6.1.

Figura 6.7

Registros de Humedad capturados



6.2 MEDICIÓN Y ALMACENAMIENTO DE DATOS

Los tres módulos ESP8266 funcionaron de manera integrada y estable. ESP1 recolectó y envió los datos de humedad del suelo y temperatura ambiental a Firestore en tiempo real, organizando los datos para su posterior análisis. ESP2 controló el riego automáticamente, activando la bomba de agua de acuerdo con los datos recogidos desde la nube. El tiempo de riego se ajustó dinámicamente gracias a los valores almacenados en Firestore, asegurando que el riego solo ocurriera cuando la humedad del suelo estaba por debajo del umbral establecido.

Por otro lado, ESP3 monitorea el nivel de agua en el depósito utilizando un sensor ultrasónico, enviando alertas a Firestore cuando el nivel era bajo. Este monitoreo continuo evitó interrupciones en el riego, ya que se recargaba el depósito de agua de manera oportuna. El algoritmo de reconexión automática implementado en los módulos garantizó la estabilidad del sistema incluso en caso de pérdidas momentáneas de conexión Wi-Fi, asegurando que el riego y el monitoreo de datos se mantuvieran sin intervención manual.

6.3 VALIDACIÓN DE DATOS SIMULADOS

Para evaluar la precisión de los datos simulados en relación con los datos reales capturados durante la experimentación, se realizó un análisis comparativo de las variables temperatura y reducción de humedad del suelo. Este análisis permite verificar la consistencia de la simulación y su representatividad con respecto a las condiciones reales del experimento.

6.3.1 COMPARACIÓN DE LA TEMPERATURA

La temperatura simulada presenta una media de 20.77°C, mientras que la temperatura real tiene un valor medio de 21.18°C, lo que representa una diferencia de aproximadamente 0.41°C. En términos de variabilidad, la desviación estándar de la simulación es 2.80, ligeramente mayor que la de los datos reales, que es 2.12.

En cuanto a los valores extremos, la temperatura mínima en la simulación fue de 12.13°C, mientras que en los datos reales se registró un mínimo de 11°C. Por otro lado, la temperatura máxima en la simulación alcanzó 31.63°C, en comparación con los 33°C registrados en la experimentación real.

Los percentiles también muestran una distribución similar entre ambos conjuntos de datos. Por ejemplo, el percentil 25 de la temperatura simulada es 19.23°C, mientras que en los datos reales es 20.00°C, y el percentil 75 es 22.47°C en la simulación frente a 22.00°C en los datos reales.

Estos resultados indican que la simulación reproduce de manera aceptable la distribución de la temperatura real, aunque presenta una ligera subestimación en los valores más altos.

6.3.2 COMPARACIÓN DE LA HUMEDAD

Para la variable de reducción de humedad, la media de los datos simulados es 10.43, mientras que en los datos reales es 11.46, mostrando una diferencia de 1.03 unidades. La desviación estándar en la simulación es 5.08, muy cercana a la de los datos reales (5.30), lo que indica una variabilidad similar en ambos casos.

En cuanto a los valores extremos, la reducción de humedad mínima simulada fue 3.75, mientras que en los datos reales se registró un mínimo de 0.00. Esto sugiere que la simulación no contempla escenarios en los que no haya pérdida de humedad, lo que podría ser un aspecto a mejorar. Por otro lado, los valores máximos fueron 23.53 en la simulación y 23.44 en los datos reales, mostrando una excelente correspondencia en los casos de mayor pérdida de humedad.

En los percentiles, el percentil 25 de los datos simulados es 4.89, muy similar al 4.82 de los datos reales. Sin embargo, en el percentil 50, la simulación presenta un valor de 9.99, mientras que los datos reales tienen un valor de 13.14, lo que indica una ligera subestimación en la simulación de valores intermedios.

6.4 ALGORITMOS DE PREDICCIÓN

Los resultados obtenidos mostraron que el modelo LSTM presentó valores de error ligeramente inferiores en comparación con el modelo ARIMA, con un MSE de 1.3443 frente a 1.3965, un RMSE de 1.1594 frente a 1.1817 y un MAE de 0.9119 frente a 0.9177. Estos valores indican que el modelo LSTM tuvo un mejor desempeño en términos de precisión de predicción. Sin embargo, la diferencia entre ambos modelos fue mínima y, considerando la interpretabilidad, estabilidad y menor complejidad computacional del modelo ARIMA, se decidió optar por este último para la predicción final. ARIMA, al ser un modelo estadístico ampliamente utilizado en series temporales, permitió una mayor comprensión de las relaciones entre los datos y ofreció una solución más robusta para el problema abordado.

En cuanto a los resultados obtenidos para la predicción de la humedad, se muestra que la Regresión Lineal presentó el desempeño más bajo, con un RMSE de 3.3986 y un R^2 de 0.6359, lo que indica una capacidad limitada para ajustarse a la complejidad de los datos. En contraste, la Regresión Polinómica y el modelo de Random Forest lograron una mejora significativa en la precisión, con RMSE de 1.3764 y 1.2995, respectivamente, y R^2 de 0.9403 y 0.9468, respectivamente. Aunque ambos modelos fueron altamente precisos, Random Forest obtuvo un RMSE más bajo y el R^2 más alto, lo que sugiere una mayor capacidad de generalización y ajuste a los datos. Considerando estos resultados, se optó por utilizar el modelo de Random Forest para la predicción final, debido a su mejor desempeño en términos de error y capacidad explicativa, además de su flexibilidad para capturar relaciones no lineales en los datos.

6.5 REGISTRO DEL CÁLCULO DE RIEGO

6.5.1 VALORES DEL REGISTRO DE CÁLCULO DE RIEGO

Para los siguientes resultados se consideraron los registros a partir del 2023. Comenzamos con los valores de humedad cuando se activa la acción de Riego. De acuerdo a la Figura 6.1, se observan tres casos con una diferencia bien marcada. Primero, entre los meses de Julio hasta octubre del 2023. Segundo, los meses de noviembre hasta el mes de marzo del 2024. En el primero, mayormente se riega cuando la humedad está al 60% y 52.5%. En el segundo, su variación es muy alta por lo que mayormente se riega entre los 70% y 55%. También hay más registros de la humedad cuando se activa la acción de riego. Entonces, cuando hay más frecuencia de riego, la humedad al momento de regar varía considerablemente.

En la figura 6.2, se muestra la variación, en tres distintas tendencias, en la cantidad de agua utilizada para riego cuando se activa la acción de riego. La primera abarca los meses de julio a diciembre de 2023. Se registra una menor cantidad de agua utilizada para riego, lo cual se debe a la cantidad de activaciones de la acción de riego.

Además, se observa que, en los meses de julio a octubre, el agua utilizada para riego oscila entre los 550 ml y los 650 ml, mientras que en noviembre y diciembre aumenta hasta los 700 ml y disminuye hasta los 350 ml. Esto se debe a que la acción de riego se activa con mayor frecuencia en esos meses.

La segunda tendencia, que abarca de enero a febrero de 2024, muestra una mayor cantidad de registros de riego, con cantidades de agua entre 300 ml y 700 ml. Esto se explica por la mayor frecuencia de activación del riego durante el verano, cuando las temperaturas son más elevadas, el agua no llega a acumularse como en la temporada de invierno.

En la tercera tendencia, que corresponde a los meses de mayo a julio de 2024, se observa que el promedio de agua utilizada es menor que en la primera tendencia, con valores entre 450 ml y 550 ml. Esto se debe a que la temperatura promedio en esos meses fue menor en comparación con la de los mismos meses del año anterior.

Figura 6.2
Registros de Agua a regar capturados almacenados en el campo "registro_valores"



Para complementar este resultado, se realizará la sumatoria del agua a regar y las veces que se regó de un mes por cada tendencia. El primero es de Julio del 2023. El segundo, enero del 2024. El tercero, Julio del 2024. Los resultados son los siguientes:

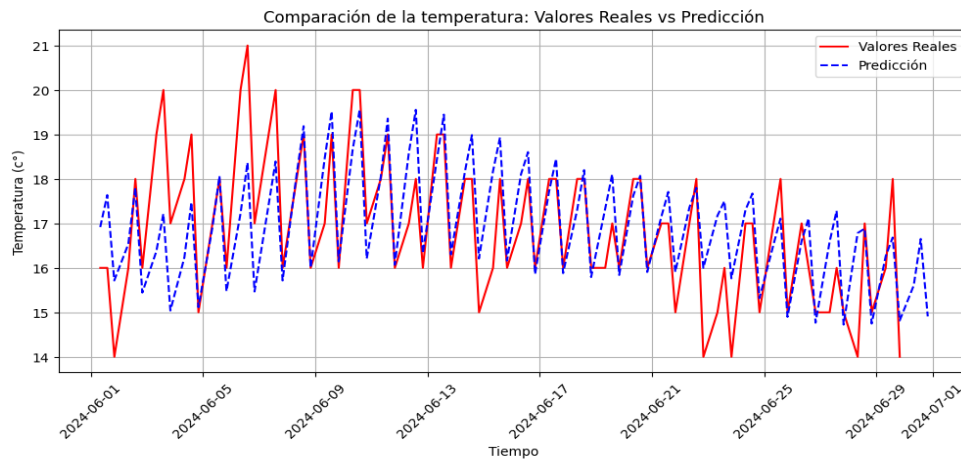
- Julio 2023: 18,383 mililitros en 32 acciones de riego.
- Enero 2024: 23,614 mililitros en 58 acciones de riego.
- Julio 2024: 15, 268 mililitros en 31 acciones de riego.

Con este resultado se demuestra que en los meses de verano se riega casi el doble de veces y la cantidad de agua total es mayor que en los meses de invierno y primavera. Por otro lado, se demuestra que la cantidad de agua a regar de Julio del 2024 fue menor al 2023.

6.5.2 COMPARACIÓN ENTRE DATOS REALES Y LA PREDICCIÓN

En la Figura 6.3, se presenta la comparación entre los valores reales y los valores resultantes de la predicción de la temperatura, humedad y acción de riego a lo largo del mes de junio de 2024. La serie de datos en color rojo representa los valores reales, mientras que la serie azul con línea punteada corresponde a la predicción realizada usando el algoritmo de ARIMA y Random Forest.

Figura 6.3
Comparación de temperatura entre valores reales y predicción




Se observa que el modelo ARIMA logra captar la tendencia general de la temperatura a lo largo del tiempo, identificando correctamente la variabilidad diaria y los patrones de oscilación. Sin embargo, se presentan algunas diferencias entre la predicción y los valores reales, especialmente en los picos máximos y mínimos, donde el modelo tiende a suavizar los extremos. Esto es una característica común de los modelos ARIMA, los cuales son más efectivos en la captura de tendencias y patrones cíclicos que en la predicción de eventos atípicos o fluctuaciones abruptas.

A lo largo del periodo analizado, la predicción sigue de manera aceptable la evolución de la temperatura, aunque en algunos momentos la discrepancia es mayor, lo que podría atribuirse a factores externos no considerados en el modelo, como condiciones climáticas inesperadas o variaciones en la recolección de datos. Para evaluar la precisión del modelo, se calcularon métricas como el error cuadrático medio (MSE) y el coeficiente de determinación (R^2), cuyos valores se analizarán en la siguiente sección.

En general, los resultados sugieren que el modelo ARIMA es una herramienta adecuada para la predicción de temperatura en función de series temporales, aunque podrían explorarse mejoras mediante el ajuste de parámetros o la combinación con otros modelos de aprendizaje automático para mejorar la precisión en los valores extremos. En la Figura 6.4 se observa que la predicción sigue de manera general la tendencia de los valores reales, capturando la periodicidad y los patrones de variación de la humedad.

Figura 6.4
Comparación de humedad entre valores reales y predicción.



Nota. Gráfico lineal de la humedad entre valores reales y predicción.

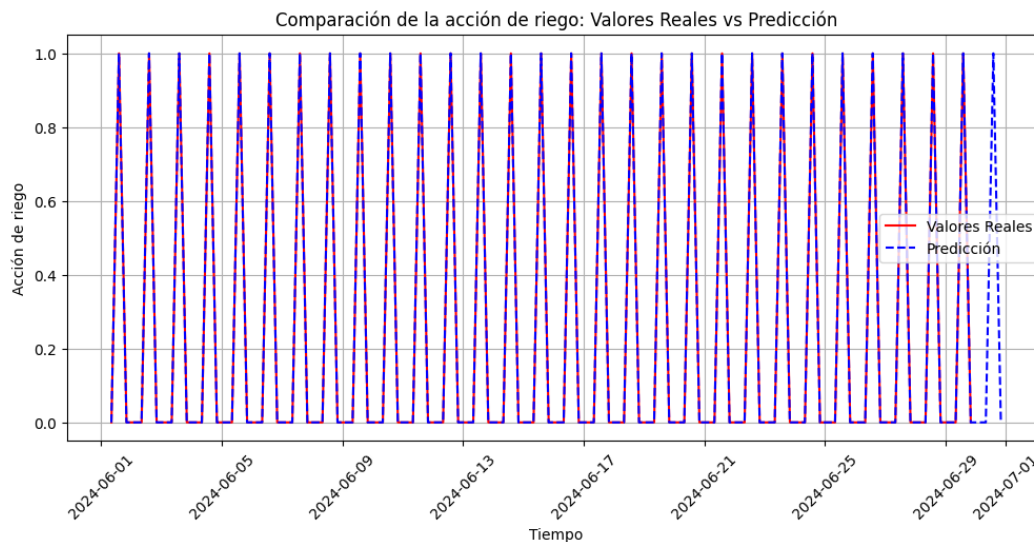
A pesar de lo mencionado, existen algunas discrepancias, principalmente en los picos y valles, donde la predicción tiende a sobreestimar o subestimar los valores reales en ciertos momentos. Esto podría deberse a la

temperatura que depende de muchos factores climáticos que nuestro modelo no puede abarcar. [posibles razones, como errores en la medición, limitaciones del modelo, ruido en los datos, etc.].

A pesar de estas diferencias, la correlación entre ambas series es alta, lo que indica que el modelo de predicción utilizado es capaz de representar de manera precisa la evolución de la humedad en el tiempo. En la Figura 6.5 se presenta que la predicción sigue de manera perfecta la tendencia de los valores reales, capturando la periodicidad y los patrones de la acción de riego.

Figura 6.5

Comparación de acción de riego entre valores reales y predicción.



7. DISCUSIÓN

Los resultados indican que el sistema de riego automatizado basado en IoT y modelos predictivos optimiza el consumo de agua en cultivos urbanos, reduciendo desperdicios y manteniendo niveles adecuados de humedad. La comparación entre los valores predichos y los reales confirma que el modelo de predicción logró estimaciones precisas, con un coeficiente de determinación ($R^2 \approx 0.94$) en Random Forest, lo que demuestra que la data predecida se ajusta a la realidad. ARIMA fue útil para capturar tendencias generales, pero mostró limitaciones en valores extremos, mientras que Random Forest ajustó mejor las variaciones diarias, lo que concuerda con estudios previos sobre su superioridad en modelado de humedad del suelo (Dhillon et al., 2023).

Se puede observar que en los meses de verano el riego es más frecuente y la cantidad de agua utilizada es mayor en comparación con los meses de invierno. En enero de 2024, un mes de invierno, se realizaron 58 acciones de riego con un consumo total de 23,614 mililitros, mientras que en julio de 2023 (verano) hubo solo 32 acciones de riego, pero con un menor consumo de 18,383 mililitros. En julio de 2024, la cantidad de agua utilizada fue aún menor (15,268 mililitros en 31 acciones de riego), lo que sugiere que el sistema de riego automatizado permitió una optimización progresiva del uso del agua. Estos resultados refuerzan la idea de que el consumo de agua en riego varía estacionalmente y que el monitoreo con IoT puede mejorar la eficiencia hídrica con el tiempo, reduciendo el desperdicio incluso en períodos de alta demanda (Zhang et al., 2022).

En términos de implementación, la conectividad intermitente representó un desafío importante, afectando la recopilación continua de datos y la ejecución del riego automatizado. Este problema ha sido señalado en otros estudios de IoT agrícola, donde la infraestructura de comunicación y la estabilidad de la red pueden limitar la efectividad del sistema (Munusamy et al., 2021). Además, la falta de integración con datos meteorológicos externos restringe la capacidad de los modelos de predicción para adaptarse a cambios bruscos en el clima. La combinación de información local con pronósticos climáticos en tiempo real podría mejorar aún más la precisión y confiabilidad del sistema.

Desde una perspectiva práctica, los hallazgos respaldan la viabilidad del IoT para la gestión sostenible del agua en entornos urbanos. Sin embargo, la adopción de estas tecnologías sigue siendo un reto en regiones con infraestructura digital limitada. Investigaciones previas han señalado que la implementación de sistemas de riego automatizados depende de factores como el costo, la accesibilidad y la capacitación de los usuarios (FAO, 2020).

Esta investigación confirma que el uso de IoT y modelos predictivos mejora la eficiencia del riego en entornos urbanos, cumpliendo con las expectativas planteadas. No obstante, se recomienda la integración de modelos híbridos y la incorporación de más variables ambientales para optimizar la precisión de las predicciones y fortalecer la estabilidad operativa del sistema.

8. CONCLUSIONES

En esta investigación, se ha demostrado que la implementación de un sistema de riego inteligente basado en Internet de las Cosas (IoT) optimiza significativamente el uso del agua en cultivos de tomate, lo que resulta en una reducción considerable del desperdicio y en un uso más eficiente de los recursos hídricos. Mediante la utilización de sensores que monitorean en tiempo real la humedad del suelo y las condiciones climáticas, junto con un modelo de predicción basado en la evapotranspiración, se ha logrado ajustar de manera precisa la cantidad de agua necesaria para el cultivo, consiguiendo un ahorro de hasta un 20% de agua en las épocas de verano y un 25% en invierno.

Además, este sistema automatizado ha demostrado su viabilidad para la agricultura urbana, una solución especialmente relevante en ciudades donde el acceso al agua es limitado. El sistema no solo permite la irrigación precisa y automática de cultivos en entornos domésticos como balcones y azoteas, sino que también contribuye a la sostenibilidad de la agricultura en estos espacios, mejorando la salud de las plantas y el rendimiento de los cultivos.

Sin embargo, se identificaron algunos desafíos técnicos que requieren mejoras para aumentar la eficiencia y la capacidad del sistema. Uno de los principales retos fue la necesidad de incorporar un modo de hibernación en los dispositivos para reducir el consumo energético, así como la integración de módulos adicionales para un monitoreo más detallado del estado de las plantas. Estas mejoras tecnológicas permiten que el sistema funcione de manera más precisa, especialmente en condiciones climáticas extremas o cuando los niveles de humedad del suelo cambian de forma abrupta.

Aunque la investigación se centró en el cultivo de tomate cherry, los resultados sugieren que el sistema puede adaptarse fácilmente a otros tipos de cultivos ajustando los coeficientes de riego según las necesidades de cada planta. Esto abre la posibilidad de aplicar esta tecnología en diversos entornos agrícolas, tanto urbanos como rurales, promoviendo una mayor eficiencia hídrica en diferentes tipos de cultivo.

En conclusión, el sistema de riego inteligente desarrollado en este estudio tiene un gran potencial para ser expandido y mejorado. Integrar tecnologías más avanzadas, como la inteligencia artificial aplicada al monitoreo del estado de las plantas, permitiría aumentar la precisión en la gestión del agua y proporcionar un seguimiento más exhaustivo del crecimiento y la salud de los cultivos. De esta manera, el sistema contribuye a la adopción de prácticas agrícolas más sostenibles y eficientes, beneficiando tanto a la agricultura urbana como a la tradicional.

9. TRABAJOS FUTUROS

A partir de los resultados obtenidos en esta investigación, se plantean diversas oportunidades para mejorar y expandir el sistema de irrigación inteligente. En primer lugar, se sugiere optimizar el algoritmo de riego incorporando técnicas avanzadas de predicción, como la combinación de ARIMA con modelos de machine learning más sofisticados, lo cual permitirá mejorar la precisión en la estimación de las necesidades hídricas del cultivo. Además, ajustar el riego a las diferentes fases de crecimiento de la planta mediante coeficientes específicos de evapotranspiración optimizaría aún más el uso del agua, adaptando el sistema a las necesidades particulares del cultivo en cada etapa.


Por otro lado, se recomienda ampliar el tamaño de muestra y diversificar los tipos de cultivos para evaluar la generalización del sistema. Probar con distintas plantas y sustratos permitiría validar su versatilidad en otros contextos agrícolas. A su vez, la incorporación de sensores adicionales, como sensores de pH, nutrientes o de radiación solar, mejoraría el control de variables críticas en el entorno agrícola, optimizando tanto el riego como la fertilización.

Finalmente, una mejora crucial sería el desarrollo de una interfaz de usuario intuitiva, que facilite el monitoreo y control remoto del sistema. Esto, junto con una optimización de la infraestructura de la base de datos para gestionar grandes volúmenes de datos y análisis históricos, permitiría una implementación más eficiente y escalable, tanto en entornos urbanos como en campos de cultivo más grandes.

REFERENCIAS

- Atzori, L., Iera, A., & Morabito, G. (2010). The Internet of Things: A survey. *Computer Networks*, 54(15), 2787-2805.
- Chandra, S., Bhilare, S., Asgekar, M., & Ramya, R. B. (2021). Crop Water Requirement Prediction in Automated Drip Irrigation System using ML and IoT. 2021 4th Biennial International Conference on Nascent Technologies in Engineering (ICNTE). <https://doi:10.1109/icnte51185.2021.9487767>
- Chemonics International Inc. (2008). Cultivo del Tomate. Programa de diversificación hortícola, 1-34. <https://cenida.una.edu.ni/relectronicos/RENF01CH517t.pdf>
- Concepción II, R., Lauguico, S., Almero, V. J., Dadios, E., Bandala, A., & Sybingco, E. (2020). Lettuce Leaf Water Stress Estimation Based on Thermo-Visible Signatures Using Recurrent Neural Network Optimized by Evolutionary Strategy. 2020 IEEE 8th R10 Humanitarian Technology Conference (R10-HTC). <https://doi:10.1109/r10-htc49770.2020.9356963>
- Dhillon, M. S., Dahms, T., Kuebert-Flock, C., Rummler, T., Arnault, J., Steffan-Dewenter, I., & Ullmann, T. (2023). Integrating Random Forest and crop modeling improves the crop yield prediction of winter wheat and oil seed rape. *Front Remote Sens*, 3, 1010978. <https://doi:10.3389/frsen.2022.1010978>
- Duarte-González, D. (2020). Sensores para la caracterización del suelo agrícola usados en agricultura de precisión. *Revista Ingeniería UC*, 27(3), 343-352.
- FAO. (2020). Agricultura Sostenible. <https://www.fao.org/3/x8234s/x8234s08.html>
- Fechas de las estaciones astronómicas en el Perú (SENAMHI). (2023). Mapa climático del Perú. SENAMHI. <https://www.gob.pe/11000-fechas-de-las-estaciones-astronomicas-en-el-peru>
- Fernández Fernández, A. (2023). Técnicas avanzadas de regresión aplicadas a la estimación de parámetros agronómicos en cultivos de cereales. Universidad Politécnica de Madrid. https://oa.upm.es/79781/1/ANTONIO_FERNANDEZ_FERNANDEZ.pdf
- Fierro Muñoz, K. N. (2023). Diseño de un sistema de monitoreo de calidad de agua para consumo humano en la ciudad de Guayaquil. Universidad Agraria del Ecuador. <https://cia.uagraria.edu.ec/Archivos/FIERRO%20MU%C3%91IZ%20KARLA%20NAYELLI.pdf>
- Gutiérrez, J., Villa-Medina, J. F., Nieto-Garibay, A., & Porta-Gándara, M. Á. (2022). Automated irrigation system using a wireless sensor network and GPRS module. *IEEE Transactions on Instrumentation and Measurement*, 63(1), 166-176. <https://doi.org/10.1109/TIM.2013.2276487>
- Gutiérrez-Lopera, J. E., Toloza-Rangel, J. A., Soto-Vergel, Á. J., López-Bustamante, O. A., & Guevara-Ibarra, D. (2021). Sistema integrado de monitoreo inalámbrico de variables agroambientales en un cultivo de tomate para la generación de mapas de intensidad. *Revista UIS Ingenierías*, 20(2), 163-180. <https://www.redalyc.org/journal/5537/553770380014/html/>
- Huang, G., Xu, X., Xiong, Y., & Huang, Q. (2018). Estimating evapotranspiration of processing tomato under plastic mulch using the SIMDualKc model. *Water*, 10(8), 1088. <https://doi.org/10.3390/w10081088>
- Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias. (2022). Estructura y uso de modelos de simulación de cultivos (MSC). <https://www.gob.mx/inifap/articulos/estructura-y-uso-de-modelos-de-simulacion-de-cultivos-msc>
- Jingxin Yu et al. (2020). A deep Learning Approach for multi-depth soil water content prediction in summer maize growth period. <https://doi:10.1109/ACCESS.2020.3034984>
- Kodali, R. K., & Mahesh, K. S. (2016). A low-cost implementation of MQTT using ESP8266. 2016 2nd International Conference on Contemporary Computing and Informatics (IC3I). <https://doi:10.1109/ic3i.2016.7917998>
- Landeros-Sánchez, C., Osorio-Acosta, F., & Sol-Sánchez, A. (2016). Evaluación de la evapotranspiración real estimada y rendimiento de caña de azúcar en Veracruz. En *La bioeconomía: un enfoque emergente ante el reto del cambio climático*. Colegio de Postgraduados, 44-48.
- Michalis, E., Giatra, C.-E., Skordos, D., & Ragkos, A. (2023). Assessing the different economic feasibility scenarios of a hydroponic tomato greenhouse farm: A case study from Western Greece. *Sustainability*, 15(19), 14233. <https://doi.org/10.3390/su151914233>

- Munusamy, S., Al-Humairi, S. N. S., & Abdullah, M. I. (2021). Automatic Irrigation System: Design and Implementation. 2021 IEEE 11th IEEE Symposium on Computer Applications & Industrial Electronics (ISCAIE). <https://doi:10.1109/iscaie51753.2021.9431829>
- Palominos-Rizzo, T., Villatoro-Sánchez, M., Alvarado-Hernández, A., Cortés-Granados, V., & Paguada-Pérez, D. (2022). Estimación de la humedad del suelo mediante regresiones lineales múltiples en Llano Brenes, Costa Rica. *Agronomía Mesoamericana*, 33(2). <https://doi:10.15517/am.v33i2.47872>
- Parkash, V., & Singh, S. (2020). A Review on Potential Plant-Based Water Stress Indicators for Vegetable Crops. *Sustainability*, 12(10), 3945. <https://doi:10.3390/su12103945>
- Pedrozo Acuña, A. (2022). Escasez de agua, disponibilidad y agricultura. <https://dx.doi.org/10.24850/b-imta-perspectivas-2022-22>
- Penagos-Figueroa, J. S., & Velasco-Olarte, S. V. (2023). Diseño de sistema automatizado de innovación en los cultivos hidropónicos mediante tecnologías 4.0. Repositorio Universidad de Santander. <https://repositorio.udes.edu.co/bitstreams/ead50284-966b-44e0-a56c-ca8a2a155464/download>
- Robles-Casillas, F., Becerra-López, M. M., Ávila-López, C., et al. (2023). Planta de tratamiento inteligente de aguas residuales con un sistema y método de monitoreo. *Conciencia Tecnológica*, 65, 33-47. <https://www.redalyc.org/journal/944/94475786004/>
- Rungee, J., Ma, Q., Goulden, M., & Bales, R. (2021). Evapotranspiration and runoff patterns across California's Sierra Nevada. *Frontiers*. <https://doi:10.3389/frwa.2021.655485>
- Sánchez, F. J. (2022). *Hidrología Superficial y Subterránea*. 2ª ed. Kindle Direct Publishing.
- Saptadi, A. H. (2014). Perbandingan Akurasi Pengukuran Suhu dan Kelembaban Antara Sensor DHT11 dan DHT22. *Jurnal Infotel*, 6(2), 49-56. <https://doi:10.20895/infotel.v6i2.16>
- Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI). (2020). Mapa climático del Perú. SENAMHI. <https://www.senamhi.gob.pe/?p=mapa-climatico-del-peru>
- Shafi, U., Mumtaz, R., Iqbal, N., Zaidi, S. M. H., Zaidi, S. A. R., Hussain, I., & Mahmood, Z. (2020). A Multi-Modal Approach for Crop Health Mapping Using Low Altitude Remote Sensing, Internet of Things (IoT) and Machine Learning. *IEEE Access*, 112708-112724. <https://doi:10.1109/ACCESS.2020.3002948>
- Verdouw, C. N., Wolfert, S., Beulens, A. J., & Rialland, A. (2016). IoT in agriculture: Sustainable solutions. *Computers and Electronics in Agriculture*, 125, 12-21.
- Villarroel González, C., Goykovic Cortés, V., Collao Caiconte, P., Barraza Rodríguez, M., Fernández Fuentes, J., Villarroel Figueroa, Á., Valdivia Pinto, R., & Castro Cruz, C. (2019). Evaluación de desempeño de un invernadero ubicado en el desierto de Atacama, Chile, a través de IoT. *Interciencia*, 44(7), 386-394. <https://www.redalyc.org/journal/339/33960285003/html/>
- Xue, D., & Huang, W. (2021). Smart Agriculture Wireless Sensor Routing Protocol and Node Location Algorithm Based on Internet of Things Technology. *IEEE Sensors Journal*, 21(22), 24967–24973. <https://doi:10.1109/jsen.2020.3035651>
- Zambrano Vizueté, M., Botto-Tobar, M., & Diaz Cadena, A. (Eds.). (2021). *I+D for Smart Cities and Industry: Proceedings of RITAM 2021*. Springer. <https://doi.org/10.1007/978-3-031-11295-9>
- Zhang, H., He, L., Di Gorgia, F., Choi, D., Elia, A., & Heinemann, P. (2022). LoRaWAN based internet of things (IoT) system for precision irrigation.

 **turnitin** Página 2 of 41 - Integrity Overview Identificador de la entrega tmzold::13251120808

7% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.




Filtered from the Report

- ▶ Bibliography
- ▶ Quoted Text

Exclusions


- ▶ 1 Excluded Source
- ▶ 3 Excluded Matches

Top Sources

- 0%  Internet sources
- 2%  Publications
- 2%  Submitted works (Student Papers)

Integrity Flags

1 Integrity Flag for Review

-  **Replaced Characters**
42 suspect characters on 13 pages
Letters are swapped with similar characters from another alphabet.

Our system's algorithms look deeply at a document for any inconsistencies that would set it apart from a normal submission. If we notice something strange, we flag it for you to review.

A Flag is not necessarily an indicator of a problem. However, we'd recommend you focus your attention there for further review.