Universidad Nacional Mayor de San Marcos
Universidad del Perú. Decana de América
Facultad de Ingeniería Electrónica y Eléctrica
Escuela Profesional de Ingeniería Electrónica

Diseño e implementación de un prototipo de sistema de riego inteligente basado en inteligencia artificial para cultivos en Andajes

TESIS

Para optar el Título Profesional de Ingeniero Electrónico

AUTOR

Luis Gustavo LEZMA TAPIA

ASESOR

Mg. Victor Edmundo ALVA SALDAÑA

Lima, Perú

2026



Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

https://creativecommons.org/licenses/by-nc-sa/4.0/

Usted puede distribuir, remezclar, retocar, y crear a partir del documento original de modo no comercial, siempre y cuando se dé crédito al autor del documento y se licencien las nuevas creaciones bajo las mismas condiciones. No se permite aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros a hacer cualquier cosa que permita esta licencia.

Referencia bibliográfica

Lezma, L. (2026). *Diseño e implementación de un prototipo de sistema de riego inteligente basado en inteligencia artificial para cultivos en Andajes*. [Tesis de pregrado, Universidad Nacional Mayor de San Marcos, Facultad de Ingeniería Electrónica y Eléctrica, Escuela Profesional de Ingeniería Electrónica]. Repositorio institucional Cybertesis UNMSM.

Metadatos complementarios

Datos de autor	
Nombres y apellidos	Luis Gustavo Lezma Tapia
Tipo de documento de identidad	DNI
Número de documento de identidad	75605426
URL de ORCID	No Aplica
Datos de asesor	
Nombres y apellidos	Víctor Edmundo Alva Saldaña
Tipo de documento de identidad	DNI
Número de documento de identidad	07299248
URL de ORCID	https://orcid.org/0009-0000-7698-2993
Datos del jurado	
Presidente del jurado	
Nombres y apellidos	Celso Ysidro Geronimo Huaman
Tipo de documento	DNI
Número de documento de identidad	09191500
Miembro del jurado 1	
Nombres y apellidos	Juan Francisco Tisza Contreras
Tipo de documento	DNI
Número de documento de identidad	07206008
Miembro del jurado 2	
Nombres y apellidos	Jorge Elías Moscoso Sánchez
Tipo de documento	DNI
Número de documento de identidad	08596442
Datos de investigación	
Línea de investigación	ODS9. 21. Inteligencia Artificial
Grupo de investigación	No Aplica
Agencia de financiamiento	No Aplica

Ubicación geográfica de la investigación	País: Perú Departamento: Lima Provincia: Oyón Distrito: Andajes Centro poblado: Churín Latitud: -10.812691 Longitud: -76.876507
Año o rango de años en que se realizó la investigación	Enero 2026 - Junio 2026
URL de disciplinas OCDE	Ingeniería eléctrica, Ingeniería Electrónica https://purl.org/pe-repo/ocde/ford#2.02.01

UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS
(Universidad del Perú, DECANA DE AMÉRICA)
FACULTAD DE INGENIERÍA ELECTRÓNICA Y ELÉCTRICA
Teléfono 619-7000 Anexo 4226
Calle Germán Amezaga 375 – Lima 1 – Perú

ACTA DE SUSTENTACIÓN

TESIS

ACTA N°75/FIEE-PPP/2026

Los suscritos Miembros del Jurado, docentes permanentes de las Escuelas Profesionales de la Facultad de Ingeniería Electrónica y Eléctrica, reunidos en la fecha 15 de Octubre del 2026, como Presidente de Jurado el **DR. CELSO YSIDRO GERONIMO HUAMAN,** integrado por el Miembro de Jurado el **DR. JORGE ELÍAS MOSCOSO SÁNCHEZ,** el Miembro de Jurado el **MG. JUAN FRANCISCO TISZA CONTRERAS y** Miembro Asesor el **MG. VICTOR EDMUNDO ALVA SALDAÑA.**

Después de escuchar la Sustentación Presencial de la Tesis del Bachiller **LUIS GUSTAVO LEZMA TAPIA** con código 20190067 que para optar el Título Profesional de Ingeniero Electrónico sustentó la Tesis titulada **DISEÑO E IMPLEMENTACIÓN DE UN PROTOTIPO DE SISTEMA DE RIEGO INTELIGENTE BASADO EN INTELIGENCIA ARTIFICIAL PARA CULTIVOS EN ANDAJES.**

El jurado examinador procedió a formular las preguntas reglamentarias y, luego de una deliberación en privado, decidió otorgarle el calificativo de 15 (quince).

Ciudad Universitaria, 15 de Octubre del 2026

DR. CELSO YSIDRO GERONIMO HUAMAN
Presidente Jurado

MG. JUAN FRANCISCO TISZA CONTRERAS
Miembro Jurado

DR. JORGE ELÍAS MOSCOSO SÁNCHEZ
Miembro Jurado

MG. VICTOR EDMUNDO ALVA SALDAÑA
Miembro Asesor

UNIVERSIDAD NACIONAL MAYOR DE
SAN MARCOS
Universidad del Perú, Decana de América

CERTIFICADO DE SIMILITUD

Yo, **VICTOR EDMUNDO ALVA SALDAÑA** en mi condición de asesor acreditado con el Dictamen N°76/FIEE-PPP/2026 de la Tesis titulada **DISEÑO E IMPLEMENTACIÓN DE UN PROTOTIPO DE SISTEMA DE RIEGO INTELIGENTE BASADO EN INTELIGENCIA ARTIFICIAL PARA CULTIVOS EN ANDAJES,** presentado por el bachiller LUIS GUSTAVO LEZMA TAPIA, para optar el título profesional de Ingeniero Electrónico. CERTIFICO que se ha cumplido con lo establecido en la Directiva de Originalidad y de Similitud de Trabajos Académicos, de Investigación y Producción Intelectual. Según la revisión, análisis y evaluación mediante la plataforma PIDS, el documento evaluado cuenta con el 09% de similitud, nivel PERMITIDO para continuar con los trámites correspondientes y para su publicación en el repositorio institucional.

Se emite el presente certificado en cumplimiento de lo establecido en las normas vigentes, como uno de los requisitos para la obtención del título profesional de Ingeniero Electrónico.

Lima, 15 de Octubre del 2026

Firma del Asesor

DNI: 07299248

Nombres y apellidos del asesor:
VICTOR EDMUNDO ALVA SALDAÑA

AGRADECIMIENTO

Quiero expresar mi más sincero agradecimiento a mis padres, hermana y abuelos, quienes siempre han creído en mí desde el inicio, brindándome su apoyo incondicional durante todo este camino.

De igual manera, a mi asesor de tesis por su paciencia, orientación y valiosos aportes, los cuales fueron cruciales para el enfoque y desarrollo del presente trabajo de investigación. Su dedicación me permitió fortalecer mis conocimientos y encaminar adecuadamente este proyecto de investigación.

RESUMEN

Diseño e implementación de un prototipo de sistema de riego inteligente basado en inteligencia artificial adaptativa, para mejorar el control de eficiencia de recursos hídricos en áreas de cultivo para el distrito de Andajes (Churín). El sistema está compuesto por la integración del sistema de riego por goteo, sensores de humedad de suelo, sensores de temperatura y humedad ambiental, para evaluar el estado hídrico de los cultivos y tomar decisiones de riego de forma autónoma. Se diseñó un sistema de control basado en el sistema embebido Jetson Orin Nano Developer Kit, sensores de recopilación de datos, actuadores electromecánicos implementados en un sistema de riego por goteo, además de implementar un software para su programación que permiten la adquisición, procesamiento y análisis de datos en tiempo real. Se implementó un modelo de inteligencia artificial adaptativa que optimiza la activación de las electroválvulas para mantener las condiciones adecuadas de humedad en el área de cultivo y se establece un esquema comparativo del sistema de riego por goteo convencional y el propuesto con inteligencia artificial adaptativa. Se analizó indicadores como consumo de agua, estabilidad de humedad y frecuencia de riego, para determinar la eficiencia del sistema inteligente frente al método tradicional.

Palabras Clave: Riego inteligente, Goteo, Eficiencia, Cultivos.

ABSTRACT

Design and implementation of a prototype smart irrigation system based on adaptive artificial intelligence to improve water resource efficiency in agricultural areas of the Andajes district (Churin). The system integrates a drip irrigation system with soil moisture sensors and ambient temperature and humidity sensors to assess crop water status and make autonomous irrigation decisions. A control system was designed based on the Jetson Orin Nano Developer Kit embedded system, data collection sensors, and electromechanical actuators implemented in a drip irrigation system. Software was also implemented for programming the system, enabling real-time data acquisition, processing, and analysis. An adaptive artificial intelligence model was implemented to optimize the activation of solenoid valves to maintain adequate moisture conditions in the agricultural area. A comparative analysis was conducted between the conventional drip irrigation system and the proposed system with adaptive artificial intelligence. Indicators such as water consumption, moisture stability, and irrigation frequency were analyzed to determine the efficiency of the smart system compared to the traditional method.

Key Words: Intelligent Irrigation, Drip Irrigation, Efficiency, Cultivation

ÍNDICE GENERAL

CARATULA **i**
RESUMEN **iii**
ABSTRACT **iv**
ÍNDICE GENERAL **v**
LISTA DE FIGURAS **viii**
LISTA DE TABLAS **x**
CAPITULO I: 1
INTRODUCCIÓN 1
I.1. Introducción 1
I.2. Planteamiento del problema 5
I.2.1. Determinación del problema 5
I.2.2. Formulación del problema Problema general 7
I.3. Objetivos 8
I.3.1. Objetivo General 8
I.3.2. Objetivo Específicos 8
I.4. Importancia y alcance de la investigación 9
I.5. Limitaciones de la investigación 12
CAPITULO II: 15
REVISIÓN DE LA LITERATURA 15
II.1. Marco teórico 15
II.1.1. Escasez del recurso hídrico en la agricultura de la sierra peruana 15
II.1.2. Agricultura de Precisión y Eficiencia Hídrica 16
II.1.3. Automatización de sistemas de riego y eficiencia 20
II.2. Antecedentes del estudio 21
II.2.1. Antecedentes Internacionales 21
II.2.2. Antecedentes Nacionales 25
II.3. Bases teóricas 28
II.3.1. Sensores de Humedad del Suelo 28
II.3.1.1. Fundamentos de medición de humedad. 28

II.3.1.2. Fundamentos eléctricos. 29
II.3.1.3. Tipos de sensores de humedad del suelo. 31
II.1.3.4. Selección del sensor para sistemas de riego. 32
II.3.2. Sistemas Embebidos en Automatización 32
II.3.2.1. Características de los sistemas embebidos. 33
II.3.2.2. Jetson Nano Plataforma. 34
II.3.3. Fundamentos de Machine Learning 35
II.3.4. Sistemas de Control Automático 38
II.3.4.1. Sistema de lazo abierto. 39
II.3.4.2. Sistema de lazo cerrado. 39
II.3.4.3. Variables de entrada y salida. 40
II.3.4.4. Sistema de decisión. 40
II.3.5. Sistemas de riego por goteo 41
II.4. Definición de términos 44
CAPITULO III: 46
HIPÓTESIS Y VARIABLES 46
III.1. Hipótesis 46
III.1.1. Hipótesis general 46
III.1.2. Hipótesis específicas 46
III.2. Variables 46
III.2.1. Variables independientes 47
III.2.2. Variables dependientes 47
III.2.3. Variables de control 47
III.3. Operacionalización de las variables 47
CAPITULO IV: 48
MATERIALES Y MÉTODOS 48
IV.1. Área de estudio 49
IV.2. Diseño de investigación 51
IV.3. Población y muestra 56
IV.4. Procedimientos, técnicas e instrumentos de recolección de información. 58
IV.4.1. Procedimientos 58
IV.4.2. Técnicas 67
IV.4.3. Instrumentación 67
IV.5. Análisis estadístico 68
CAPITULO V: 70

RESULTADOS 70
V.1. Presentación y análisis de los resultados 70
V.1.1. Implementación de la arquitectura tecnológica propuesta 70
V.1.2. Evaluación del Modelo Random Forest 72
V.1.2.1. Configuración del modelo Random Forest 72
V.1.2.2. Evaluación del desempeño predictivo 73
V.1.2.3. Capacidad de adaptación del sistema 74
V.1.3. Comparación experimental entre sistemas 75
V.1.3.1. Consumo de agua 75
V.1.3.2. Frecuencia de activación del sistema 76
V.1.3.3. Tiempo total de riego 77
V.1.3.4. Estabilidad de la humedad del suelo 78
V.1.4. Eficiencia hídrica del sistema propuesto 80
V.1.4.1. Consumo acumulado de agua 80
V.1.4.2. Porcentaje de ahorro hídrico 81
V.1.4.3. Relación entre ahorro de agua y estabilidad de humedad 81
V.1.5. Análisis estadístico y contraste de hipótesis 83
V.1.5.1. Estadística descriptiva 83
V.1.5.2. Prueba de normalidad 84
V.1.5.3. Contraste estadístico del consumo de agua 84
V.1.5.4. Contraste estadístico de la humedad del suelo 85
V.1.5.5. Contraste estadístico del tiempo de riego 86
V.1.6. Contraste de hipótesis 86
CAPITULO VI: 88
DISCUSIÓN 88
CAPITULO VII: 98
CONCLUSIONES 98
CAPITULO VIII: 100
RECOMENDACIONES 100
CAPITULO IX: 102
BIBLIOGRAFÍA 102
CAPITULO X: 110
ANEXOS 110

LISTA DE FIGURAS

Figura 1. Adopción de IA según sectores. 3
Figura 2. Estados de la humedad del suelo en el desarrollo plantas. 29
Figura 3. Fórmula elemental de la conductividad.....30
Figura 4. Estructura interna de sensor capacitivo de suelo.....31
Figura 5. Sensor de suelo capacitivo. 32
Figura 6. Sistema embebido Jetson Orin Nano Developer Kit.. 35
Figura 7. Árbol de decisión regresión. 37
Figura 8. Electroválvula de 12V. 42
Figura 9. Riego por goteo.).....43
Figura 10. Vista Satelital de Lima.. 51
Figura 11. Mapa topológico del sistema. 54
Figura 12. Flujograma del proceso. 56
Figura 13. Vista Satelital de Churín, Lima.....57
Figura 14. Área de estudio. 57
Figura 15. Área de estudio antes de estandarizar.....59
Figura 16. Área de estudio con impurezas reducidas. 59
Figura 17. Área de estudio con surcos preparados.....60
Figura 18. Instalación de sistema de riego. 60
Figura 19. Electroválvula seleccionada 61
Figura 20. Instalación de infraestructura y tablero 62
Figura 21. Cableado e instalaciones en el tablero 62
Figura 22. Plano de Hardwaredel sistema. 63
Figura 23. Instalación de sensores 63
Figura 24. Pantalla de Inicio y Login de Nvidia 64
Figura 25. Código del motor de inferencia con Random Forest 65
Figura 26. Detalle del ciclo de predicción con Random Forest 65
Figura 27. Consumo promedio diario de agua según sistema de riego.....76
Figura 28. Frecuencia promedio de activación diaria del sistema.. 77
Figura 29. Tiempo promedio diario de riego.. 78

Figura 30. Evolución de la humedad del suelo durante los 45 días de monitoreo. 79
Figura 31. Comparación integral de indicadores. 82

LISTA DE TABLAS

Cuadro 1. Uso global del agua por sector 20
Cuadro 2. Enfoques de riego 20
Cuadro 3. Operacionalización de las variables 47
Cuadro 4. Componentes en el sistema de riego inteligente 70
Cuadro 5. Distribución de sensores en área de estudio 71
Cuadro 6. Parámetros de configuración del modelo Random Forest 72
Cuadro 7. Desempeño del modelo Random Forest 73
Cuadro 8. Predicción generada por el modelo 74
Cuadro 9. Consumo promedio diario de agua durante el periodo experimental 76
Cuadro 10. Frecuencia promedio de activación del sistema 77
Cuadro 11. Tiempo promedio diario de riego 78
Cuadro 12. Comportamiento promedio de la humedad del suelo 79
Cuadro 13. Consumo acumulado de agua durante los 45 días de evaluación 80
Cuadro 14. Ahorro hídrico logrado por el sistema inteligente 81
Cuadro 15. Comparación de indicadores de desempeño 82
Cuadro 16. Estadísticos descriptivos de las variables evaluadas 83
Cuadro 17. Prueba de normalidad Shapiro-Wilk 84
Cuadro 18. Prueba t de Student para el consumo de agua 85
Cuadro 19. Prueba t de Student para humedad del suelo 85

CAPITULO I:
INTRODUCCIÓN

I.1. Introducción

En la actualidad, la agricultura viene enfrentando desafíos bastante grandes a causa del crecimiento poblacional, variabilidad climática y la ascendente presión sobre escases de los recursos naturales, haciendo énfasis en el recurso hídrico. En este sentido, como señala la FAO (2024) “El cambio climático es un desafío mundial que requiere la adopción de medidas integrales e intersectoriales, en particular en los sistemas agroalimentarios.” Bajo estas condiciones se ha visto la necesidad de impulsar la incorporación de diversas tecnologías de la información, control y comunicaciones en el sector agrícola, promoviendo el desarrollo de la agricultura de precisión, en la cual la automatización, el monitoreo y el análisis inteligente de los datos de campo permiten optimizar de forma eficiente el uso adecuado de los recursos y mejorar la productividad.

En el transcurso de esta evolución tecnológica, resalta la integración de sensores, sistemas embebidos y análisis de datos, estos permiten obtener la información precisa respecto a las condiciones del área de estudio, para este caso el área de cultivo y su entorno. Estas herramientas evidencian un avance significativo a comparación de los métodos tradicionales de monitoreo agrícola, principalmente porque posibilita una mejor toma de decisiones basada en el análisis de datos reales de campo y no únicamente con la experiencia empírica del personal agricultor.

La agricultura de precisión se viene consolidando como una estrategia tecnológica que se orienta en la mejora de eficiencia productiva a través de recopilar, procesar y analizar los datos que provienen del entorno agrícola.

El enfoque ha integrado herramientas de análisis inteligente y sensores que gestionen de manera específica las necesidades que tiene los cultivos. Se viene destacando que al aplicar tecnologías de monitoreo en tiempo real se puede optimizar el uso de recursos críticos como energía, agua y fertilizantes, que contribuyen a la sostenibilidad ambiental e incremento de la productividad agrícola, se reconoce además que la digitalización de estos procesos facilita la gestión y la efectiviza ante escenarios de incertidumbre climática y variabilidad del ambiente (Babar y Akan, 2024)

En áreas que cuentan con condiciones geográficas y climáticas variables, como es el caso de la localidad de Churín, el uso metódico de los riegos tradicionales basados en la experiencia del agricultor o en programaciones fijas genera un uso ineficiente del recurso hídrico. En este contexto, “Se prevé que las temperaturas sigan subiendo en toda Centroamérica, con un aumento significativo del estrés térmico extremo y períodos más largos de calor peligroso en algunos escenarios de calentamiento” (Ranasinghe y otros, 2021), lo que evidencia la creciente presión y variabilidad climática sobre los sistemas agrícolas. Provocando un déficit o exceso de agua en los cultivos del área, afectando su desarrollo adecuado y contribuyendo al desperdicio de un recurso que, con el paso de los años, se vuelve cada vez más limitado.

Los sistemas de riego inteligente vienen adquiriendo creciente importancia en la agricultura moderna debido a su capacidad para determinar automáticamente cuándo, dónde y cuánto debe regarse, empleando información que proviene de sensores de humedad en el suelo, variables meteorológicas y algoritmos de aprendizaje automático que permiten estimar con precisión los requerimientos hídricos de los cultivos. Se señala en diversas literaturas que los sistemas de riego inteligente se basan en datos que contribuyen de manera significativa a reducir el consumo de agua y energía, mejorando al mismo tiempo la uniformidad del riego y favorecer el desarrollo adecuado de las plantas, específicamente en las zonas en las que la disponibilidad de agua es limitada (Vallejo et al., 2023).

La Inteligencia Artificial actúa complementando la optimización de procesos, además se encarga de potenciar habilidades y permite la resolución de problemas complejos. La capacidad de aprendizaje y adaptación que posee abre oportunidades antes no mapeadas para la innovación, expandiendo las posibilidades en diferentes sectores y disciplinas. (MIDAGRI,2025)

El sector agrícola es en la actualidad uno de los sectores que muestran mayor rezago en su adaptabilidad al uso de la Inteligencia Artificial. Dentro de las muchas razones destacan principalmente la baja calidad e inconsistencia de los datos en campo. Asimismo, el alto costo de implementación de este tipo de tecnologías, a la par de la falta de dispositivos con un grado elevado de especialización que faciliten de forma más práctica su desarrollo en este sector. A ello se le añade la importancia de reforzar el desarrollo y la adecuada aplicación de las herramientas tecnológicas, con el objetivo de poder superar las exigentes limitaciones y sobre todo promover una adopción más competente. (MIDAGRI, 2025)

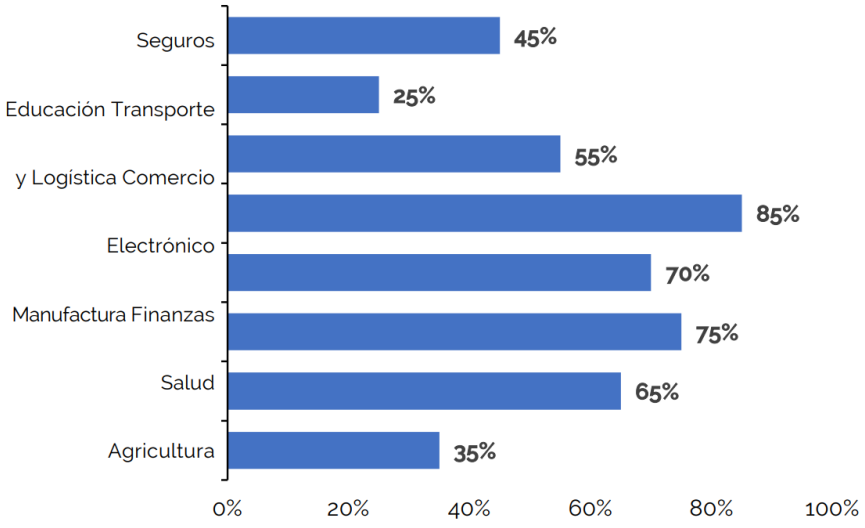

Figura 1. **Adopción de IA según sectores.** Fuente: Datos tomados de Oliveira y Silva (2023)

Frente a esta problemática actual, se propone el desarrollo de un sistema de riego inteligente basado en inteligencia artificial adaptativa, el cual es

capaz de analizar diversos parámetros y variables como la humedad del suelo, la temperatura y humedad ambiental para que, con la data adecuada y precisa, ésta pueda tomar la decisión más adecuada de manera autónoma y con aprendizaje constante. A diferencia de los sistemas tradicionales y convencionales, el sistema propuesto permite al usuario ajustar dinámicamente los tiempos y frecuencias de riego en función de la variación del comportamiento de las variables que se están monitoreando, así optimizando el uso adecuado del agua usada en las áreas de cultivo.

En la presente tesis se plantea el diseño e implementación de un prototipo funcional basado en un sistema de riego por goteo, en el cual se integran sensores de campo, un sistema embebido Jetson Orin Nano y un modelo de inteligencia artificial adaptativa, estas tecnologías permiten el procesamiento de datos en tiempo real, la automatización de procesos y la optimización del rendimiento del sistema (NVIDIA, 2024). Asimismo, se propone la validación del sistema a través de un análisis comparativo frente a un método de riego convencional en la zona de cultivo.

Desde la perspectiva de la ingeniería electrónica, el procesamiento de información en el borde de la red (Edge Computing) representa la alternativa eficiente que se requiere en la agricultura para tener capacidad inmediata de respuesta y operación en las zonas de conectividad limitada. La incorporación de plataformas de cómputo de alto rendimiento permite la ejecución de modelos de inteligencia artificial de manera directa en campo, amenorando la dependencia del servicio en la nube y amenorando los tiempos de respuesta en la toma de decisiones. En este contexto, integrar dispositivos especializados de sensores inteligentes, procesamiento y algoritmo de aprendizaje automático se constituye como la principal tendencia tecnológica para desarrollar sistemas agrícolas autónomos y sostenibles (Adli et al., 2023)

De esta forma, el proyecto busca contribuir al uso eficiente del recurso hídrico y sentar las bases para la implementación a futuras soluciones

agrícolas inteligentes aplicables a entornos rurales similares.

I.2. Planteamiento del problema

I.2.1. Determinación del problema

El constante crecimiento poblacional, el cambio climático impredecible y la presión sobre los recursos naturales en estos últimos años han intensificado la necesidad de una gestión más competente y sostenible del recurso hídrico en el sector agrícola (Camacho & González, 2024). Considerando este contexto tanto geográfico como climático en zonas rurales, en el caso de la localidad de Churín, se están empleando métodos de riego tradicionales que se basan netamente en la experiencia vivida del agricultor o del poblador a cargo, en situaciones un poco más modernas, se encuentran con una metodología de programaciones fijas, las cuales producen un uso ineficiente del agua. Este escenario conduce en su totalidad a condiciones de déficit sobre el riego, esto afecta el adecuado desarrollo de los cultivos que se estén llevando a cabo ya sea para venta o para consumo del agricultor, a su vez desperdiciando el uso del recurso limitado del agua.

La situación descrita no representa un problema aislado, es parte del problema global que se relaciona con la disponibilidad y gestión sostenible del agua. Según el Informe Mundial de las Naciones Unidas acerca del Desarrollo de los Recursos Hídricos, la agricultura representa la principal actividad en la que se consume agua dulce a nivel mundial, 70% del total de la extracción de agua en el mundo. Para UNESCO (2024) la creciente variabilidad climática y ocurrencia más frecuente de eventos extremos generan mayor incertidumbre en la planificación agrícola, sobre todo en zonas rurales y de montaña donde los sistemas productivos dependen de manera directa con la disposición hídrica estacional, esta necesidad se incrementa ante la necesidad de implementar una solución tecnológica para lograr una eficiente gestión y la sostenibilidad del recurso hídrico.

La problemática se agrava debido a la limitada incorporación de tecnologías que permitan monitorear en tiempo real las condiciones del suelo y del entorno, así como ajustar de manera dinámica las estrategias de riego. Si bien existen sistemas automatizados basados en sensores que permiten cierto nivel de control, la gran mayoría de estos sistemas funcionan bajo la condición de esquemas con umbrales fijos o programaciones predefinidas por el usuario, esto ocasiona que se vea restringida la capacidad de adaptación en sus sistemas frente a las variaciones ambientales y constantes cambios de riego en los cultivos.

El registro de los avances tecnológicos referidos a agricultura inteligente, indican que la adopción de herramientas que se basan en inteligencia artificial, Internet de las Cosas (IoT) y análisis predictivo corresponde en gran parte a explotaciones agrícolas de pequeña y mediana escala en América Latina. Se ha identificado factores relevantes como escasa infraestructura tecnológica de la que se dispone en zonas rurales, poca disponibilidad y acceso a los datos agrícolas estructurados y la necesidad de soluciones de bajo costo que puedan ser operados de modo autónomo en entornos en los que la conectividad sea restringida. La consecuencia viene a ser la brecha tecnológica que complica la transición hacia modelos eficientes y sostenibles de producción agrícola, particularmente en regiones en las que el recurso hídrico constituya un factor crítico para la productividad de los cultivos (FAO, 2024)

En base a esta situación, surge la necesidad de desarrollar sistemas de riego más inteligentes que no solo automaticen el proceso, sino que incorporen capacidades de adaptación basadas en el análisis del comportamiento de variables como la humedad del suelo y la temperatura ambiental. Según Bello-Pavón, García-Montoya y Lacayo-Arauz (2021) El sistema de riego por goteo establecerá la actividad de riego en momentos establecidos en base a la información que lea los sensores de campo, este será el punto inicial y midiendo los parámetros del suelo el sistema será enviado a apagar cuando el sensor detecte las medidas adecuadas

provocando así que las cintas de riego dejen de gotear, así ayudando a gestionar la humedad y la calidad del suelo. Tomando como base lo mencionado, la aplicación de un modelo de inteligencia artificial predictiva nos permite procesar data en tiempo real, dando la facilidad de tomar decisiones más precisas y eficientes en la gestión del riego.

Por lo tanto, el desafío tecnológico consiste en diseñar e implementar un sistema de riego inteligente que integre sensores, procesamiento de datos y un modelo de inteligencia artificial adaptativa capaz de optimizar el uso del agua en función de las condiciones reales del entorno. Asimismo, resulta necesario validar su desempeño mediante la comparación con métodos de riego convencionales, a fin de evidenciar mejoras en indicadores como el consumo de agua y la estabilidad de la humedad del suelo.

En consecuencia, la presente investigación plantea el desarrollo de un prototipo de sistema de riego por goteo basado en inteligencia artificial adaptativa, orientado a mejorar la eficiencia hídrica en cultivos a pequeña escala en el distrito de Andajes, contribuyendo a la modernización de las prácticas agrícolas y al uso sostenible del recurso hídrico.

I.2.2. Formulación del problema

Problema general

¿Cómo el diseño e implementación de un prototipo de sistema de riego inteligente basado en inteligencia artificial adaptativa y el uso de sensores de humedad del suelo y temperatura ambiental permite superar la ineficiencia del riego tradicional y optimizar el uso del recurso hídrico en cultivos del distrito de Andajes, provincia de Churín, en el año 2026?

Problemas específicos

1. ¿Cómo diseñar una arquitectura tecnológica adecuada que integre sensores de humedad del suelo, temperatura ambiental y actuadores hidráulicos en un prototipo de sistema de riego inteligente para las

condiciones del distrito de Andajes?

2. ¿Qué modelo de inteligencia artificial adaptativa es el más adecuado para analizar las variables de humedad y temperatura, permitiendo ajustar dinámicamente los tiempos y frecuencias de riego?

3. ¿Cómo diseñar el sistema de control para garantizar la adquisición de datos en tiempo real y la activación eficiente y confiable de las electroválvulas en el sistema de riego por goteo?

I.3. Objetivos

I.3.1. Objetivo General

Diseñar, implementar y evaluar experimentalmente un prototipo de sistema de riego inteligente basado en inteligencia artificial adaptativa, que permita optimizar el uso del recurso hídrico mediante el análisis de variables de humedad del suelo y temperatura ambiental en cultivos del distrito de Andajes, provincia de Churín, en el año 2026.

I.3.2. Objetivo Específicos

1. Diseñar una arquitectura tecnológica que integre sensores de humedad del suelo, temperatura ambiental, un sistema embebido y actuadores hidráulicos, adaptada a las condiciones del entorno de estudio.

2. Desarrollar e implementar un modelo de inteligencia artificial para predecir y ajustar los tiempos en función de la temperatura ambiental y humedad de suelo, mejorando la eficiencia operativa de sistema frente a esquemas tradicionales de riego.

3. Comparar el consumo de agua, la eficiencia hídrica y la estabilidad de la humedad del suelo entre el sistema de riego inteligente propuesto y un sistema de riego convencional mediante pruebas experimentales.

I.4. Importancia y alcance de la investigación

En esta investigación se contribuye al arduo desarrollo de la agricultura de precisión a través de la integración de sensores, de los sistemas embebidos e inteligencia artificial para la optimización del riego. En esta línea, la aplicación de técnicas de inteligencia artificial, tales como el aprendizaje automático y el análisis de datos, nos permite mejorar la toma de decisiones y la eficiencia de los sistemas agrícolas modernos (Tovar-Quiroz, 2023).

Desde esta perspectiva, la presente tesis propone un modelo de inteligencia artificial, el cual permite ajustar dinámicamente las decisiones de riego en base a las condiciones del suelo y ambiente, evidenciando un comportamiento adaptativo.

La incorporación creciente de tecnologías digitales en actividades agrícolas ha permitido la evolución desde modelos de gestión que se basan en la experiencia empírica hacia sistemas que se fundamentan en la toma de decisiones basados en datos. Para Javaid et al. (2023) la convergencia entre inteligencia artificial, Internet de las Cosas (IoT) y analítica de datos viene transformando los sistemas agrícolas pues proporciona mecanismos de monitoreo continuo, predicción de eventos y automatización de procesos críticos, estas capacidades favorecen la gestión eficiente de recursos productivos, sobre todo en escenarios en los que las condiciones ambientales son de alta variabilidad, como se manifiesta en ecosistemas agrícolas andinos.

El diseño y prototipado de un sistema de riego inteligente funcional ofrece una herramienta práctica e inmediata para el sector agrícola. A diferencia de soluciones únicamente teóricas, el prototipo propuesto constituye una alternativa tangible y adaptable a las condiciones de la provincia de Churín, distrito de Andajes. El enfoque en la automatización permite mejorar la operatividad del riego, reduciendo la dependencia de la experiencia

empírica del agricultor y optimizando el uso del recurso hídrico mediante decisiones basadas en datos en tiempo real.

En un nivel socioambiental como en el del Estado Peruano, las investigaciones abordan directamente la principal problemática, el agua, la cual constituye un desafío que se va agravando en el Perú con el pasar de los años. A causa de la presencia de eventos climáticos adversos, tales como las sequias recurrentes, el fenómeno del niño, el fenómeno de la niña, que afectan la disponibilidad del recurso hídrico y limitan el adecuado y progresivo desarrollo de las actividades agrícolas. En este escenario se genera un impacto significativo en la productividad del sector, al igual que incrementa la vulnerabilidad de los agricultores y se ve amenazado la sostenibilidad de los sistemas productivos, dejando así evidenciar la necesidad de implementar soluciones tecnológicas que permitan una mejor gestión del agua (Zegarra & Vásquez, 2023).

Al optimizar el uso del recurso hídrico, el proyecto promueve una gestión sostenible del agua en la comunidad. La implementación de un sistema de riego inteligente permite aplicar el agua en función de las necesidades reales del cultivo. De esta forma se reduce el desperdicio y se contribuye a la sostenibilidad agrícola de la zona. De igual forma, esta propuesta a futuro puede ser usada como cimiento para su aplicación en zonas del Perú con características similares que lo requieran.

Desde la óptica de la sostenibilidad, la modernización de sistemas de riego representa una estrategia efectiva para enfrentar la reciente presión sobre los recursos hídricos que se destinan a la producción agrícola. La literatura actual destaca que implementar tecnologías inteligentes de monitoreo y control permite la reducción significativa de pérdida de agua asociada a prácticas tradicionales, mejorando a la par la productividad y resiliencia de sistemas agrícolas frente a eventos climáticos extremos. Estas tecnologías facilitan la transición hacia un modelo de agricultura sostenible que se alinee a objetivos de eficiencia energética y conservación de los recursos

naturales que se promueve a nivel internacional (Klerkx y Rose, 2024)

Visto desde el ámbito académico y especialmente científico, el estudio presentado contribuye al desarrollo del aprendizaje en la agricultura de precisión, a través de la integración de sensores, inteligencia artificial y sistemas embebidos en un sistema implementado. El Machine Learning es una subdisciplina de la inteligencia artificial que nos permite analizar grandes volúmenes de datos y extraer patrones útiles para la toma de decisiones de forma eficiente, lo cual resulta crucial en la optimización de procesos para los nuevos sistemas agrícolas modernos (Benos et al., 2021).

En el campo de la tecnología, la presente investigación confirma la viabilidad del uso de plataformas embebidas de alto rendimiento, como es el caso de la Jetson Orin Nano, para la implementación de sistemas inteligentes aplicados a la agricultura. La aplicación de sensores ambientales, procesamiento de datos y algoritmos de *machine learning* permite además del monitoreo continuo de variables críticas como la humedad del suelo y las condiciones ambientales, así como la identificación de patrones y la predicción de requerimientos hídricos en los cultivos. Tomando aquello como referencia, diversos estudios señalan que la agricultura de precisión se apoya en tecnologías digitales avanzadas para incrementar la eficiencia de la gestión de recursos y fortalecer la productividad mediante la automatización de decisiones (Patiño Perdomo et al., 2025). De igual forma, la implementación de sistemas inteligentes capaces de decidir la acción de dispositivos como electroválvulas en función de datos analizados en tiempo real representa una aplicación directa de la Ingeniería en entornos rurales, aportando al desarrollo de soluciones escalables, adaptativas y sostenibles frente a problemáticas como la escasez de agua y la variabilidad climática.

La investigación aborda el diseño, la implementación y validación de un prototipo funcional de sistema de riego inteligente basado en inteligencia

artificial, empleando técnicas de machine learning, aplicado a un sistema de riego por goteo en un entorno experimental a escala controlada. Asimismo, el sistema se desarrolla considerando las condiciones geográficas y climáticas de la provincia de Churín, distrito de Andajes.

El alcance incluye la adquisición de datos mediante sensores de humedad del suelo y temperatura ambiental, el desarrollo de un modelo de inteligencia artificial para la toma de decisiones y la implementación de un sistema de control automático para la activación de electroválvulas. Asimismo, se contempla el registro y análisis de datos en tiempo real para evaluar el comportamiento del sistema.

Se realizarán pruebas experimentales comparativas considerando condiciones, evaluando el desempeño del sistema propuesto frente a un sistema de riego convencional basado en programación fija, considerando indicadores como el consumo de agua, la frecuencia de riego y la estabilidad de la humedad del suelo.

El sistema será diseñado de manera modular, permitiendo su futura expansión a mayores áreas de riego y la incorporación de nuevos sensores o funcionalidades.

La investigación no contempla la producción industrial ni la comercialización del sistema, limitándose al desarrollo y evaluación de un prototipo a nivel experimental.

I.5. Limitaciones de la investigación

La presente investigación se desarrolla con un enfoque aplicado e innovador, proponiendo una solución tecnológica avanzada para el riego inteligente mediante visión e inteligencia artificiales. No obstante, como todo trabajo de investigación de carácter experimental y de prototipado, presenta ciertas limitaciones que no disminuyen su valor, sino que delimitan claramente su alcance y abren oportunidades para futuras investigaciones.

En primer lugar, el sistema propuesto se implementa y valida a nivel de prototipo funcional, orientado a demostrar la viabilidad técnica y operativa del enfoque planteado. Las pruebas experimentales se realizan en un entorno agrícola específico de la provincia de Churín, distrito de Andajes, lo cual permite un análisis profundo y contextualizado del problema, aunque limita la extrapolación directa de los resultados a otros cultivos, regiones o condiciones agroclimáticas sin una adaptación previa del sistema.

Asimismo, el desempeño del módulo de visión artificial depende de factores externos inherentes al entorno agrícola, tales como las condiciones de iluminación natural, variaciones climáticas, presencia de sombras, polvo o elementos visuales no controlados. Si bien el diseño del sistema considera procesos de calibración y ajuste de los algoritmos, estas variables pueden influir en la precisión del análisis visual, especialmente en escenarios extremos.

De igual manera, los algoritmos de inteligencia artificial aplicados en el sistema necesitan un proceso de aprendizaje respaldado en datos representativos del marco agrícola. En estas condiciones, el entrenamiento del modelo se realiza con un conjunto de datos delimitado y controlado, desarrollado para recopilar las principales variaciones de las variables ambientales pertinentes. Este criterio es consistente con prácticas ampliamente utilizadas en el desarrollo de prototipos tecnológicos, donde se prioriza la validación funcional del sistema antes de su escalamiento. Diversos estudios en agricultura de precisión indican que los modelos iniciales pueden ser entrenados con data acotados para evaluar su desempeño y comportamiento en condiciones controladas, permitiendo posteriormente su mejora progresiva mediante la incorporación de nuevos datos y procesos de ajuste fino.

En última instancia, la presente investigación se orienta al desarrollo electrónico del sistema, la integración de sus componentes de hardware y

software, así como a la evaluación técnica de su funcionamiento, excluyendo el análisis económico, la producción a gran escala y la valoración comercial del prototipo. Dichos aspectos se proponen como líneas de trabajo futuras, lo que resalta el carácter sólido, escalable y proyectable de la solución desarrollad

CAPITULO II:
REVISIÓN DE LA LITERATURA

II.1. Marco teórico

II.1.1. Escasez del recurso hídrico en la agricultura de la sierra peruana

Durante el periodo 2015–2025, la gestión del recurso hídrico en el Perú ha evidenciado importantes desafíos, particularmente en las regiones de la sierra, donde la agricultura depende en gran medida de la disponibilidad estacional del agua. A nivel nacional, la distribución del recurso hídrico presenta una marcada desigualdad espacial, concentrándose la mayor disponibilidad en la vertiente amazónica, mientras que las zonas andinas presentan limitaciones en el acceso al agua para actividades productivas (Autoridad Nacional del Agua [ANA], 2020).

En el sector agrícola, el uso del agua constituye la principal demanda del recurso hídrico en el país. De acuerdo con la ANA (2020), la actividad agraria representa aproximadamente entre el 70 % y 80 % del uso total del agua, lo cual evidencia la alta dependencia de este recurso para la producción agrícola. Esta situación genera una presión significativa sobre la disponibilidad hídrica, especialmente en regiones altoandinas donde las fuentes de agua son limitadas y altamente variables.

Asimismo, las condiciones climáticas propias de la sierra peruana intensifican esta problemática. La variabilidad de las precipitaciones y la estacionalidad de las lluvias afectan directamente la disponibilidad de agua para riego. Según el Ministerio del Ambiente del Perú (2021), el cambio climático ha generado alteraciones en los patrones hidrológicos,

incrementando la frecuencia de eventos extremos como sequías, lo cual repercute negativamente en la seguridad hídrica de las zonas rurales.

El retroceso de los glaciares tropicales en el Perú constituye un factor crítico en la reducción de las reservas hídricas naturales. El MINAM (2021) señala que la pérdida progresiva de masa glaciar ha disminuido la disponibilidad de agua en cuencas altoandinas, afectando directamente las actividades agrícolas que dependen de estos recursos.

Los sistemas de riego utilizados en la sierra peruana presentan limitaciones en términos de eficiencia. De acuerdo con el Instituto Nacional de Innovación Agraria (2020), el uso predominante de técnicas tradicionales de riego, como el riego por gravedad, genera pérdidas significativas de agua durante su conducción y aplicación, lo que reduce la eficiencia hídrica del sistema productivo.

En este contexto, la escasez del recurso hídrico en la agricultura de la sierra peruana no solo responde a factores naturales, sino también a deficiencias en la gestión y uso del agua. Esta situación evidencia la necesidad de implementar soluciones tecnológicas que permitan optimizar la eficiencia hídrica, mejorar la toma de decisiones y reducir las pérdidas en los sistemas de riego.

II.1.2. Agricultura de Precisión y Eficiencia Hídrica

La agricultura está clasificada como el sector con mayor consumo de agua dulce a nivel mundial, esto representa aproximadamente el 70% de las extracciones totales, y en países en desarrollo representa el 90% (FAO, 2021; UNESCO, 2023). Debido a este elevado nivel de demanda, es posicionado como un componente crítico dentro de las estrategias de gestión del recurso del agua. Bajo este contexto, en las regiones más afectadas por el estrés hídrico, el recurso hídrico toma un papel determinante no solo nos garantizará la seguridad alimentaria, sino además tiene el objetivo de preservar de forma equilibrada el ambiente y la

sostenibilidad de los ecosistemas (World Bank, 2022).

En este sentido es evidente la necesidad de poder incorporar nuevas soluciones usando las herramientas tecnológicas que nos permitan incrementar la eficiencia en el adecuado uso del agua en el rubro de la agricultura (FAO, 2021; UNESCO, 2023). En función de lo anterior la agricultura de precisión ha sido fundamental en el enfoque de optimizar la gestión del recurso hídrico, a través de la incorporación de sensores, sistemas de monitoreo y herramientas de análisis de datos (World Bank, 2022).

Bajo este planteamiento, la implementación de técnicas de inteligencia artificial, como es el caso del *machine learning*, nos permite no solo supervisar variables ambientales en tiempo real, sino además poder identificar patrones y predecir las necesidades hídricas de los cultivos a futuro, de esta manera facilitando la toma de decisiones automatizadas (Liakos et al., 2020).

Según lo antes mencionado, la investigación desarrollada presenta el tema de un sistema de riego implementado con inteligencia artificial, el cual su base es la integración de sensores de humedad ambiental, sensores de humedad de suelo y de manera conjunta se implementó un modelo de aprendizaje predictivo, capaz de procesar información tomada en campo y poder actuar en función a predicciones realizadas por el sistema. Este sistema busca mejorar la eficiencia en la aplicación del riego mediante un control más preciso y adaptativo, contribuyendo de esta forma a la reducción del desperdicio de agua y al uso sostenible de los recursos hídricos en entornos agrícolas.

La necesidad constante de mejorar la eficiencia en el uso del agua ha promovido la implementación de nuevas tecnologías de riego más precisas dentro de la agricultura moderna en el País. En este contexto el riego por goteo se ha posicionado como una alternativa sólida y más eficientes,

debido a su gran capacidad de suministrar agua de manera localizada y además de bastante controlada directamente en la zona radial del cultivo (Keller & Bliesner, 2020).

El sistema de riego por goteo opera de forma óptima con caudales que oscilan entre 1 y 4 litros por hora por emisor, esto nos permite una adecuada dosificación del agua, y sobre todo una reducción significativa de pérdidas por evaporación y escorrentía. En contraste con otros métodos tradicionales como el riego por inundación, en el cual se aplica con volúmenes considerablemente mayores sin un control adecuado del proceso, lo que genera una disminución considerable de la eficiencia del sistema.

Los sistemas de riego que son automatizados implementan sensores de humedad del suelo que permiten monitorear el contenido volumétrico de agua (*Volumetric Water Content, VWC*), esta variable es clave para la gestión eficiente del riego. Estos sensores se operan dentro de su forma típica dentro de rangos de medición que van desde valores cercanos a 0% y suben hasta niveles cerca a la saturación del suelo, esto dependerá de sus características físicas y además tipos de suelo que se encuentren analizando para el sistema. Siguiendo esta línea, el monitoreo de forma continua de la humedad del suelo nos permite optimizar la programación del riego y así reducir el uso ineficiente del recurso hídrico, más aún cuando se incorporan con estrategias de manejo basadas en datos (Jovanovic et al., 2020; FAO, 2020)

Adicionalmente, la automatización del riego por goteo contribuye a la reducción del consumo de energía asociado al bombeo, al optimizar los tiempos de operación en función de las necesidades reales del cultivo. Diversos estudios indican que la implementación de sistemas de riego, los cuales se sustentan en sensores y control automatizado, permitiendo así evitar el desperdicio de los recursos hídricos, promoviendo el ahorro de la energía variable, la cual va en función de las condiciones del sistema y

además del manejo del riego (FAO, 2021; IEA,2022). En consecuencia, la incorporación de sistemas de riego automatizados por goteo constituye una adecuada estrategia para mejorar la eficiencia hídrica y energética en la agricultura.

Desde el punto de vista ambiental, la optimización del riego es fundamental para mitigar la sobreexplotación de los acuíferos. La extracción intensiva de acuíferos para actividades agrícolas está provocando, según estudios recientes, descensos sostenidos del nivel freático en distintas regiones del mundo que comprometen la sostenibilidad de los sistemas productivos (United States Geological Survey, 2023; World Resources Institute, 2022). En este marco, la adopción de estrategias de riego eficientes, orientadas al monitoreo y al control, posibilita una reducción importante de la demanda del recurso hídrico, favoreciendo de esta forma la preservación de los acuíferos y reforzando la resiliencia de los sistemas agrícolas ante situaciones de variabilidad climática y prolongadas sequías que acontecen en el medio ambiente.

Considerando un punto de vista productivo, la adopción de tecnologías de riego inteligente ha demostrado mejoras significativas en el rendimiento de los cultivos asociadas con una gestión más precisa del agua disponible que pueden variar entre el 10 % y el 25 %, como consecuencia de la disminución del estrés hídrico y la optimización de las condiciones del entorno radicular. (International Water Management Institute, 2021; Food and Agriculture Organization, 2022). De igual forma, el control automatizado del riego permite una mayor estabilidad en el desarrollo fenológico de los cultivos, lo cual favorece una producción más uniforme y eficiente. En su conjunto, estos beneficios demuestran el potencial de la gestión inteligente del agua de riego como una solución tecnológica clave para mejorar simultáneamente la sostenibilidad ambiental y la productividad agrícola.

Cuadro 1. **Uso global del agua por sector**

Sector	Uso (%)
Agricultura	70
Industrial	20
Doméstico	10

Fuente. Elaboración propia con base en FAO (2021), World Bank (2022) y OECD (2022).

II.1.3. Automatización de sistemas de riego y eficiencia

La automatización de los sistemas de riego se ha establecido como una solución tecnológica orientada a mejorar la eficiencia del uso del recurso hídrico, disminuir las pérdidas relacionadas con la aplicación del agua y optimizar la productividad agrícola. Diversos estudios demuestran que la incorporación de sistemas de control permite mejorar significativamente la eficiencia de aplicación del agua, pasando de rangos típicos de entre 35 % y 60 % en los sistemas tradicionales, a valores superiores al 80 % en los sistemas tecnificados bajo condiciones controladas (FAO, 2021; IWMI, 2021). Este incremento está asociado a una mejor regulación del suministro hídrico y a la reducción de pérdidas por evaporación, escorrentía y percolación profunda.

Cuadro 2. ***Enfoques de riego***

Enfoque	Características	Eficiencia
Riego tradicional	Manual, sin sensores	35-60%
Riego tecnificado	Programación básica	60-80%
Riego automatizado	Sensores + Control	>80%

Fuente. Elaboración propia con base en FAO (2021), IWMI (2021)

En este marco, los sistemas de riego automatizado se apoyan en la captación de datos de los sensores de humedad del suelo y de las variables ambientales, que permiten caracterizar en tiempo real el estado hídrico del cultivo. La información obtenida se procesa mediante sistemas de control

que determinan las condiciones adecuadas para la activación del riego, optimizando la disponibilidad de agua en la zona radicular y evitando situaciones de déficit o exceso de agua.

La automatización del riego mediante sistemas de control permite una dosificación más precisa del recurso hídrico a través de la activación de actuadores tales como electroválvulas, lo cual contribuye a una mayor eficiencia del sistema en comparación con los métodos convencionales. Este tipo de control favorece la estabilidad del contenido de humedad en el suelo, disminuyendo la variabilidad de las condiciones hídricas del cultivo y mejorando su desempeño productivo.

Estos sistemas, en conjunto, integran sensores, unidades de procesamiento y elementos de actuación, conformando arquitecturas de control que posibilitan una gestión más eficiente del riego agrícola. La evidencia analizada demuestra que esta estrategia proporciona una base tecnológica importante para optimizar el uso del agua en la agricultura contemporánea, en particular, en situaciones en las que el suministro de agua es escaso y se necesita una administración más meticulosa del recurso.

II.2. Antecedentes del estudio

II.2.1. Antecedentes Internacionales

En el ámbito internacional, diversos estudios recientes han abordado el desarrollo de sistemas de riego inteligente mediante la integración de sensores, automatización y técnicas de inteligencia artificial.

- Togneri et al. (2022) crearon un modelo mediante aprendizaje automático para predecir la humedad del suelo en sistemas de riego inteligente, usando datos de sensores IoT y variables ambientales. El estudio demostró que los enfoques totalmente basados en datos permiten precisar con gran exactitud las necesidades de agua,

resaltando el potencial del aprendizaje automático para optimizar la gestión de riego y reducir el uso innecesario de agua. Estos hallazgos abogan a favor de la utilización de modelos predictivos como herramienta esencial para mejorar la eficiencia del riego agrícola. En este contexto, la presente investigación adopta este enfoque y lo orienta hacia su implementación en condiciones reales de cultivo, priorizando la eficiencia y aplicabilidad en campo.

- M. ElSaadani et al. (2021) propusieron un modelo basado en machine learning para la predicción de la humedad del suelo utilizando datos meteorológicos, como alternativa al uso exclusivo de sensores físicos y una gran cantidad de datos históricos. El sistema permitió estimar las condiciones hídricas de los cultivos incluso en ausencia de mediciones directas, mejorando la continuidad y confiabilidad del sistema de riego inteligente. Este enfoque evidencia que los modelos predictivos pueden complementar o reforzar los sistemas basados en sensores. En ese sentido, la presente investigación integra variables ambientales y datos de sensores para lograr una solución más robusta y adaptable.

- S. Kim et al. (2024) implementaron en machine learning un modelo para la predicción de la humedad del suelo para ambientes dedicados a la agricultura de precisión, se usan datos históricos que son recopilados de los sensores y variables ambientales. Este estudio involucra el procesamiento y selección de datos influyentes, así como la ardua evaluación de modelos predictivos a través de métricas de error. Los resultados obtenidos revelan que el modelo hace factible estimar con un alto nivel de precisión al contenido hídrico del suelo. Este planteamiento propone la viabilidad de utilizar modelos de machine learning como principal base para la toma de decisiones para la optimización del uso de agua en sistemas de riego.

- B. A. T. Koné et al. (2023) se desarrolló un modelo el cual se basa en Deep learning con el objetivo de predecir la humedad del suelo considerando arquitecturas hibridas como CNN-LSTM, estas integran data climática e históricos de humedad. Este estudio se enfocó en la estimación de futuros valores de humedad de suelo, con el principal objetivo de mejorar el planeamiento del riego. Se obtuvieron resultados que demostraban que el modelo propuesto permitió predecir de forma precisa la humedad del suelo a corto plazo, permitiendo evidenciar la capacidad de enfoques basados en un aprendizaje automático apoyando a la toma de decisiones para el sistema de riego.

- Q. Han et al. (2023), en este proyecto se evaluó el desempeño de diversos algoritmos de machine learning, al igual que el Random Forest, Extreme Gradient y K-Nearest Neighbors, para poder obtener la predicción de la humedad del suelo. Los resultados obtenidos presentaron que los modelos basados en un aprendizaje automático superan los métodos tradicionales en precisión. Asimismo, demostró que los modelos de tipo ensemble presentaron un mejor desempeño de predicción para mejorar la eficiencia agrícola.

- Jiménez et al. (2023) en Colombia, desarrollaron un estudio con el fin de implementar un sistema inteligente capaz de determinar los requerimientos hídricos usando sensores y técnicas de modelado agrícola. La metodología se basó en la implementación de nodos de adquisición y transmisión inalámbrica de datos que permiten monitorear las variables: temperatura ambiente, potencial matricial del suelo y humedad relativa. La información se procesó en un sistema de inferencia que genera recomendaciones de riego. Este sistema estableció prescripciones diarias de agua según el tipo de suelo y estado fenólico del cultivo, reducción de situaciones de

exceso o déficit de agua. El estudio reconoce que la integración de redes de sensores y sistemas inteligentes representa una eficiente alternativa que optimiza la gestión del agua en la agricultura.

- Cabay y Pachana (2023) en Ecuador, desarrollaron un estudio a través del que se buscó optimizar la infraestructura de monitoreo agrícola a través de la incorporación del aprendizaje automático para la eficiente gestión de riego. La metodología estuvo basada en implementar una red de sensores de humedad del suelo que se conecte con microcontroladores inalámbricos y complementada con información meteorológica que se obtiene de las plataformas digitales. La toma de decisiones fue usando el modelo Random Forest que determinó la activación o desactivación automática de la válvula inteligente. Estos resultados evidenciaron que mejoró la precisión del monitoreo en la gestión automatizada del riego, para que se mantenga niveles correctos de humedad de suelo. Se arribó a la conclusión que, integrar sensores, plataformas IoT y algoritmos de Machne Learning optimiza significativamente el consumo de agua.

- Ortiz y Mendoza (2024) en México, realizaron un estudio con el objetivo de diseñar un sistema automatizado que permita optimizar la aplicación de agua en cultivos a través de tecnologías embebidas. En el estudio se empleó sensores para monitorear las variables relacionadas al estado hídrico del suelo y un sistema de control que se basó en hardware programable para la activación automática de los mecanismos de riego. Los resultados muestran que automatizar permite mejor el control de condiciones de riego y reducir la dependencia de intervención manual. Se concluye que implementar plataformas embebidas es una alternativa viable para el desarrollo de soluciones de bajo costo que se orienten al uso de agricultura inteligente.

En conjunto, los antecedentes internacionales evidencian una tendencia

hacia la integración de sensores físicos y procesamiento inteligente en sistemas de riego automatizado, con resultados favorables en eficiencia hídrica y precisión de decisión.

II.2.2. Antecedentes Nacionales

En el contexto nacional, diversas investigaciones han abordado la automatización del riego mediante sensores de humedad y control electrónico, especialmente en regiones agrícolas del Perú.

- En el ámbito nacional, Espinoza (2020) en Tacna, se desarrolló la tesis titulada “Diseño y construcción de un sistema de riego automatizado modular para el ahorro de agua, monitoreando la humedad y temperatura a tiempo real” (2020), en la U. N. Jorge Basadre Grohmann, el principal objetivo fue la de diseñar y desarrollar un sistema de riego que esté automatizado y orientado a optimizar el uso del recurso del agua. Para la cual se usaron criterios de diseño, los cuales se basan en principios de mecánica de fluidos para la adecuada selección de componentes como el referido a diámetro de tuberías, el caudal requerido y la potencia necesaria para la bomba a usarse, añadiendo además sensores de humedad para el suelo y de temperatura que permiten monitorear en tiempo real el estado óptimo del cultivo. La información recopilada se procesa por medio de un sistema electrónico digital, el cual activa un relé para el control de la bomba de agua en función de valores de humedad previamente establecidos, implementando un esquema de control automático basado en umbrales. Los resultados demostraron que mejoró la eficiencia del riego y se redujo la intervención manual; sin embargo, el sistema tiene limitaciones porque utiliza una lógica de control determinística, lo que restringe su capacidad de adaptación a condiciones variables del entorno, por lo que esta investigación propone la incorporación de modelos predictivos de machine learning para optimizar la toma de decisiones en el uso del recurso hídrico.

- Dueñas Vara y Ruesta Revoredo (2022) implementó un sistema de riego inteligente basado en tecnologías IoT para cultivos agrícolas en el sur del Perú, aplicado al cultivo de Pitahaya en Chancay, integrando sensores de humedad del suelo y temperatura ambiental para el monitoreo y control del riego. El sistema permitió optimizar la distribución del agua y mejorar las condiciones de cultivo mediante decisiones automatizadas. Este enfoque evidencia la aplicabilidad de tecnologías IoT en la agricultura peruana.

- Cañazaca Limachi (2024) implementó un sistema de riego por goteo automatizado sustentado en sensores de humedad de suelo, esto implementado en la región de Puno, finca de Patascachi. El sistema presentado utilizado un microcontrolador para procesar información de los sensores y así poder activar el riego de manera automática a través de una bomba que es controlada por relés, dependiendo las condiciones hídricas de las cuales se obtienen por los sensores de suelo. Los resultados que se consiguieron mostraron que este sistema permitió estabilizar los niveles óptimos de humedad, manteniendo valores cercanos al requerido por los cultivos y optimizando la eficiencia del riego en contraparte con método tradicionales. Esta perspectiva evidencia la crucial importancia de la automatización en sistemas de riego, no obstante, su base es la lógica de control por umbrales, esto provoca una limitante de capacidad en su adaptación, este es el motivo por el cual la presente investigación propone la implementación del machine learning.

- Mendoza y Pérez (2024) en Jaén, desarrollaron una investigación bajo el título de “Propuesta de un sistema de riego automatizado por microaspersión para las áreas verdes de la Universidad Nacional de Jaén”, basada con el objetivo de diseñar un sistema automatizado para optimizar el uso de recursos hídricos a través de la incorporación de sensores de humedad y mecanismos de control

automático. Metodológicamente corresponde al diseño de una red de riego por microaspersión integrada con sensores que monitoreen las condiciones del suelo y suministren de agua según lo que se haya detectado como requerimiento. Los resultados han evidenciado que existe reducción de desperdicio de agua y mejora de eficiencia operativa en el sistema referido al manejo manual tradicional. Se concluye que, la automatización se basa en sensores y optimiza la gestión hídrica, reduciendo la intervención humana en las actividades de riego.

- Ordoñez y Cieza (2024) en Jaén, proponen un estudio denominado: “Diseño de un sistema de control automatizado mediante tecnología Arduino para el riego del vivero de la Municipalidad Provincial de Jaén - Perú” que propuso como objetivo diseñar un sistema automatizado que optimice el proceso de riego a través del monitoreo continuo de variables relacionadas con condiciones de cultivo. El estudio fue de método aplicado y correspondió al uso de sensores, plataforma Arduino y elementos que control que permitieron optimizar la activación del sistema de riego. A través de los resultados se mostró un que el sistema implementado mantuvo condiciones establecer para cultivar y redujo la necesidad de supervisión manual.

- Santa Rosa (2024) en la Universidad Nacional de Huamanga propuso un estudio bajo el título de: “Desarrollo de un modelo productivo de conductividad hidráulica para optimizar el sistema de riego de Laguna Huanzo en Huanca Sancos, Ayacucho” el estudio propuso como objetivo mejorar la gestión del recurso hídrico a través de la aplicación de modelos predictivos y algoritmos de aprendizaje automático. La metodología se basó en el empleo de información acerca de las propiedades físicas del suelo y modelos basados en aprendizaje automático, incluyendo el algoritmo K-Nearest Neighbors (K-NN) para calcular los parámetros hidráulicos que se relacionan con la distribución del agua en el sistema de riego. Los

resultados evidencian mejoras en la capacidad de predicción y en la toma de decisiones para la gestión del agua. Se concluye que la aplicación de técnicas de inteligencia artificial representa una herramienta eficaz para optimizar el sistema de riego en contextos agrícolas con alta variabilidad ambiental.

En general, los antecedentes nacionales demuestran la pertinencia y viabilidad de implementar sistemas de riego automatizado en el contexto peruano. No obstante, la mayoría de los estudios se enfocan en control basado únicamente en sensores físicos y lógica condicional, sin integrar visión artificial ni modelos de Machine Learning para enriquecer el proceso de decisión.

II.3. Bases teóricas

La presente investigación se fundamenta en principios teóricos relacionados con la agricultura de precisión, la automatización de sistemas de riego, el sensado ambiental, la visión artificial y el uso de técnicas de machine learning para la toma de decisiones en entornos agrícolas. La integración de estas disciplinas permite el desarrollo de sistemas inteligentes capaces de optimizar el uso de recursos hídricos mediante el monitoreo y análisis de variables del entorno.

II.3.1. Sensores de Humedad del Suelo

II.3.1.1. Fundamentos de medición de humedad.

La medición de humedad del suelo se basa en la determinación indirecta del contenido de agua a partir de la evaluación de propiedades físicas que cambian en función de la cantidad de agua presente en la matriz del suelo. La conductividad eléctrica y la capacitancia dieléctrica son de los principios más utilizados y están relacionados con las propiedades electromagnéticas del medio.

Estos principios permiten estimar el contenido volumétrico de agua en el suelo sin necesidad de métodos destructivos, y son ampliamente utilizados

en sistemas de medición en agricultura debido a la confiabilidad y facilidad de implementación en sistemas automatizados. (Jones, 2021; Alexander & Sadiku, 2016).

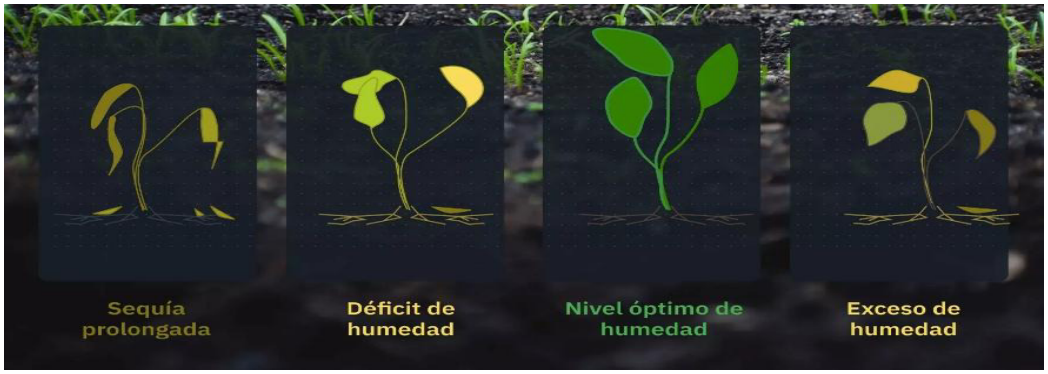

Figura 2. **Estados de la humedad del suelo en el desarrollo plantas**. *Fuente. Datos tomados* de “Humedad del suelo”, por EOS Data Analytics (2023)

Desde una perspectiva física, la medición de humedad del suelo implica la interacción de campos eléctricos con un medio heterogéneo compuesto por partículas sólidas, agua y aire. La distribución volumétrica de estas fases determina las propiedades eléctricas globales del sistema. Los sensores convierten estas variaciones en señales analógicas o digitales que pueden ser procesadas por sistemas electrónicos de adquisición de datos.

II.3.1.2. Fundamentos eléctricos.

La conductividad eléctrica del suelo depende de la concentración de iones disueltos en el agua contenida en los poros. Cuando el contenido de humedad aumenta, la conductividad eléctrica también tiende a incrementarse debido a la mayor movilidad iónica. Este principio es utilizado en sensores resistivos, donde la resistencia eléctrica medida entre dos electrodos disminuye a medida que aumenta la humedad.

La relación básica se fundamenta en la ley de Ohm:
Donde R es la resistencia, ρ la resistividad del material, L la distancia entre electrodos y A el área de sección transversal efectiva. A mayor contenido de agua, menor resistividad y por tanto menor resistencia medida.

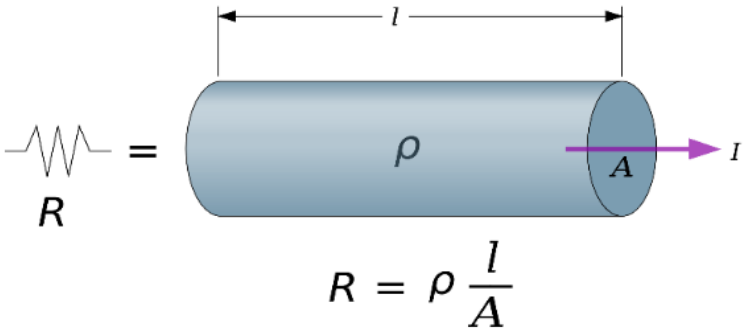

Figura 3. **Fórmula elemental de la conductividad.** Fuente. Datos tomados de "Elementos de un circuito eléctrico", por Fundación Endesa.

Sin embargo, la conductividad también está influida por la salinidad del suelo, lo que puede producir errores cuando varía la concentración de sales.

La medición capacitiva, en cambio, se basa en la variación de la permitividad dieléctrica del suelo. La constante dieléctrica del agua es de aproximadamente 80, mientras que para el aire es de alrededor de 1, y para el suelo seco, entre 3 y 5. Debido a esta diferencia significativa, pequeños cambios en el contenido volumétrico de agua generan variaciones detectables en la capacitancia del medio.

La capacitancia puede expresarse como:
$C = \varepsilon \cdot (A / d)$; donde C es la capacitancia, ε la permitividad dieléctrica del medio, A el área efectiva del electrodo y d la distancia entre placas. Al aumentar el contenido de agua, aumenta la permitividad y, por tanto, la capacitancia medida.

Este principio permite estimar el contenido volumétrico de humedad en rangos típicos entre 0 % y 60 %, que corresponden a los niveles habituales en suelos agrícolas.

II.3.1.3. Tipos de sensores de humedad del suelo.

Los sensores resistivos consisten generalmente en dos electrodos metálicos insertados en el suelo. Miden la resistencia eléctrica entre ambos puntos, la cual disminuye al aumentar la humedad. Suelen operar con tensiones de 3.3 V o 5 V y proporcionan una salida analógica proporcional a la humedad relativa.
Entre sus ventajas se encuentran el bajo costo y la simplicidad de implementación. Sin embargo, presentan desventajas importantes como la corrosión de los electrodos, degradación con el tiempo y alta sensibilidad a la salinidad del suelo. Su vida útil puede verse reducida en ambientes húmedos permanentes.

Por otro lado, los sensores capacitivos utilizan un circuito oscilador cuya frecuencia varía en función de la capacitancia del suelo circundante. No requieren contacto eléctrico directo entre electrodos expuestos, lo que reduce la corrosión. Generalmente operan en rangos de 3.3 V a 5 V y entregan señales analógicas estables.

Estos sensores permiten estimar el contenido volumétrico de agua con mayor estabilidad a largo plazo y menor interferencia por salinidad en comparación con los resistivos. Además, presentan mejor repetibilidad y menor mantenimiento.

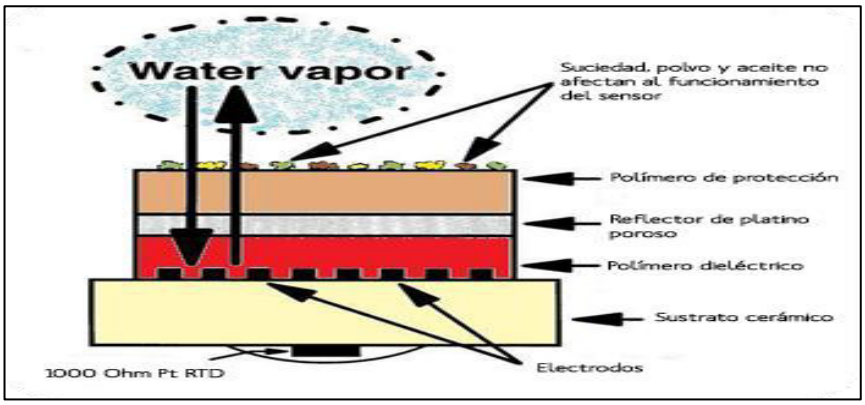

Figura 4. **Estructura interna de sensor capacitivo de suelo.** Fuente. Tomado de Sensorstecnics

II.1.3.4. Selección del sensor para sistemas de riego.

La selección del sensor en sistemas de riego automatizado debe considerar criterios técnicos, económicos y operativos. En el contexto en donde requiera instalar diversos nodos de medición que se encuentren distribuidos en el campo, el costo por cada uno de los puntos se vuelve un factor a tener en cuenta. En esta situación el sensor capacitivo muestra una alternativa bastante adecuada debido a su costo accesible en comparación con otras tecnologías, presenta una robustes ante ambientes húmedos y menor susceptibilidad a la corrosión. Además, su señal analógica puede integrarse fácilmente con microcontroladores o sistemas embebidos, facilitando la automatización del riego.



Figura 5. **Sensor de suelo capacitivo.** Fuente. Tomado de “Tutorial del sensor de humedad del suelo para Arduino, ESP8266 y ESP32”, por El Osciloscopio (s.f.)

Desde el punto de vista técnico, los sensores capacitivos permiten trabajar en el rango típico de humedad agrícola (0 % – 60 % volumétrico), presentan tiempos de respuesta cortos y consumo energético reducido, características importantes en sistemas alimentados de manera remota. En consecuencia, para un sistema de riego automatizado orientado a optimizar la eficiencia hídrica mediante monitoreo continuo y activación automática de electroválvulas, el sensor capacitivo constituye una solución técnicamente adecuada, económicamente viable y compatible con arquitecturas de control electrónico.

II.3.2. Sistemas Embebidos en Automatización

Un sistema embebido es un sistema informático diseñado para realizar funciones específicas dentro de un sistema más amplio, generalmente con restricciones de tiempo real, consumo de energía y recursos de hardware.

A diferencia de una computadora de propósito general, un sistema embebido está diseñado para ejecutar funciones específicas, tales como la adquisición de datos, el procesamiento de señales o el control automático. (Benítez, 2024).

En el ámbito de la automatización, los sistemas embebidos actúan como unidades de procesamiento local capaces de recibir señales provenientes de sensores, ejecutar algoritmos de decisión y generar señales de control hacia actuadores. Estos sistemas integran hardware y software en una arquitectura compacta, permitiendo operar de manera autónoma sin necesidad de infraestructura informática compleja.

Desde el punto de vista estructural, un sistema embebido está compuesto por:

- Unidad de procesamiento (CPU o GPU).
- Memoria (RAM y almacenamiento).
- Interfaces de entrada y salida (GPIO, I2C, SPI, UART).
- Sistema operativo o firmware.
- Módulos de comunicación opcionales.

II.3.2.1. Características de los sistemas embebidos.

- Los sistemas embebidos presentan características específicas que los diferencian de otras plataformas computacionales.

- Están diseñados para ejecutar tareas concretas de manera eficiente, como control de procesos o procesamiento de señales.

- Operación en tiempo real, muchos sistemas embebidos deben responder a eventos dentro de intervalos de tiempo definidos, especialmente en aplicaciones de control automático.

- Integración hardware–software, el diseño del sistema considera de manera conjunta los recursos físicos y los algoritmos de

procesamiento, garantizando eficiencia y estabilidad

II.3.2.2. Jetson Nano Plataforma.

La Jetson Nano es una plataforma de cómputo embebido desarrollada para aplicaciones de inteligencia artificial y procesamiento de alto rendimiento en dispositivos compactos. Está equipada con un procesador ARM de cuatro núcleos y una GPU basada en arquitectura CUDA con 128 núcleos, lo que le permite ejecutar algoritmos de visión artificial y aprendizaje automático directamente en el dispositivo.

Entre sus características técnicas principales se encuentran:

- CPU ARM Cortex-A57 de cuatro núcleos.
- GPU de 128 núcleos CUDA.
- Memoria RAM de 8 GB.
- Consumo energético configurable entre aproximadamente 5 W y 10 W.
- Compatibilidad con sistemas operativos basados en Linux.
- Soporte para bibliotecas de inteligencia artificial y visión por computadora.
- Puertos USB 4x USB 3.0 Type-A y 1x USB 2.0 Micro-B (utilizado para alimentación de 5V/2A o modo dispositivo).
- Puerto Ethernet Gigabit (RJ-45) de 10/100/1000 Mbps.
- Bus de Expansión (40 Pines GPIO) Incluye buses I2C, SPI, UART, PWM e I2S para conexión directa con sensores, servomotores y microcontroladores.

Estas especificaciones permiten realizar inferencia de modelos de aprendizaje automático y análisis de datos en tiempo real, sin necesidad de enviar continuamente la información a un servidor externo. De esta manera facilitando y adaptándose a las condiciones del medio y a la circunstancia que se están tomando a consideración para la elaboración de este estudio. Además de velar por un consumo energético adecuado y tecnología actual.



Figura 6. **Sistema embebido Jetson Orin Nano Developer Kit.** Fuente. Tomado de “NVIDIA Jetson Orin Nano Developer Kit de 8GB”, por Electromanía Perú (s.f.).

II.3.3. Fundamentos de Machine Learning

El Machine Learning o aprendizaje automático constituye una rama de la inteligencia artificial orientada al desarrollo de algoritmos capaces de aprender patrones a partir de datos y realizar predicciones sin necesidad de ser programados explícitamente mediante reglas fijas. A diferencia de los sistemas tradicionales, en los cuales el comportamiento del sistema está determinado por condiciones previamente definidas por el programador, los modelos de Machine Learning utilizan datos históricos para identificar relaciones entre variables y generalizar dichos patrones a nuevas situaciones.

El aprendizaje automático resulta particularmente útil en sistemas donde intervienen múltiples variables dinámicas y donde la modelación matemática exacta del proceso presenta alta complejidad. En el ámbito agrícola, variables como la humedad del suelo, la temperatura ambiental y otras condiciones climáticas influyen continuamente en el desarrollo del cultivo, generando relaciones no lineales difíciles de representar mediante modelos determinísticos convencionales.

En este contexto, los algoritmos de *machine learning* permiten analizar datos obtenidos a partir de sensores para identificar patrones y estimar el comportamiento futuro de variables relevantes, facilitando así la toma de decisiones automatizada en sistemas de riego (Benos et al., 2021;

ElSaadani et al., 2021).

Aprendizaje supervisado

Dentro de las diferentes técnicas de Machine Learning, el aprendizaje supervisado constituye uno de los enfoques más utilizados en problemas de predicción. Este tipo de aprendizaje se basa en el uso de un conjunto de datos previamente etiquetados, donde cada entrada está asociada a un valor de salida conocido. A partir de este conjunto de entrenamiento, el modelo aprende la relación existente entre las variables de entrada y la variable objetivo.

En el contexto de sistemas de riego, las variables de entrada pueden incluir mediciones como la humedad del suelo, la temperatura ambiental, el tiempo transcurrido o condiciones climáticas, mientras que la variable de salida puede corresponder al nivel de humedad futura del suelo o a la necesidad de activar el riego.

El aprendizaje supervisado se clasifica principalmente en problemas de clasificación y regresión, en función de la naturaleza de la variable objetivo. Para estos modelos de clasificación, las categorías discretas son las que le corresponde a la salida, como por ejemplo la determinación de si una planta o cultivo requiere ser regada o no requiere ser regada.

En contraste, los modelos de regresión son empleados más frecuentemente cuando la variable que se requiere predecir es continua, como por ejemplo el nivel de humedad del suelo para un determinado instante. En el contexto de los sistemas de riego inteligente, los enfoques basados en regresión resultan particularmente relevantes, ya que permiten estimar de forma cuantitativa el estado hídrico del suelo y apoyar la toma de decisiones en la gestión del riego (Aurélien Géron, 2022).

Modelos de predicción en Machine Learning

Existen diversos modelos de Machine Learning aplicables a problemas de predicción en sistemas agrícolas. Entre los más utilizados se encuentran la regresión lineal, los árboles de decisión y los métodos basados en ensambles como Random Forest. La regresión lineal es uno de los modelos más simples y consiste en establecer una relación matemática entre una variable dependiente y una o más variables independientes.

Su principal ventaja radica en su facilidad de implementación e interpretación, lo cual resulta adecuado para sistemas donde se requiere bajo costo computacional.

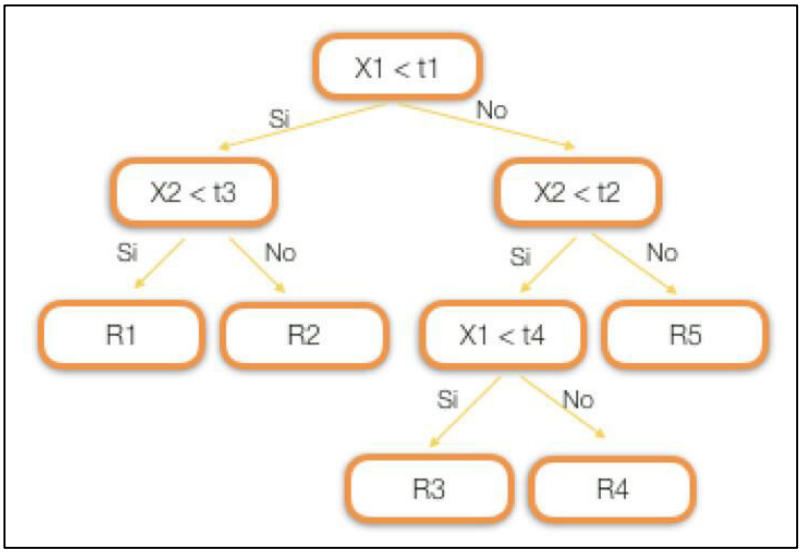

Figura 7. **Árbol de decisión regresión.** Fuente. Tomado de "Árboles de Decisión Regresión – Teoría", por AprendeIA (2019)

Por otro lado, los árboles de decisión permiten modelar relaciones no lineales entre variables, generando estructuras jerárquicas que facilitan la toma de decisiones. Estos modelos son especialmente útiles en contextos donde las condiciones del entorno presentan alta variabilidad. Los modelos de tipo Random Forest, basados en la combinación de múltiples árboles de decisión, permiten mejorar la precisión de las predicciones y reducir el sobreajuste, siendo adecuados para sistemas con múltiples variables de entrada y datos con ruido.

La selección del modelo depende de factores como la cantidad de datos disponibles, la capacidad de procesamiento del sistema embebido y el nivel de precisión requerido en la predicción.

Machine Learning para la optimización del riego

La integración del Machine Learning en sistemas de riego automatizado permite desarrollar estrategias de control más eficientes en comparación con los métodos convencionales. Mediante el uso de datos históricos y mediciones en tiempo real, es posible predecir el comportamiento hídrico del suelo y anticipar las necesidades del cultivo.

En la presente investigación, el modelo de Machine Learning se emplea como herramienta de apoyo para la toma de decisiones en el sistema de control de riego. Una vez obtenidas las mediciones por el sensor de humedad del suelo, el sistema modelado es capaz de estimar o predecir el estado futuro del sistema, determinando así el mejor momento para la activación del riego o su desactivación. Este punto de vista permite pasar de un control netamente con parámetros fijos, a un sistema en el cual las decisiones son fundamentadas por la estimación de estados futuros respaldados por el procesamiento de datos. Como resultado, se logra una mejor regulación del contenido de humedad en el suelo, una reducción del consumo de agua y una mayor eficiencia en el sistema de riego.

En consecuencia, el uso de Machine Learning en sistemas de riego automatizado representa una herramienta tecnológica clave para optimizar la gestión del recurso hídrico, contribuyendo al desarrollo de soluciones sostenibles en el ámbito agrícola.

II.3.4. Sistemas de Control Automático

Un sistema de control es un conjunto de elementos interconectados cuyo propósito es regular el comportamiento de un proceso o sistema dinámico para que su salida alcance y mantenga un valor deseado. El objetivo principal es garantizar estabilidad, precisión y eficiencia en la operación del

sistema.

Desde el punto de vista formal, un sistema de control puede representarse mediante:

Entrada → Proceso → Salida; donde el proceso transforma la señal de entrada en una respuesta observable. En sistemas automatizados, esta regulación se realiza sin intervención humana directa, utilizando sensores, controladores y actuadores.

En aplicaciones agrícolas, el proceso puede ser el riego del cultivo, cuya finalidad es mantener condiciones adecuadas de humedad para el desarrollo óptimo de la planta.

II.3.4.1. Sistema de lazo abierto.

En un sistema de lazo abierto, la acción de control no depende de la salida del sistema. Es decir, no existe retroalimentación. La operación se basa únicamente en una programación preestablecida.

Características principales:

- Diseño sencillo.
- Bajo costo.
- No corrige errores ante perturbaciones externas.
- Menor precisión.

II.3.4.2. Sistema de lazo cerrado.

En un sistema de lazo cerrado, la salida es medida y comparada con un valor de referencia. La diferencia entre ambos genera una señal de error que ajusta la acción de control. Este tipo de sistema permite corregir desviaciones causadas por variaciones ambientales, mejorando la estabilidad y eficiencia del proceso. En el contexto agrícola, un sistema de lazo cerrado activa el riego únicamente cuando la humedad del suelo desciende por debajo de un umbral establecido.

II.3.4.3. Variables de entrada y salida.

Todo sistema de control se basa en variables claramente definidas:

Variables de entrada

Son las señales que influyen en el sistema. En el sistema propuesto incluyen:

- Nivel de humedad del suelo.
- Nivel de temperatura y humedad del ambiente.
- Parámetros de configuración (umbrales).

Variables de salida

Son las respuestas generadas por el sistema. En este caso:

- Activación o desactivación del sistema de riego.
- Tiempo de funcionamiento de la electroválvula.
- Registro de estado del cultivo.

La relación entre entrada y salida puede representarse mediante una función de transferencia o una lógica de decisión programada en el sistema embebido.

II.3.4.4. Sistema de decisión.

El sistema de decisión constituye el núcleo del controlador. Es el componente encargado de procesar las variables de entrada y determinar la acción a ejecutar.

Existen diferentes enfoques para la toma de decisiones:

- Control basado en umbrales.
- Control proporcional, integral o derivativo (PID).
- Control basado en reglas.
- Control basado en modelos predictivos o aprendizaje automático.

En sistemas agrícolas automatizados de pequeña escala, es común utilizar lógica condicional combinada con umbrales predefinidos. Sin embargo,

cuando se integra análisis de imágenes mediante Machine Learning, el sistema puede realizar decisiones más complejas basadas en patrones detectados.

El sistema de decisión debe cumplir criterios de:

- Estabilidad.
- Rapidez de respuesta.
- Confiabilidad.
- Eficiencia energética.

El sistema desarrollado en la presente investigación corresponde a un sistema de control automático de lazo cerrado basado en sensores. La retroalimentación se obtiene mediante:

- Sensor de humedad del suelo (variable física cuantificable).
- Análisis visual del estado del cultivo (variable cualitativa transformada en datos numéricos).

El controlador, implementado en el sistema embebido, procesa ambas entradas y determina la activación del sistema de riego a través de un actuador (relé y electroválvula). De esta manera, el sistema regula automáticamente el suministro de agua en función del estado real del cultivo. Este enfoque permite una gestión hídrica más eficiente, adaptable a condiciones cambiantes del entorno, y alineada con los principios de automatización y agricultura de precisión.

II.3.5. Sistemas de riego por goteo

En los sistemas de riego automatizado por goteo, la electroválvula constituye el elemento fundamental de actuación encargado de regular el flujo de agua hacia el cultivo. Este dispositivo electromecánico permite controlar de manera precisa la apertura y cierre del paso de agua en función de señales eléctricas provenientes de un sistema de control.

Entre las principales funciones de la electroválvula en sistemas de riego automatizado se encuentran:

- Controlar el suministro de agua de manera precisa en función de las necesidades del cultivo.
- Automatizar los ciclos de riego mediante señales generadas por el sistema de control.
- Reducir el desperdicio hídrico al evitar la sobre irrigación.
- Integrarse con sistemas electrónicos y embebidos para operación autónoma.

Las electroválvulas utilizadas en aplicaciones agrícolas suelen operar en rangos de tensión de 12 V o 24 V, y están diseñadas para soportar condiciones ambientales adversas, como humedad, variaciones de temperatura y exposición prolongada al exterior. Asimismo, presentan características de operación tipo “todo o nada”, funcionando como actuadores discretos dentro del sistema de control.

Desde el punto de vista del control automático, la electroválvula actúa como el elemento final dentro de un sistema de lazo cerrado. En este tipo de sistemas, las variables del proceso son medidas mediante sensores, procesadas por un controlador y utilizadas para generar acciones que regulan el comportamiento del sistema.

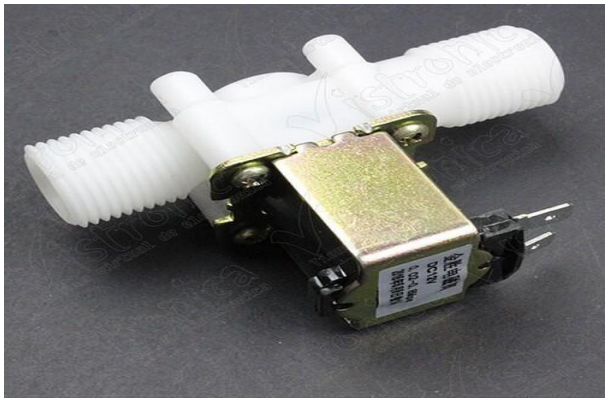

Figura 8. **Electroválvula de 12V.** Fuente. Tomado de “Cómo conectar electroválvula 12v dc”, por Arduino Forum (2018)

En la presente investigación, el sistema de actuación está compuesto por un módulo de relé que funciona como interfaz de potencia entre el sistema embebido y la electroválvula. Debido a que el controlador opera con

señales de baja potencia, el relé permite conmutar cargas de mayor tensión y corriente, garantizando aislamiento eléctrico y protección del sistema de control.

El funcionamiento del sistema se describe de la siguiente manera: el controlador procesa la información proveniente del sensor de humedad del suelo y, en función de los criterios definidos (ya sea mediante umbrales o modelos de predicción), determina la necesidad de activar el riego. Cuando se cumplen las condiciones establecidas, el sistema envía una señal de control al módulo de relé, el cual energiza la electroválvula, permitiendo el flujo de agua hacia el sistema de riego por goteo.

Una vez que el nivel de humedad del suelo alcanza el valor adecuado para el cultivo, el sistema desactiva la señal de control, provocando el cierre de la electroválvula y deteniendo el suministro de agua. Este mecanismo permite mantener la variable controlada dentro de un rango óptimo, contribuyendo a la eficiencia del sistema.

Este enfoque permite optimizar el uso del recurso hídrico, ya que el riego se realiza únicamente cuando las condiciones del suelo lo requieren, reduciendo pérdidas y mejorando la eficiencia operativa del sistema.



Figura 9. **Riego por goteo**. Fuente. Tomado de “Tipos de sistemas de riego:

ventajas y desventajas de cada uno", por Gestiona Agroambiental (2022)

II.4. Definición de términos

Agricultura de precisión. Método tecnológico que combina sensores, sistemas de monitoreo y análisis de información para mejorar la gestión de recursos agrícolas, facilitando el uso más eficiente del agua y aumentando la producción de cultivos mediante decisiones fundamentadas en datos actualizados (Banco Mundial, 2022; FAO, 2021).

Aprendizaje supervisado. Metodología de Machine Learning que emplea conjuntos de datos etiquetados para comprender la relación entre las variables de entrada y salida, lo que permite hacer predicciones mediante modelos de clasificación o regresión (Aurélien Géron, 2022).

Eficiencia hídrica. Habilidad de utilizar el agua de manera ideal, reduciendo pérdidas durante el riego y atendiendo las necesidades de los cultivos con el menor consumo de agua posible (FAO, 2021; IWMI, 2021).

Electroválvula. Dispositivo electromecánico que controla la apertura y el cierre del flujo de agua en un sistema de riego automatizado mediante señales del controlador, permitiendo la automatización de los ciclos de riego y mejorando la eficacia del sistema (Benítez, 2024).

Machine Learning (Aprendizaje automático). Componente de la inteligencia artificial que crea algoritmos capaces de reconocer patrones a partir de datos anteriores para hacer predicciones y facilitar la toma de decisiones sin requerir reglas específicamente programadas (Benos et al., 2021; ElSaadani et al. , 2021).

Sensor de humedad del suelo. Aparato electrónico que mide el contenido de agua en el suelo usando principios de conductividad eléctrica o capacitancia, ofreciendo datos que ayudan en la toma de decisiones para los sistemas de riego automatizado (Jones, 2021).

Sistema de control automático. Componentes que monitorizan y regulan el comportamiento de un proceso a través de sensores, controladores y actuadores, con el objetivo de mantener la salida del sistema dentro de valores predeterminados de forma automática (Benítez, 2024).

Sistema de riego automatizado. Sistema tecnológico combina sensores, controladores y actuadores para distribuir agua de forma automática según las condiciones del suelo y las necesidades del cultivo, lo que disminuye la necesidad de intervención humana y maximiza el uso del agua (FAO, 2021; IWMI, 2021).

Sistema de riego por goteo. Técnica de irrigación que entrega agua de manera precisa y controlada directamente a las raíces del cultivo usando emisores de bajo caudal, aumentando así la eficiencia en el uso del agua y limitando pérdidas por evaporación y escorrentía (Keller y Bliesner, 2020).

Sistema embebido. Unidad computacional creada para llevar a cabo funciones específicas dentro de un sistema más amplio, combinando hardware y software para realizar tareas de adquisición de datos, procesamiento y control automático dentro de límites de tiempo real (Benítez, 2024).

CAPITULO III:
HIPÓTESIS Y VARIABLES

III.1. Hipótesis

III.1.1. Hipótesis general

El diseño e implementación de un sistema de riego inteligente basado en inteligente artificial adaptativa permite reducir significativamente el consumo de agua y se mejora la eficiencia hídrica en comparación con el riego tradicional en la provincia de Churín, Distrito de Andajes.

III.1.2. Hipótesis específicas

H1. El diseño de una arquitectura tecnológica que integre sensores de humedad del suelo, temperatura ambiental, un sistema embebido y actuadores hidráulicos permite una adquisición y procesamiento eficiente de datos para la toma de decisiones en el sistema de riego.

H2. La implementación de un modelo de inteligencia artificial permite predecir y ajustar dinámicamente los tiempos en función de la temperatura ambiental y humedad de suelo, mejorando la eficiencia operativa de sistema frente a esquemas tradicionales de riego.

H3. El sistema de riego inteligente basado en inteligencia artificial adaptativa permite mantener condiciones adecuadas de humedad del suelo utilizando menor tiempo de riego en comparación con un sistema de riego convencional.

III.2. Variables

III.2.1. Variables independientes

- Sistema de riego convencional
- Sistema de riego inteligente basado en inteligencia artificial adaptativa

III.2.2. Variables dependientes

- Tiempo total de riego por día (minutos)
- Frecuencia de riego (número de activaciones por día)
- Humedad promedio del suelo (%)
- Variación de la humedad del suelo (%)

III.2.3. Variables de control

- Área del terreno de prueba
- Tipo de cultivo
- Sistema de riego implementado
- Distribución de goteros
- Fuente de agua y presión del sistema

III.3. Operacionalización de las variables

Cuadro 3. **Operacionalización de las variables**

Variable	Dimensiones	Indicadores	Escala de medición
Variable independiente: Tipo de sistema de riego	Tipo de control	Sistema convencional Sistema Inteligente basado en Machine Learning	Nominal
	Eficiencia en consumo de agua	Volumen total del agua consumida por día (L/día)	Razón
Variable dependiente: Eficiencia del sistema de riego	Eficiencia de control de riego	Número de activaciones del sistema por día	Razón
	Estabilidad de humedad	Humedad promedio (%)	Razón
	Eficiencia hídrica	Ahorro de agua (%) respecto del sistema tradicional	Razón

Nota. El cuadro muestra las variables, dimensiones indicadores y escala de medición considerados para la investigación.

CAPITULO IV:
MATERIALES Y MÉTODOS

El presente capítulo describe la metodología empleada para el desarrollo, implementación y evaluación de un prototipo de sistema de riego inteligente basado en inteligencia artificial. Se presenta el área de estudio, el diseño, la población y muestra, al igual que el procedimiento, técnicas a usar e instrumentos para la recopilación y análisis de datos. En este capítulo se busca establecer un marco metodológico que permita la validación de los resultados obtenidos y sentar las bases para trabajos relacionados a contribuir con la eficiencia hídrica.

El presente estudio fue implementado en un entorno agrícola controlado ubicado en el distrito de Andajes, localidad de Churín, en el cual se desarrolló un sistema de riego por goteo instrumentado con sensores y un sistema embebido que se encargue del procesamiento y validación de datos. Este entorno permitió evaluar el comportamiento del sistema bajo condiciones reales de campo. La investigación corresponde a un enfoque cuantitativo de tipo aplicado y con diseño experimental, orientado a la comparación del desempeño entre un sistema de riego convencional y un sistema de riego inteligente basado en inteligencia artificial adaptativa, evaluando su impacto en la eficiencia del uso del recurso hídrico.

Los materiales empleados en el desarrollo del sistema incluyen sensores de humedad del suelo y temperatura ambiental, un sistema embebido encargado del procesamiento de información y ejecución del algoritmo de control, electroválvulas para la activación del sistema de riego, y una infraestructura de riego por goteo implementada en el área experimental.

Estos elementos fueron integrados para permitir la adquisición de datos, el procesamiento en tiempo real y la automatización del riego.
El procedimiento de investigación se desarrolló en etapas progresivas. En una primera etapa se desarrolló la instalación del sistema de riego por goteo convencional en el área control, para poder obtener los datos sin ninguna intervención del prototipado desarrollado. Posterior a ello, se implementa el prototipado con inteligencia artificial previamente codificado. Luego de ello se realiza la recopilación de datos del sistema el cual se encarga de ajustar de forma dinámica los tiempos de activación en función de las variables y su predicción. Finalmente, se ejecutaron pruebas comparativas entre el sistema convencional y el sistema inteligente.

Las técnicas utilizadas incluyeron la observación directa del comportamiento del sistema durante su operación, el registro automatizado de datos mediante el sistema embebido y el análisis comparativo experimental de los resultados obtenidos entre ambas modalidades de riego. Asimismo, se utilizó registro fotográfico como evidencia del proceso de implementación y funcionamiento del prototipo. Los instrumentos de recolección de datos estuvieron constituidos por los sensores de humedad del suelo y temperatura ambiental, el sistema embebido encargado del procesamiento y almacenamiento de datos, las electroválvulas como actuadores del sistema de riego, y los registros digitales generados por el sistema durante su funcionamiento.

En conjunto, la metodología implementada permitió la adquisición de datos confiables y la evaluación del desempeño del sistema propuesto, garantizando la validez del análisis comparativo entre el sistema de riego convencional y el sistema de riego inteligente basado en inteligencia artificial adaptativa.

IV.1. Área de estudio

El presente estudio se desarrolló en el distrito de Andajes, localidad de

Churín, ubicado en el departamento de Lima, Perú. Una de las principales características de esta zona es la variabilidad climática que presenta con variaciones significativas de temperatura durante el día y la noche, esta condición influye directamente en la demanda del recurso hídrico en los cultivos. De igual forma, la posibilidad del recurso hídrico en el centro poblado de Churín es limitada, esto demuestra una clara necesidad de la implementación de un sistema de riego mucho más eficiente, dinámico y automatizado.

El área en cuestión corresponde a un terrene de aproximadamente 40m2. Destinado a la implementación del sistema convencional y al sistema con inteligencia artificial de riego por goteo. Este espacio fue seleccionado por su accesibilidad, disponibilidad y por representar condiciones reales de cultivo a pequeña escala, permitiendo la validación del sistema en un entorno controlado pero representativo. El sistema de riego fue implementado directamente sobre el terreno, considerando la instalación de sensores de humedad del suelo y temperatura ambiental para la adquisición de datos en tiempo real. Asimismo, se diseñó una distribución uniforme de los puntos de riego mediante un sistema de goteo, garantizando la homogeneidad en la aplicación del recurso hídrico durante las pruebas experimentales.

Las coordenadas geográficas del área de estudio son 10°48'45.88"S, 76°52'35.72"W, con una altitud aproximada de 2200 msnm, lo que permite ubicar con precisión el entorno experimental dentro del contexto geográfico del distrito de Andajes y sus condiciones agroclimáticas características.

Este entorno experimental permite la evaluación del comportamiento del sistema de riego inteligente bajo condiciones reales de campo, facilitando el análisis del consumo de agua y la eficiencia del sistema propuesto en comparación con métodos tradicionales de riego.

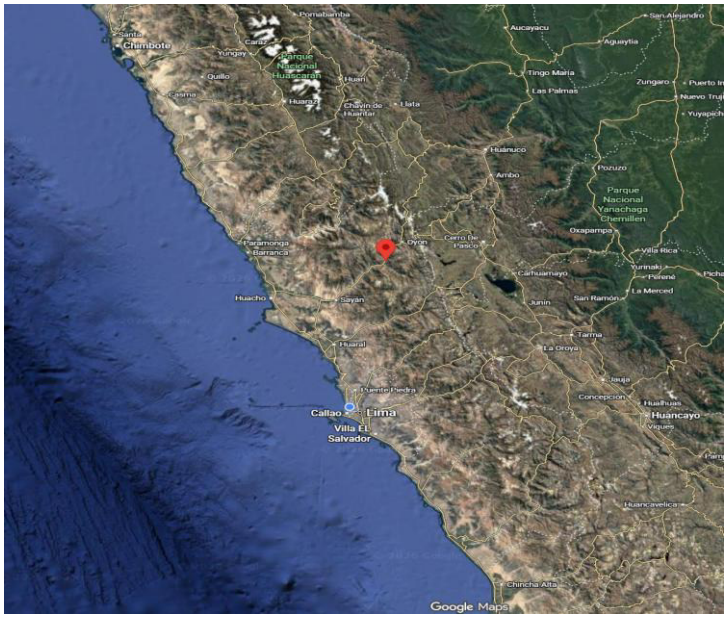

Figura 10. **Vista Satelital de Lima.** Fuente. Tomado de Google Earth (2026).

IV.2. Diseño de investigación

El presente estudio corresponde a una investigación de tipo aplicada, debido a que se orienta a la solución de un problema real relacionado con la eficiencia en el uso del recurso hídrico en sistemas de riego agrícola, mediante el diseño e implementación de un prototipo tecnológico basado en inteligencia artificial adaptativa.

El enfoque de la investigación es cuantitativo, ya que se fundamenta en la recolección, medición y análisis de variables numéricas tales como el tiempo de riego, la frecuencia de activación del sistema, la humedad del suelo y la variación de la humedad, permitiendo una evaluación objetiva del desempeño del sistema propuesto y su comparación con un sistema convencional.

El diseño de la investigación es de tipo cuasi experimental, debido a que se establecen dos condiciones de estudio bajo un mismo entorno de pruebas: un sistema de riego convencional basado en programación fija y un sistema de riego inteligente basado en inteligencia artificial adaptativa. La variable independiente es manipulada de forma controlada, evaluando su efecto sobre las variables dependientes, sin asignación aleatoria de unidades

experimentales.

El esquema de investigación se estructura de la siguiente manera:

- Grupo control: Sistema de riego por goteo convencional.
- Grupo experimental: Sistema de riego por goteo inteligente basado en inteligencia artificial.

Ambos sistemas operan bajo condiciones homogéneas de terreno, tipo de cultivo, sistema de riego por goteo y condiciones ambientales, con el objetivo de asegurar la validez de la comparación experimental.

La investigación es de corte longitudinal, debido a que las mediciones de las variables se realizan durante un periodo determinado de tiempo, lo que permite analizar el comportamiento del sistema en función de las condiciones cambiantes del entorno y el desempeño del control de riego en el tiempo. Este diseño permite evaluar de manera objetiva la eficiencia del sistema propuesto en comparación con el método tradicional, determinando su impacto en la optimización del recurso hídrico y el mantenimiento adecuado de la humedad del suelo.

Con la finalidad de complementar el diseño experimental y describir de manera estructurada la arquitectura del sistema de riego inteligente, se incorpora un mapa topológico del sistema, el cual permite visualizar la interconexión entre los componentes físicos, electrónicos y de procesamiento involucrados en la solución propuesta. El sistema desarrollado se puede dividir principalmente en 3 niveles: nivel de recolección de datos, nivel de procesamiento de información con inteligencia artificial y nivel de actuación.

En el nivel de adquisición de datos, se implementó a través de seis sensores de humedad de suelo y dos sensores de temperatura. Ambos tipos de sensores permitirán capturar información en tiempo real acerca del estado hídrico del suelo y además las condiciones ambientales, de esta

forma garantizando una representación adecuada respecto al comportamiento del cultivo en la zona de estudio.

Los sensores se encuentran conectados a una tarjeta de desarrollo Arduino, la cual cumple la función de unidad de adquisición de datos. Este microcontrolador se encarga de la lectura, acondicionamiento y digitalización de las señales provenientes de los sensores, consolidando la información en un formato adecuado para su transmisión.

En el nivel de procesamiento, la información recolectada es enviada desde el Arduino hacia el sistema embebido Nvidia Jetson Nano mediante un canal de comunicación serial (USB). La Jetson Nano constituye el núcleo del sistema inteligente, donde se implementa el modelo de inteligencia artificial adaptativa. Este modelo procesa las variables de entrada, analiza patrones históricos y condiciones actuales, y determina de manera autónoma los tiempos y frecuencias óptimos de riego.

Cabe destacar que la Jetson Nano opera con una arquitectura simplificada de conexión, requiriendo únicamente dos enlaces: una fuente de alimentación de 220V (mediante adaptador) y un canal de comunicación con el Arduino, lo que facilita la implementación y reduce la complejidad del sistema.

En el nivel de actuación, el Arduino recibe las instrucciones generadas por la Jetson Nano y ejecuta las acciones correspondientes mediante módulos de relé. Estos módulos permiten controlar la activación de electroválvulas de 12V, las cuales regulan el flujo de agua en el sistema de riego por goteo. De esta manera, el sistema actúa directamente sobre el entorno físico, cerrando el ciclo de control.

Adicionalmente, el sistema cuenta con una fuente de alimentación de 12V que energiza tanto las electroválvulas como el Arduino (a través de un adaptador de voltaje), garantizando un funcionamiento estable y continuo

de los dispositivos de campo.

El mapa topológico permite evidenciar la integración de tecnologías de censado, procesamiento embebido e inteligencia artificial en una arquitectura jerárquica y modular, facilitando el análisis, escalabilidad y replicabilidad del sistema propuesto.

Para poder visualizar una adecuada representación estructural del sistema y sus procesos, se desarrolla un flujograma de funcionamiento, en el cual se describe su secuencia lógica desde la recopilación de datos hasta la adecuada toma de decisiones y ejecución de riego.

Todo el proceso inicia con la captura de datos mediante los sensores en campo, estos se registran continuamente con las condiciones del entorno. Estos datos son enviados al Arduino, donde se realiza una primera etapa de lectura y organización de la información.

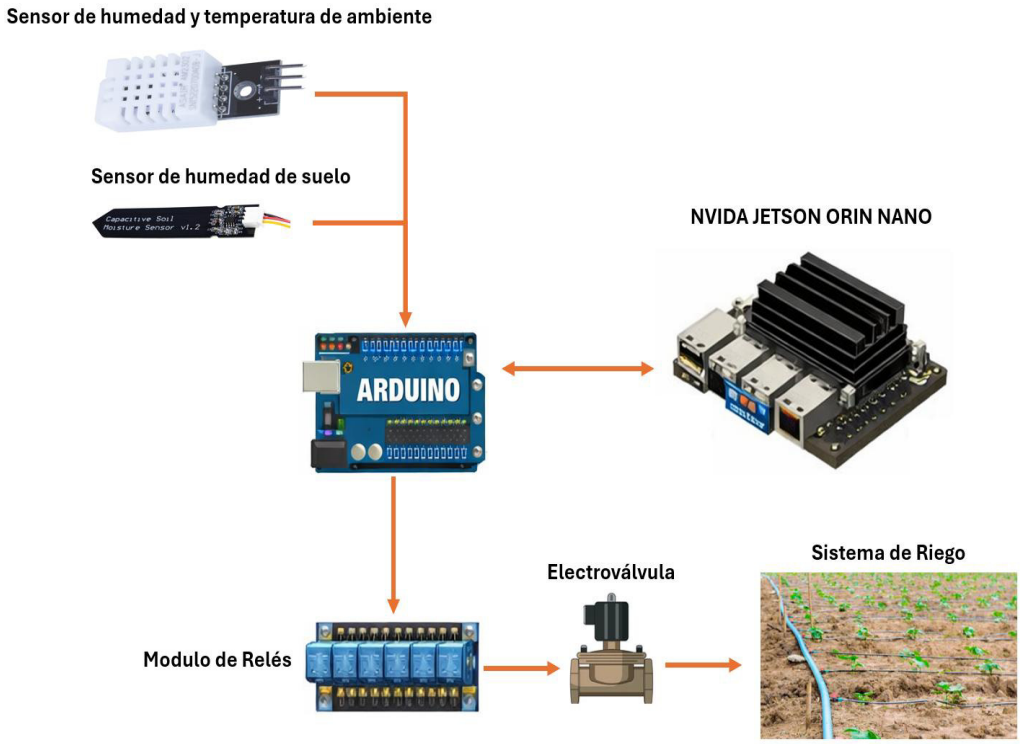

Figura 11. **Mapa topológico del sistema.** Fuente. Elaboración propia

Posteriormente, el Arduino transmite los datos hacia la Jetson Nano, donde se ejecuta el modelo de inteligencia artificial adaptativa. En esta etapa, el sistema realiza el análisis de las variables en tiempo real, considerando además el comportamiento histórico de los datos para identificar patrones y tendencias.

En función de este análisis, el modelo determina si las condiciones del suelo requieren riego, así como la duración y frecuencia óptima del mismo. Esta decisión constituye el núcleo del sistema inteligente, ya que reemplaza la lógica fija de los sistemas tradicionales por un enfoque dinámico y adaptativo.

Una vez generada la decisión, la Jetson Nano envía una señal de control al Arduino, el cual procede a activar o desactivar los módulos de relé según corresponda. Estos módulos controlan directamente las electroválvulas, permitiendo el paso del agua hacia el sistema de riego por goteo.

El sistema continúa operando de manera cíclica, repitiendo el proceso de adquisición, análisis y actuación, lo que permite una retroalimentación constante y una adaptación continua a las condiciones del entorno.

El flujograma evidencia un sistema de control cerrado, donde la inteligencia artificial desempeña un papel central en la optimización del uso del recurso hídrico, garantizando niveles adecuados de humedad en el suelo y evitando el desperdicio de agua.

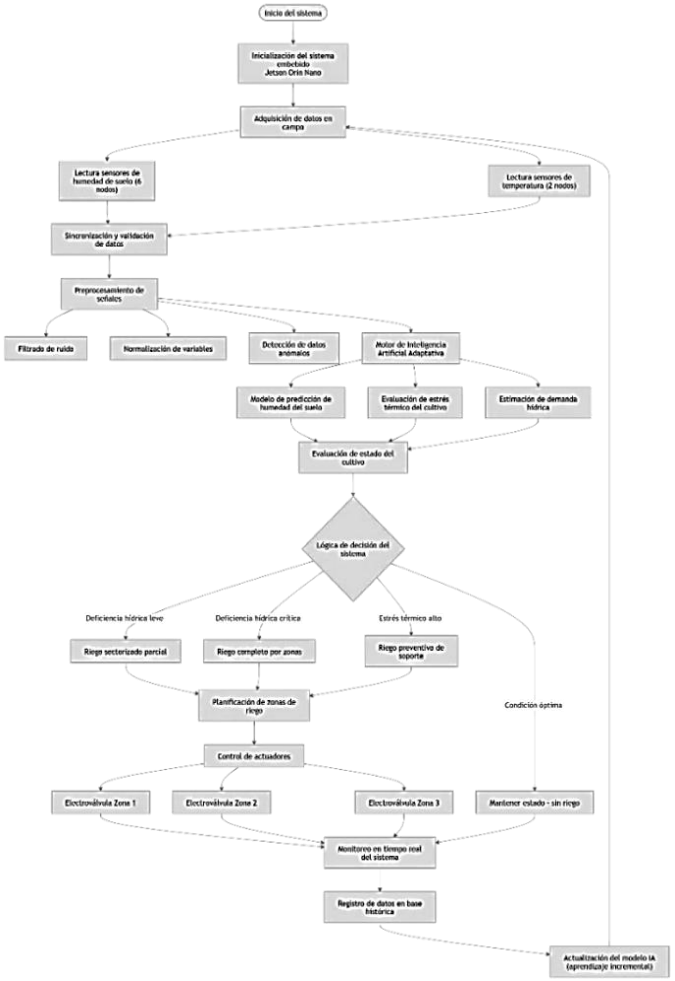

Figura 12. **Flujograma del proceso.** Fuente. Elaboración propia

IV.3. Población y muestra

La población de estudio está constituida por el área agrícola destinada al cultivo dentro del distrito de Andajes, provincia de Churín, la cual presenta condiciones representativas de sistemas de producción agrícola a pequeña escala en la sierra central del Perú.

Se tomará en cuenta que en el área seleccionada para la evaluación experimental se viene sembrando alfalfa (*Medicago sativa)*, cultivo conocido en la zona por su correcta adaptación a condiciones climáticas en la sierra de Lima, además de la importancia que tiene en el entorno económico de los sistemas agropecuarios locales y los requerimientos hídricos constantes, en este tipo de cultivo se puede evaluar el desempeño adecuado del sistema de riego basado en uso de inteligencia artificial.

Debido a la naturaleza experimental de la investigación, la unidad de análisis no corresponde a individuos humanos, sino al sistema de riego implementado y al comportamiento del cultivo bajo condiciones controladas.



Figura 13. **Vista Satelital de Churín, Lima.** Fuente. Tomado de Google Earth (2026).

La muestra está conformada por un área experimental de aproximadamente 40m2, en la cual se implementa el prototipo de sistema de riego inteligente basado en inteligencia artificial adaptativa, así como su comparación con un sistema de riego convencional bajo las mismas condiciones de terreno, tipo de cultivo y sistema de riego por goteo.



Figura 14. **Área de estudio.** Fuente. Elaboración propia.

En este sentido, la muestra es de tipo no probabilística por conveniencia,

ya que el área de estudio ha sido seleccionada intencionalmente por su accesibilidad y representatividad de condiciones reales de cultivo en la zona.

IV.4. Procedimientos, técnicas e instrumentos de recolección de información.

El presente apartado describe de manera detallada el procedimiento seguido para el diseño, implementación y evaluación del sistema de riego inteligente basado en inteligencia artificial adaptativa, así como las técnicas e instrumentos utilizados para la recolección de datos durante el desarrollo experimental. Este proceso permite asegurar la trazabilidad del experimento y la validez de la comparación entre el sistema de riego convencional y el sistema propuesto.

IV.4.1. Procedimientos

El desarrollo de la presente investigación se ejecutó mediante un procedimiento metodológico estructurado y secuencial orientado al diseño, implementación y evaluación de un sistema de riego inteligente basado en inteligencia artificial adaptativa, el cual fue contrastado con un sistema de riego convencional bajo condiciones equivalentes de operación en campo. El objetivo principal de este procedimiento fue garantizar la correcta implementación del prototipo, la estabilidad del sistema experimental y la obtención de datos confiables para el análisis comparativo del desempeño de ambas estrategias de riego.

En una primera etapa se realizó la planificación del sistema experimental, definiéndose el área de estudio correspondiente a un terreno de $40m^2$, el cual fue acondicionado para la instalación del sistema de riego por goteo. Para lo cual de antemano se tuvo que habilitar la zona antes mencionada de la parcela con el objetivo de eliminar las impurezas, estandarizar el área y facilitar el acceso y el estudio al mismo.



Figura 15. **Área de estudio antes de estandarizar.** Fuente. Elaboración propia.



Figura 16. **Área de estudio con impurezas reducidas.** Fuente. Elaboración propia

Como siguiente tratamiento a la parcela, es procedió a realizar la elaboración y delimitación de surcos, orientados para su adecuada distribución y correcto ordenamiento de las plantas durante su siembra. Este trabajo de acondicionar el área, no solo nos facilita la distribución homogénea sino además, permite la adecuada instalación y alineación del sistema por goteo en ejecución.



Figura 17. **Área de estudio con surcos preparados.** Fuente. Elaboración propia

En la siguiente etapa, requerimos la instalación del tendido de tendido de tuberías los sistemas de riego por goteo, convencional con programación fija, y al sistema de riego por goteo con inteligencia artificial adaptativa.



Figura 18. **Instalación de sistema de riego.** Fuente. Elaboración propia

Dentro de la siguiente etapa nos encontramos en la de instalar al sistema estándar, los sensores que serán los encargados de recibir la data del ambiente y transferirla hacia el circuito; los actuadores, que son responsables de la acción final determinada por el programa y el tablero de eléctrico, el cual es el encargado de alimentar y transferir la información para todo el sistema en cuestión para esta investigación.



Figura 19. **Electroválvula seleccionada** Fuente. Elaboración propia

El sistema de riego tomado en cuenta hace uso de goteros autocompensantes de 2 L/h de caudal nominal, que son distribuidos de manera uniforme en la zona de estudio, a fin de que se garantice una homogénea aplicación del agua y se facilite realizar la comparación del sistema inteligente propuesto y el sistema convencional usado.

En esta etapa se establecieron las primeras condiciones generales del experimento, considerando la distribución espacial de los puntos de riego, la ubicación exacta de los sensores de suelo y de los sensores de temperatura, al igual que la disposición del sistema de control. De igual forma, se definieron las variables críticas del estudio, asegurando la capacidad del sistema para registrar datos relevantes en relación con el comportamiento hídrico del suelo y las condiciones ambientales del entorno.

Posteriormente, se llevó a cabo la implementación de la infraestructura hidráulica del sistema de riego por goteo, la cual incluyó la instalación de líneas principales de conducción de agua, derivaciones secundarias y emisores de goteo distribuidos uniformemente en el área experimental. Este sistema fue desarrollado con el principal objetivo de garantizar una distribución adecuada y homogénea del agua en la totalidad del área de cultivo, minimizando el rango de variaciones del riego y asegurando las

condiciones para un adecuado estudio. Asimismo, se verificó el correcto funcionamiento del sistema hidráulico mediante pruebas de flujo y presión antes de su integración con el sistema de control.



Figura 20. **Instalación de infraestructura y tablero** Fuente. Elaboración propia

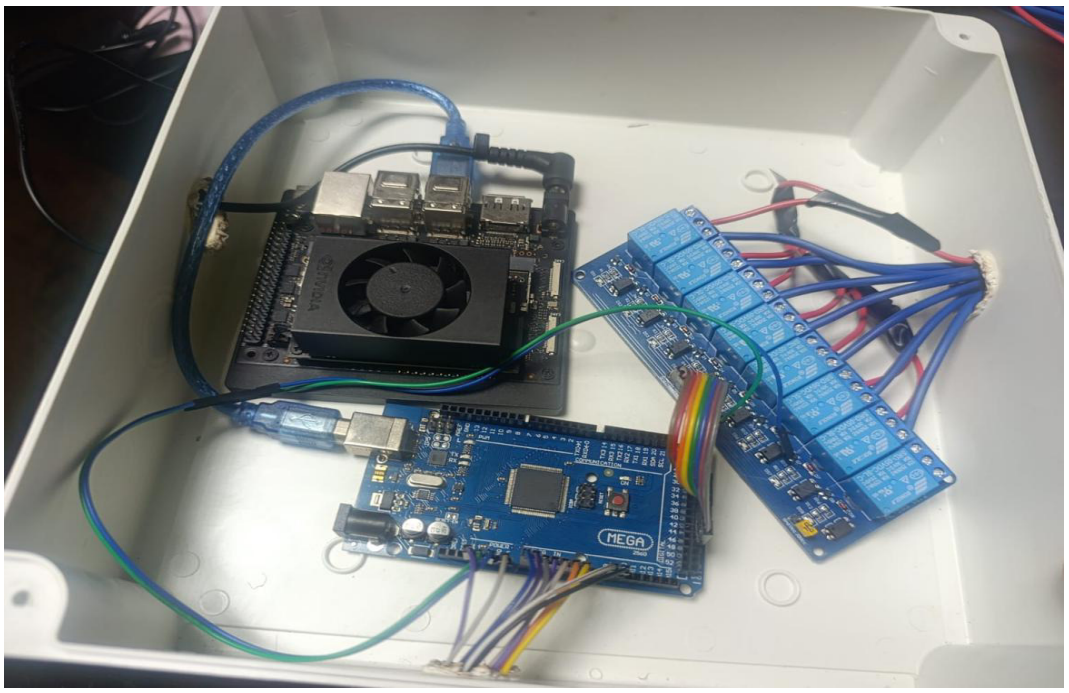

Figura 21. **Cableado e instalaciones en el tablero** Fuente. Elaboración propia

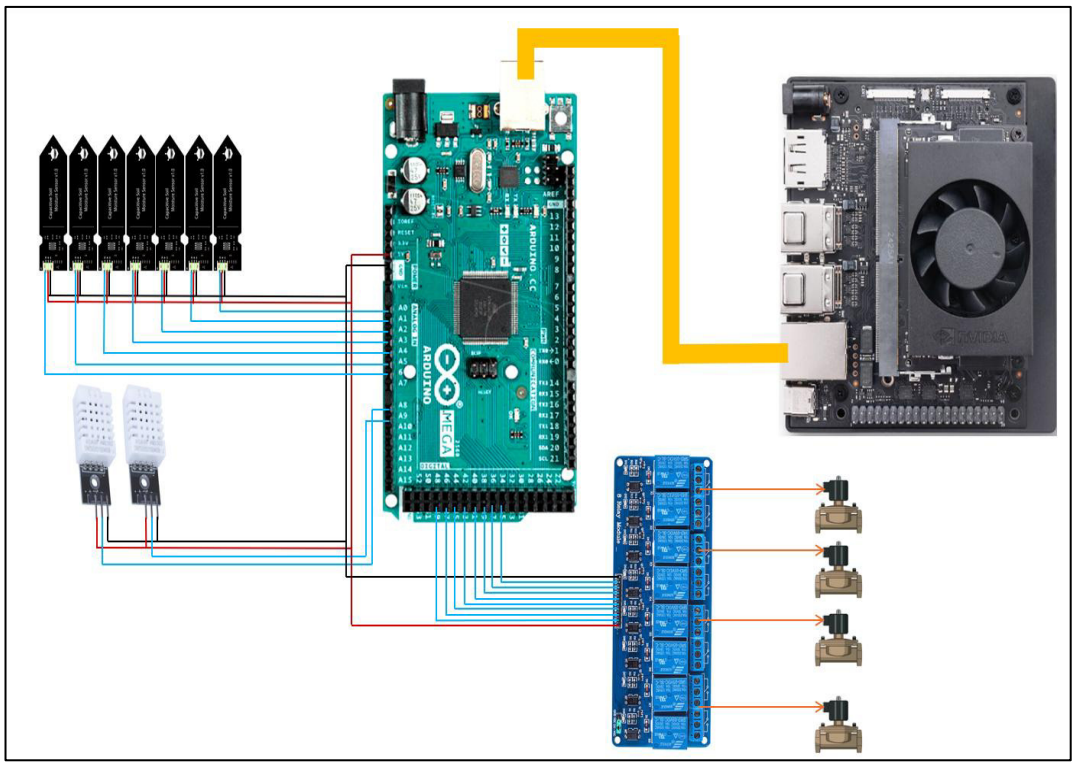

Figura 22. **Plano de Hardwaredel sistema.** Fuente. Elaboración propia

En una etapa posterior se implementó el sistema de censado y adquisición de datos, integrando sensores de humedad del suelo y sensores de temperatura ambiental estratégicamente ubicados para representar de manera adecuada las condiciones del área de cultivo. Estos sensores fueron conectados a un sistema embebido encargado de la adquisición, filtrado, procesamiento y almacenamiento de datos en tiempo real.



Figura 23. **Instalación de sensores** Fuente. Elaboración propia

El sistema generó registros sistemas digitales continuos, para así poder darle un seguimiento a la trazabilidad de las variables que se van midiendo a través de todo el periodo experimental. Igualmente se realizó la calibración inicial para los sensores en campo con el propósito de mejorar la precisión en las mediciones para así poder reducir errores sistemáticos.

El sistema de riego por goteo con inteligencia artificial fue implementando, usando el logaritmo de Random Forest, el cual fue implementado en el sistema embebido Nvidia Jetson Orin Nano.

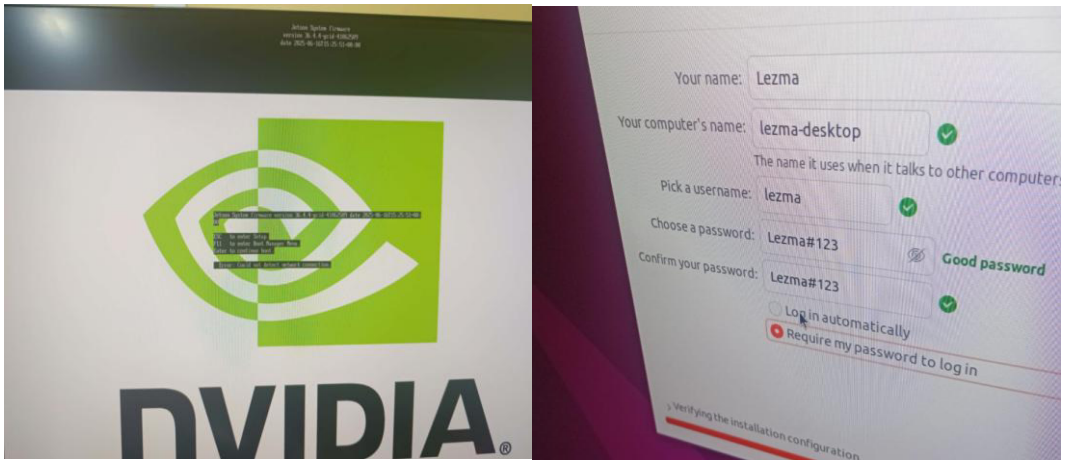

Figura 24. **Pantalla de Inicio y Login de Nvidia** Fuente. Elaboración propia

Para el desarrollo del código se detalla en la clase Interferencia, el cual es la encarada de gestionar el ciclo de interferencia y la toma de decisiones para el sistema de riego automático, en el cual primero inicializa el registro de eventos del sistema, para poder supervisar en tiempo real la ejecución, posteriormente determina la predicción promedio y calcula su desviación estándar entre árbol y árbol, para poder medir su varianza o incertidumbre en la predicción del recurso hídrico.

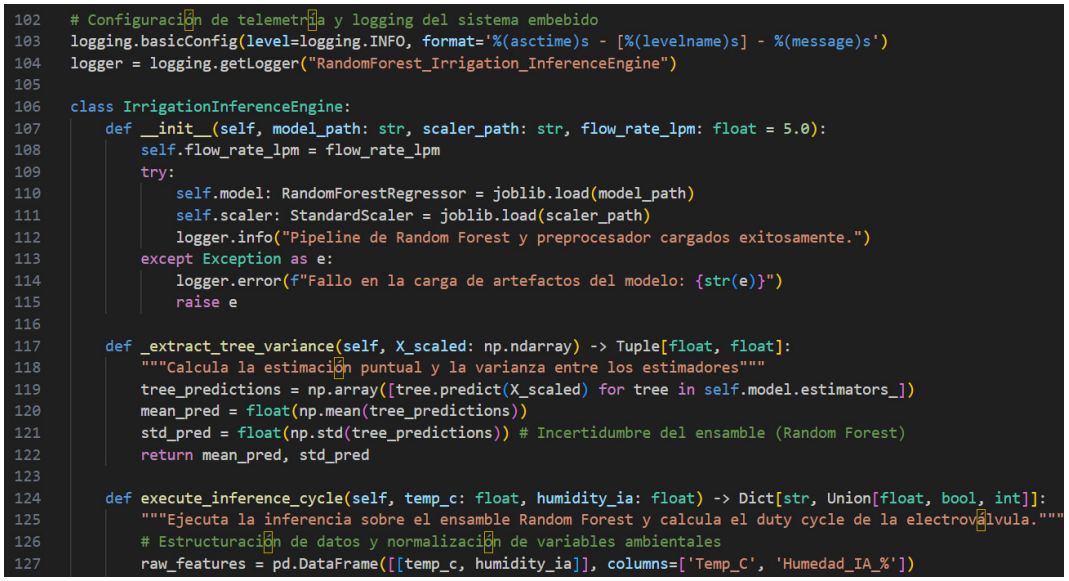

```python
# Configuración de telemetría y logging del sistema embebido
logging.basicConfig(level=logging.INFO, format='%(asctime)s - [%(levelname)s] - %(message)s')
logger = logging.getLogger("RandomForest_Irrigation_InferenceEngine")

class IrrigationInferenceEngine:
    def __init__(self, model_path: str, scaler_path: str, flow_rate_lpm: float = 5.0):
        self.flow_rate_lpm = flow_rate_lpm
        try:
            self.model: RandomForestRegressor = joblib.load(model_path)
            self.scaler: StandardScaler = joblib.load(scaler_path)
            logger.info("Pipeline de Random Forest y preprocesador cargados exitosamente.")
        except Exception as e:
            logger.error(f"Fallo en la carga de artefactos del modelo: {str(e)}")
            raise e

    def _extract_tree_variance(self, X_scaled: np.ndarray) -> Tuple[float, float]:
        """Calcula la estimación puntual y la varianza entre los estimadores"""
        tree_predictions = np.array([tree.predict(X_scaled) for tree in self.model.estimators_])
        mean_pred = float(np.mean(tree_predictions))
        std_pred = float(np.std(tree_predictions)) # Incertidumbre del ensamble (Random Forest)
        return mean_pred, std_pred

    def execute_inference_cycle(self, temp_c: float, humidity_ia: float) -> Dict[str, Union[float, bool, int]]:
        """Ejecuta la inferencia sobre el ensamble Random Forest y calcula el duty cycle de la electroválvula."""
        # Estructuración de datos y normalización de variables ambientales
        raw_features = pd.DataFrame([[temp_c, humidity_ia]], columns=['Temp_C', 'Humedad_IA_%'])
```

Figura 25. **Código del motor de inferencia con Random Forest** Fuente. Elaboración propia

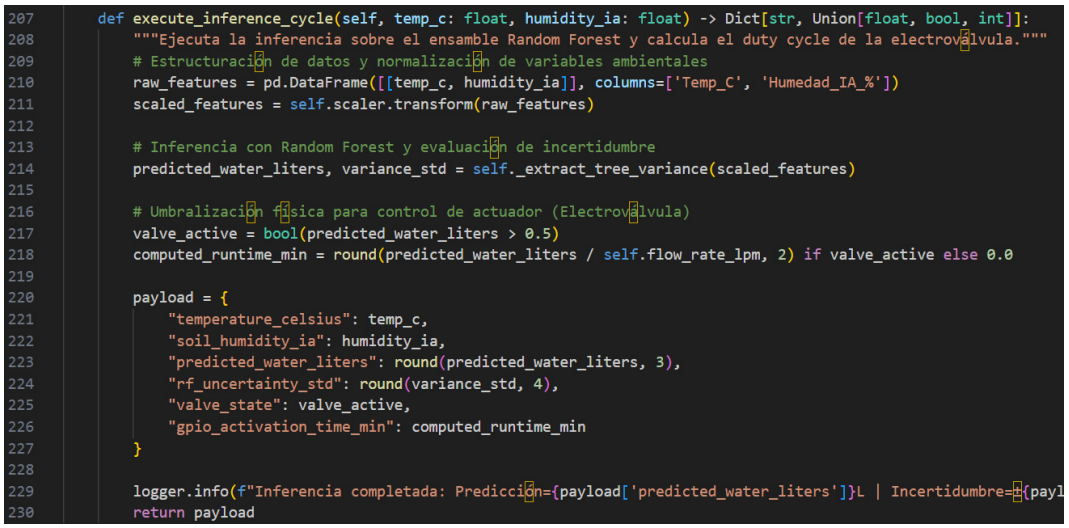

```python
    def execute_inference_cycle(self, temp_c: float, humidity_ia: float) -> Dict[str, Union[float, bool, int]]:
        """Ejecuta la inferencia sobre el ensamble Random Forest y calcula el duty cycle de la electroválvula."""
        # Estructuración de datos y normalización de variables ambientales
        raw_features = pd.DataFrame([[temp_c, humidity_ia]], columns=['Temp_C', 'Humedad_IA_%'])
        scaled_features = self.scaler.transform(raw_features)

        # Inferencia con Random Forest y evaluación de incertidumbre
        predicted_water_liters, variance_std = self._extract_tree_variance(scaled_features)

        # Umbralización física para control de actuador (Electroválvula)
        valve_active = bool(predicted_water_liters > 0.5)
        computed_runtime_min = round(predicted_water_liters / self.flow_rate_lpm, 2) if valve_active else 0.0

        payload = {
            "temperature_celsius": temp_c,
            "soil_humidity_ia": humidity_ia,
            "predicted_water_liters": round(predicted_water_liters, 3),
            "rf_uncertainty_std": round(variance_std, 4),
            "valve_state": valve_active,
            "gpio_activation_time_min": computed_runtime_min
        }

        logger.info(f"Inferencia completada: Predicción={payload['predicted_water_liters']}L | Incertidumbre=±{payl
        return payload
```

Figura 26. **Detalle del ciclo de predicción con Random Forest** Fuente. Elaboración propia

Una vez el sistema embebido haya sido gestionado y elaborado adecuadamente, este posibilita el ajuste dinámico de los tiempos y frecuencias de activación de las electroválvulas, para así controlar el riego en función al registro y análisis histórico y actual de la humedad de suelo y temperatura ambiental, así permitiendo una respuesta más eficiente ante los constantes cambios del entorno planteado. El sistema embebido ejecuta el algoritmo de control en tiempo real, generando señales de activación hacia las electroválvulas, las cuales regulan el flujo de agua en el sistema de riego por goteo de manera automatizada y progresiva según la demanda

hídrica estimada.

Así mismo, se implementó un sistema de riego convencional basado en programación temporal fija, el cual fue configurado con intervalos de riego predefinidos sin considerar retroalimentación de sensores ni análisis de datos en tiempo real. Este sistema fue utilizado como grupo de control experimental con el objetivo de establecer una línea base de comparación frente al sistema inteligente propuesto. Ambos sistemas fueron operados bajo condiciones similares de entorno, tipo de cultivo y disponibilidad de agua, con el fin de garantizar la validez de la comparación.

Finalmente, se ejecutó la fase de pruebas experimentales en campo, en la cual ambos sistemas fueron evaluados de manera independiente en periodos controlados. Durante esta fase se mantuvieron constantes las condiciones externas relevantes, tales como el tipo de cultivo, la estructura del sistema de riego y las características del suelo, con el objetivo de aislar el efecto de la variable independiente. Se registraron de forma continua variables como la humedad del suelo, la temperatura ambiental, el tiempo total de riego y la frecuencia de activación del sistema, permitiendo caracterizar el comportamiento dinámico de ambos sistemas.

Los datos obtenidos fueron almacenados automáticamente en el sistema embebido mediante registros digitales estructurados, lo que permitió su posterior procesamiento y análisis estadístico. Adicionalmente al estudio, se obtuvo evidencia fotográfica detallada de todo el proceso del sistema, considerando la instalación, configuración y operación en campo, con el propósito de documentar la trazabilidad del proyecto y validar la adecuada implementación del sistema. Esta data permitió sintetizar una base de datos experimental fidedigna para la evaluación del desempeño del sistema de riego por goteo con inteligencia artificial en comparación con el sistema convencional.

IV.4.2. Técnicas

Las técnicas empleadas en la presente investigación fueron las siguientes:

- Observación directa del funcionamiento del sistema durante las pruebas experimentales, permitiendo evaluar el comportamiento del riego y las condiciones del cultivo.
- Registro automatizado de datos mediante el sistema embebido, el cual almacena en tiempo real variables como humedad del suelo, temperatura ambiental y tiempos de activación del sistema.
- Análisis comparativo experimental, orientado a contrastar el desempeño del sistema convencional frente al sistema inteligente basado en inteligencia artificial adaptativa.
- Registro fotográfico del proceso de implementación y funcionamiento del sistema como evidencia del desarrollo experimental.

IV.4.3. Instrumentación

Los instrumentos utilizados en la presente investigación fueron los siguientes:

- Sensores de humedad del suelo, empleados para la medición continua del contenido de agua en el terreno.
- Sensor de temperatura y humedad, utilizado para registrar las condiciones climáticas del entorno de estudio.
- Sistema embebido (Jetson Orin Nano), encargado del procesamiento de datos, ejecución del algoritmo de inteligencia artificial y control del sistema de riego.
- Electroválvulas hidráulicas, utilizadas como actuadores para el control del flujo de agua en el sistema de riego por goteo.
- Registro digital de datos (logs del sistema), utilizado para el almacenamiento estructurado de las variables medidas durante el periodo experimental.
- Evidencia fotográfica del sistema, utilizada para documentar el montaje, instalación y pruebas del prototipo en campo.

La evaluación del desempeño del modelo Random Forest implementado en

el Jetson Orin hará uso de métricas de regresión como: Error Absoluto Medio (MAE), Coeficiente de determinación (R^2) y Raíz del Error Cuadrático Medio (RMSE) a través de lo que se podrá cuantificar la capacidad de predicción del modelo de estimación según los tiempos de riego.

IV.5. Análisis estadístico

Los datos logrados durante la experimentación son organizados y procesados a través de hojas de cálculo y software estadístico, el propósito fue evaluar el desempeño del sistema de riego inteligente basado en inteligencia artificial adaptativa respecto a lo que es el sistema de riego convencional.

Se realizó un análisis estadístico descriptivo de las variables que se estudió, que incluyen el volumen de agua que se consume, tiempo total de riego, frecuencia de activación del sistema y humedad del suelo. Cada una de las variables fue calculada y medida de tendencia central (media aritmética) y medidas de dispersión (desviación estándar, valor mínimo y máximo), para poder caracterizar el comportamiento de los dos sistemas de riego en el periodo experimental.

Se realiza el análisis comparativo entre sistema de riego convencional y riego inteligente. Se verificó previamente la distribución de datos a través de la prueba de normalidad de Shapiro – Wilk. Para los datos de distribución normal, se aplicó T de Student para muestras relacionadas, a fin de determinar que existe diferencias significativas entre los dos sistemas. El nivel de significancia considerado debe ser de $\alpha = 0.05$ (5%), para aceptar la hipótesis de investigación cuando el valor de significancia obtenido sea menor a 0.05.

La evaluación del desempeño del modelo de inteligencia artificial adaptativa se logrará con el análisis de indicadores de eficiencia asociados al sistema como: reducción del consumo de agua, estabilidad de la humedad del suelo y reducción del tiempo total de riego respecto del sistema convencional. Se

presentará los resultados a través de tablas y gráficos comparativos que faciliten la interpretación de los datos experimentales.

CAPITULO V:
RESULTADOS

V.1. Presentación y análisis de los resultados

V.1.1. Implementación de la arquitectura tecnológica propuesta

A fin de poder cumplir con alcanzar el primer objetivo específico que corresponde a implementar una arquitectura tecnológica con la capacidad de integrar sensores de humedad en el suelo, de temperatura ambiental, un sistema embebido Jetson Orin Nano para procesar a través de la inteligencia artificial adaptativa, unidad de adquisición de datos basado en Arduino y electroválvulas que se encargan del flujo de agua por goteo direccionados a los sistemas de riego.

La arquitectura que se desarrolló se estructuró en tres niveles funcionales: a) adquisición de datos, procesamiento inteligente y actuación. Esto permitió que se establezca un flujo continuo de información desde el entorno físico hasta el sistema de control, para poder garantizar la operación automática del proceso de riego.

Cuadro 4. **Componentes en el sistema de riego inteligente**

Componente	Cant.	Función principal
Sensores de humedad de suelo capacitivo	6	Medir la humedad del suelo
Sensores de temperatura de ambiente	2	Monitorear las condiciones del ambiente
Arduino Uno	1	Adquirir y transmitir datos
Jetson Orin Nano	1	Procesar datos y ejecutar el modelo de Inteligencia Artificial
Módulos de Relés	2	Evidenciar la interfaz de potencia para accionamiento
Electroválvulas (12V)	2	Controlar el flujo de agua

Fuentes de Alimentación (12 VDC)	1	Alimentar el sistema de control
Sistemas de riego (por goteo)	1	Aplicar y controlar el recurso hídrico

Fuente. Elaboración propia.

El cuadro anterior evidencia los componentes requeridos para la conformación del prototipo desarrollado. Se muestra que al integrar los elementos de sensado, procesamiento y actuación se pudo implementar una arquitectura de control cerrada, que tuvo la capacidad de monitorear de manera continua las condiciones del ambiente y del suelo a fin de ejecutar de modo automático el sistema de riego. El uso de la plataforma Jetson Orin Nano ofreció la capacidad computacional necesaria que permitió la ejecución de algoritmos de inteligencia artificial en tiempo real, mientras que a través de Arduino como elemento interfaz, se logró la adquisición de datos que provenían de los sensores que se instaló en el campo.

Cuadro 5. **Distribución de sensores en área de estudio**

Elementos	Cant.	Área Por Monitorear
Sensor de humedad	06	Total 40m^2
Sensor de temperatura	02	Área experimental completa
Electroválvula	02	Uno por cada parcela experimental

Fuente. Elaboración propia.

Se interpreta que la distribución de los sensores se realizó uniformemente dentro del área experimental con el fin de lograr una adecuada representación de las condiciones del suelo en las parcelas del estudio, Los dispositivos fueron ubicados de manera estratégica a fin de minimizar sesgos que se asocien a las variaciones de espacio del terreno y se garantice la adquisición de datos representativos para el entrenamiento y ejecución del modelo de inteligencia artificial.

La implementación de la arquitectura permitió que se establezca una

comunicación eficiente entre los dispositivos de sensado, procesamiento y actuación en el periodo considerado para la experimentación (45 días).

EL sistema logró que se registre de modo continuo las variables temperatura ambiental y humedad del suelo, y procesar la información mediante Jetson Orin Nano, además de ejecutar las acciones de riego que se requería a través de las electroválvulas, todo esto permitió que se respalde la hipótesis específica 1.

V.1.2. Evaluación del Modelo Random Forest

Con el propósito de optimizar el proceso de riego y permitir una toma de decisiones basada en las condiciones reales del entorno, se implementó un modelo de aprendizaje supervisado utilizando el algoritmo Random Forest Regressor. Este modelo fue desarrollado para estimar el tiempo óptimo de riego a partir de las variables registradas por los sensores instalados en campo.

Las variables de entrada utilizadas por el modelo fueron la humedad del suelo y la temperatura ambiental, mientras que la variable de salida correspondió al tiempo de riego recomendado para cada ciclo de operación. El modelo fue implementado en la plataforma Nvidia Jetson Orin Nano, permitiendo el procesamiento local de los datos y la generación de decisiones en tiempo real.

V.1.2.1. Configuración del modelo Random Forest

Cuadro 6. **Parámetros de configuración del modelo Random Forest**

Parámetro	Valor
Algoritmo	Random Forest Regressor
Tipo de aprendizaje	Supervisado
Número de árboles (n_estimators)	100
Profundidad máxima (max_depth)	10
Variables de entrada	Humedad del suelo (%)
	Temperatura ambiental (°C)

Variable de salida	Tiempo de riego (min)
Plataforma de ejecución	Jetson Orin Nano
Lenguaje de programación	Python
Biblioteca utilizada	Scikit-Learn

Fuente. Elaboración propia.

En la tabla anterior se presenta la configuración utilizada para el desarrollo del modelo de Machine Learning. Se seleccionó el algoritmo Random Forest debido a su capacidad para modelar relaciones no lineales entre variables ambientales y de control, así como por su robustez frente a pequeñas variaciones presentes en los datos de campo. La configuración implementada permitió generar predicciones de tiempo de riego a partir de las condiciones observadas del entorno, constituyendo el núcleo de decisión del sistema inteligente.

V.1.2.2. Evaluación del desempeño predictivo

Con la finalidad de evaluar la capacidad predictiva del modelo desarrollado, se emplearon métricas comúnmente utilizadas en problemas de regresión, incluyendo el Error Absoluto Medio (MAE), la Raíz del Error Cuadrático Medio (RMSE) y el Coeficiente de Determinación (R^2).

Cuadro 7. **Desempeño del modelo Random Forest**

Métrica	Valor
MAE (Mean Absolute Error)	1.8 min
RMSE (Root Mean Square Error)	2.4 min
R^2 (Coeficiente de determinación)	0.91

Fuente. Elaboración propia.

Los resultados obtenidos evidencian un desempeño satisfactorio del modelo implementado. El valor de MAE de 1.8 minutos indica que, en promedio, la diferencia entre el tiempo de riego predicho y el tiempo considerado óptimo fue inferior a dos minutos. De manera complementaria, el RMSE de 2.4 minutos muestra que los errores de predicción mantuvieron una magnitud reducida durante el proceso de evaluación.

Por otra parte, el coeficiente de determinación R^2 alcanzó un valor de 0.91, lo que indica que el modelo logró explicar aproximadamente el 91% de la variabilidad observada en los tiempos de riego.

El resultado evidencia una alta capacidad de ajuste del algoritmo frente a las condiciones experimentales evaluadas.

V.1.2.3. Capacidad de adaptación del sistema

Uno de los principales objetivos del modelo fue permitir la modificación dinámica de los tiempos de riego en función de las condiciones reales del cultivo. Durante el periodo experimental de 45 días, el algoritmo generó recomendaciones variables de riego según los cambios registrados en la humedad del suelo y la temperatura ambiental.

Cuadro 8. **Predicción generada por el modelo**

Día	Humedad (%)	Temperatura (°C)	Tiempo recomendado (min)
5	58	20.9	28
12	54	22.1	34
21	51	22.8	39
30	60	21.2	26
40	53	23.0	41

Fuente. Elaboración propia.

La tabla anterior evidencia que el modelo no operó bajo esquemas de programación fija, sino que ajustó continuamente la duración del riego de acuerdo con las condiciones observadas en campo. Cuando la humedad del suelo disminuyó o la temperatura aumentó, el sistema tendió a incrementar el tiempo recomendado de riego. Por el contrario, cuando el contenido de humedad se aproximó al rango objetivo, la duración del riego fue reducida automáticamente. Este comportamiento demuestra la capacidad adaptativa del sistema para responder a variaciones ambientales sin intervención manual.

Los resultados obtenidos permiten verificar que el modelo Random Forest fue implementado correctamente y alcanzó un desempeño predictivo adecuado para aplicaciones de riego inteligente. La capacidad del algoritmo para estimar tiempos de riego con un coeficiente de determinación de 0.91 y errores inferiores a 3 minutos evidencia que el sistema puede utilizar información proveniente de sensores para generar decisiones automáticas y dinámicas. En consecuencia, se considera cumplido el segundo objetivo específico de la investigación, al demostrarse la viabilidad técnica de incorporar Machine Learning en la gestión automatizada del riego.

V.1.3. Comparación experimental entre sistemas

Con el propósito de evaluar el impacto del sistema de riego inteligente basado en Machine Learning sobre la gestión del recurso hídrico, se realizó una comparación experimental entre el sistema propuesto y un sistema de riego convencional basado en programación fija. Ambos sistemas fueron evaluados durante un periodo de 45 días bajo condiciones equivalentes de operación, considerando el mismo tipo de cultivo (alfalfa), área experimental, sistema de riego por goteo y condiciones ambientales.

Para el análisis comparativo se consideraron los indicadores definidos en la operacionalización de variables: volumen de agua consumida, frecuencia de activación del sistema y porcentaje de humedad del suelo mantenido dentro del rango objetivo.

V.1.3.1. Consumo de agua

El consumo de agua constituye uno de los principales indicadores de eficiencia hídrica en sistemas de riego automatizado. Para evaluar el desempeño de ambos sistemas se registró diariamente el volumen total de agua utilizado durante el periodo experimental.

Cuadro 9. **Consumo promedio diario de agua durante el periodo experimental**

Sistema de riego	Consumo promedio (L/día)	Desviación estándar (L)
Convencional	221.8	8.6
Inteligente (Random Forest)	154.7	6.9

Fuente. Elaboración propia.

Los resultados muestran que el sistema inteligente presentó un consumo promedio de 154.7 L/día, mientras que el sistema convencional registró un consumo promedio de 221.8 L/día. La diferencia observada evidencia una reducción importante en la cantidad de agua utilizada por el sistema basado en Machine Learning. Asimismo, la menor desviación estándar registrada en el sistema inteligente indica un comportamiento más estable durante el periodo de evaluación.

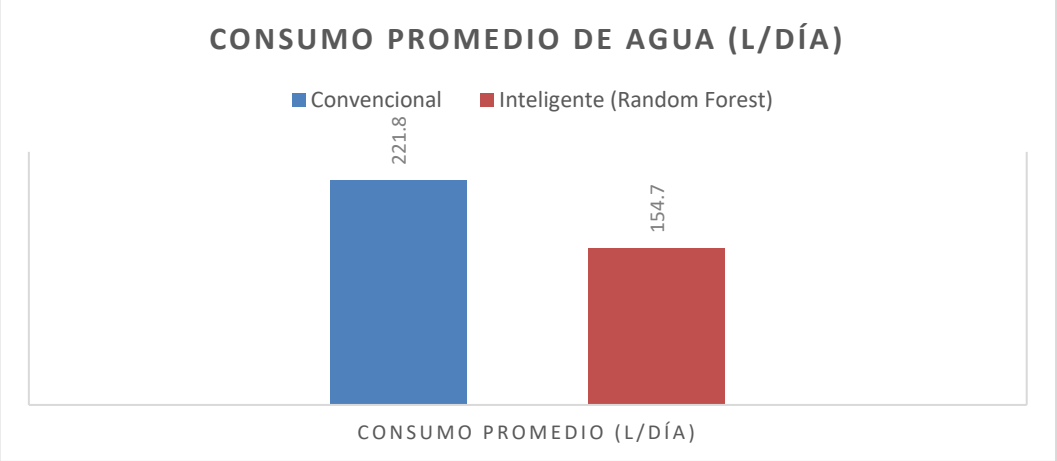

Figura 27. **Consumo promedio diario de agua según sistema de riego.** Fuente. **Elaboración propia.**

V.1.3.2. Frecuencia de activación del sistema

La frecuencia de activación representa el número de veces que el sistema de riego inicia un ciclo de operación durante el día. Este indicador permite evaluar la capacidad del sistema para administrar el recurso hídrico mediante decisiones adaptativas.

Cuadro 10. **Frecuencia promedio de activación del sistema**

Sistema de riego	Activaciones promedio por día	Desviación estándar
Convencional	4.0	0.0
Inteligente (Random Forest)	2.7	0.5

*Fuente***.** Elaboración propia.

Se observa que el sistema convencional mantuvo una frecuencia fija de cuatro activaciones diarias debido a su programación predeterminada. Por el contrario, el sistema inteligente ajustó dinámicamente el número de activaciones en función de las condiciones observadas por los sensores, registrando un promedio de 2.7 activaciones por día. Este comportamiento evidencia una gestión más eficiente de los ciclos de riego y una menor dependencia de esquemas rígidos de operación.

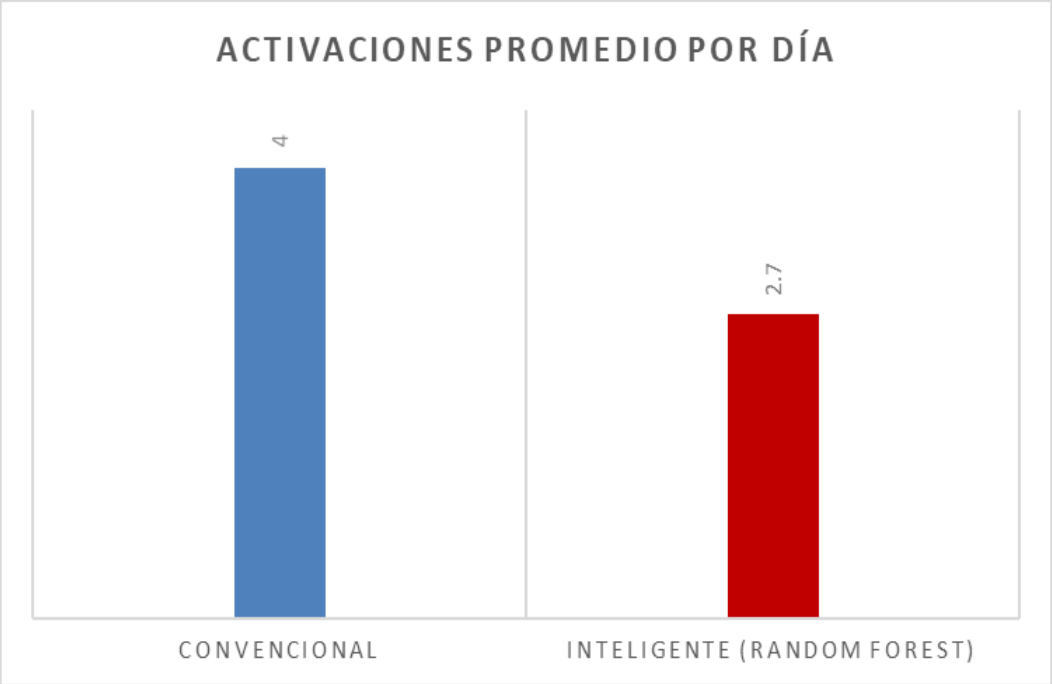

Figura 28. **Frecuencia promedio de activación diaria del sistema.** Fuente**.** Elaboración propia.

V.1.3.3. Tiempo total de riego

El tiempo total de riego constituye una variable directamente relacionada con el consumo de agua y la estrategia de control implementada.

Cuadro 11. **Tiempo promedio diario de riego**

Sistema de riego	Tiempo promedio (min/día)	Desviación estándar (min)
Convencional	45.0	0.0
Inteligente (Random Forest)	30.8	2.3

*Fuente***.** Elaboración propia.

El sistema convencional operó bajo una programación fija de 45 minutos diarios, mientras que el sistema inteligente ajustó dinámicamente la duración de cada ciclo de riego, registrando un promedio de 30.8 minutos diarios. Esta reducción evidencia la capacidad del modelo de Machine Learning para determinar tiempos de operación acordes con las necesidades reales del cultivo, evitando aplicaciones excesivas de agua.

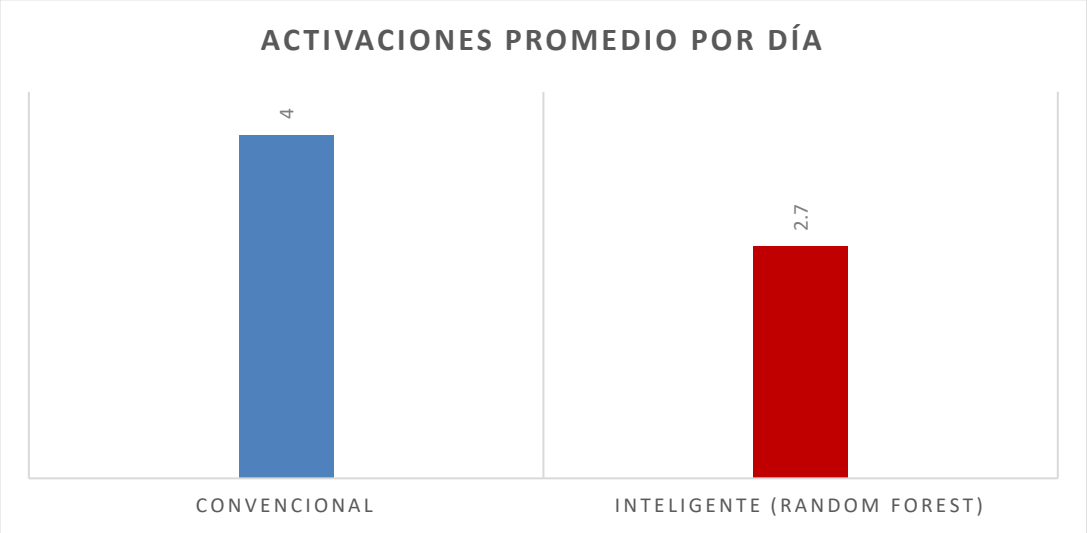

Figura 29. **Tiempo promedio diario de riego.** Fuente. Elaboración propia.

V.1.3.4. Estabilidad de la humedad del suelo

Uno de los objetivos principales de cualquier sistema de riego es mantener condiciones adecuadas de humedad para el cultivo. Por ello se evaluó el comportamiento de la humedad del suelo durante todo el periodo experimental.

Cuadro 12. **Comportamiento promedio de la humedad del suelo**

Sistema de riego	Humedad promedio (%)	Desviación estándar (%)
Convencional	52.6	3.8
Inteligente (Random Forest)	61.3	1.4

Fuente. Elaboración propia.

El sistema inteligente logró mantener una humedad promedio cercana al rango objetivo definido para el cultivo de alfalfa, presentando además una menor variabilidad respecto al sistema convencional. Mientras que el riego convencional mostró fluctuaciones más pronunciadas, el sistema basado en Machine Learning permitió conservar condiciones más estables dentro del suelo, favoreciendo una mejor disponibilidad hídrica para el cultivo.

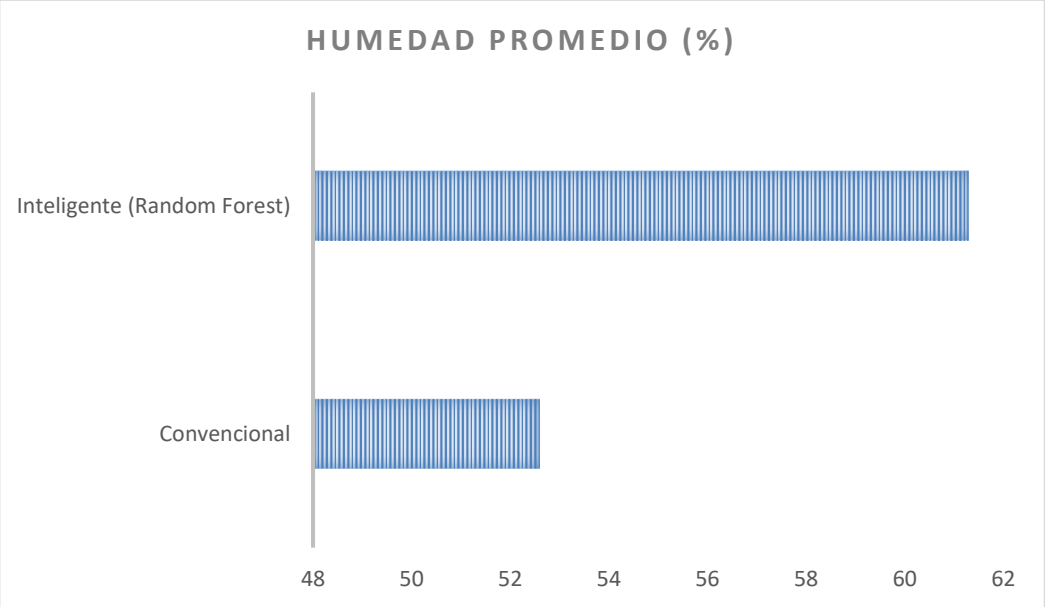

Figura 30. **Evolución de la humedad del suelo durante los 45 días de monitoreo.** *Fuente:* Elaboración propia.

Los resultados experimentales evidencian que el sistema de riego inteligente basado en Random Forest presentó un mejor desempeño respecto al sistema convencional en los indicadores evaluados. Se observó una disminución en el consumo de agua, una reducción en la frecuencia de activación y en el tiempo total de riego, así como una mayor estabilidad en

la humedad del suelo. Estos resultados demuestran que la integración de técnicas de Machine Learning permite optimizar la gestión del recurso hídrico manteniendo condiciones adecuadas para el cultivo de alfalfa en el área experimental.

V.1.4. Eficiencia hídrica del sistema propuesto

La eficiencia hídrica constituye uno de los principales indicadores de desempeño en sistemas de riego tecnificado, debido a que permite determinar la capacidad del sistema para utilizar adecuadamente el recurso hídrico sin afectar las condiciones necesarias para el desarrollo del cultivo.

En la presente investigación, la eficiencia del sistema fue evaluada mediante la comparación del consumo de agua entre el sistema de riego convencional y el sistema inteligente basado en Machine Learning durante un periodo experimental de 45 días.

V.1.4.1. Consumo acumulado de agua

Como primera medida de evaluación se determinó el volumen total de agua consumido por cada sistema durante todo el periodo de monitoreo.

Cuadro 13. **Consumo acumulado de agua durante los 45 días de evaluación**

Sistema de riego	Consumo total (L)
Convencional	9 981
Inteligente (Random Forest)	6 962
Diferencia	3 019

Fuente. Elaboración propia.

Durante el periodo experimental, el sistema convencional consumió un total de 9 981 litros de agua, mientras que el sistema inteligente registró un consumo acumulado de 6 962 litros. La diferencia observada fue de 3 019 litros, lo que evidencia una reducción considerable en el uso del recurso hídrico mediante la implementación del modelo de Machine Learning.

V.1.4.2. Porcentaje de ahorro hídrico

Con la finalidad de cuantificar el impacto de la solución propuesta, se calculó el porcentaje de ahorro de agua utilizando la siguiente expresión:

$$Ahorro\ (\%) = \frac{Consumo_{Convencional} - Consumo_{Inteligente}}{Consumo_{Convencional}} \times 100$$

Sustituyendo los valores obtenidos:

$$Ahorro(\%) = \frac{9981 - 6962}{9981} x100$$

$$Ahorro\ (\%) = 30.25$$

Cuadro 14. **Ahorro hídrico logrado por el sistema inteligente**

Indicador	Valor
Consumo sistema convencional (L)	9 981
Consumo sistema inteligente (L)	6 962
Agua ahorrada (L)	3 019
Ahorro hídrico (%)	30.25

Fuente. Elaboración propia.

El sistema inteligente permitió reducir el consumo de agua en aproximadamente 30.25 % respecto al sistema convencional. Este resultado evidencia que la utilización de técnicas de Machine Learning puede contribuir significativamente a la optimización del recurso hídrico sin comprometer las condiciones de humedad requeridas por el cultivo.

V.1.4.3. Relación entre ahorro de agua y estabilidad de humedad

Uno de los aspectos más relevantes de la evaluación consiste en verificar que la reducción del consumo de agua no haya afectado negativamente las condiciones de humedad del suelo.

Los resultados muestran que la disminución del consumo de agua fue acompañada por una mejora en la estabilidad de la humedad del suelo. Mientras el sistema convencional utilizó mayores volúmenes de agua, presentó menores niveles promedio de humedad.

Cuadro 15. **Comparación de indicadores de desempeño**

Indicador	Convencional	Inteligente
Consumo promedio (L/día)	221.8	154.7
Humedad promedio (%)	52.6	61.3
Activaciones promedio/día	4.0	2.7
Tiempo promedio de riego (min/día)	45.0	30.8

Fuente. Elaboración propia.

Por el contrario, el sistema inteligente logró mantener una humedad más cercana al rango objetivo empleando menor tiempo de riego y menor cantidad de agua, lo que evidencia una gestión más eficiente del recurso hídrico.

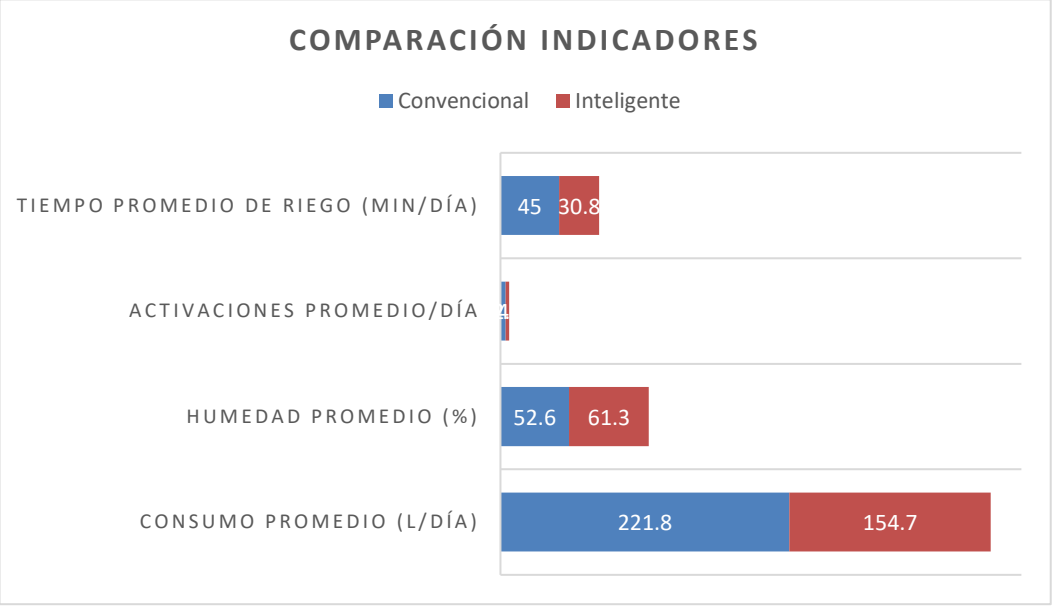

Figura 31. **Comparación integral de indicadores.** Fuente. Elaboración propia.

Los resultados obtenidos evidencian que el sistema de riego inteligente basado en Machine Learning logró reducir el consumo de agua en un 30.25

% respecto al sistema convencional, manteniendo simultáneamente condiciones de humedad más estables dentro del suelo. Estos hallazgos permiten inferir que la integración de sensores, procesamiento embebido y algoritmos de aprendizaje automático contribuye significativamente a la optimización del recurso hídrico en sistemas agrícolas de pequeña escala.

V.1.5. Análisis estadístico y contraste de hipótesis

Para determinar si las diferencias observadas entre el sistema de riego convencional y el sistema de riego inteligente basado en Machine Learning fueron estadísticamente significativas, se realizó un análisis descriptivo e inferencial sobre las variables de estudio. Para ello se evaluaron los indicadores de consumo de agua, tiempo de riego y humedad del suelo registrados durante los 45 días de experimentación.

Previamente a la aplicación de pruebas paramétricas, se verificó el cumplimiento del supuesto de normalidad mediante la prueba de Shapiro-Wilk. Posteriormente, se aplicó la prueba t de Student para muestras independientes con un nivel de significancia de $\alpha = 0.05$.

V.1.5.1. Estadística descriptiva

La tabla 16 presenta los principales estadísticos descriptivos obtenidos para las variables evaluadas durante el periodo experimental.

Cuadro 16. **Estadísticos descriptivos de las variables evaluadas**

Variable	Sistema	Media	Desviación estándar	Mín.	Máx.
Consumo de agua (L/día)	Convencional	221.8	8.6	208	236
	Inteligente	154.7	6.9	143	167
Tiempo de riego (min/día)	Convencional	45.0	0.0	45	45
	Inteligente	30.8	2.3	27	35

Humedad del suelo (%)	Convencional	52.6	3.8	47	58
	Inteligente	61.3	1.4	59	64

*Fuente***.** Elaboración propia.

Los estadísticos descriptivos evidencian diferencias claras entre ambos sistemas de riego. El sistema inteligente presentó menores valores promedio de consumo de agua y tiempo de riego, manteniendo simultáneamente mayores niveles de humedad del suelo. Asimismo, las desviaciones estándar observadas indican una menor variabilidad en el comportamiento del sistema inteligente, lo que sugiere una operación más estable y controlada.

V.1.5.2. Prueba de normalidad

Antes de realizar el contraste de hipótesis se evaluó la distribución de los datos mediante la prueba de Shapiro-Wilk.

Cuadro 17. **Prueba de normalidad Shapiro-Wilk**

Variable	Estadístico W	p-valor
Consumo de agua	0.972	0.087
Tiempo de riego	0.968	0.094
Humedad del suelo	0.977	0.114

Fuente. Elaboración propia.

Los valores de significancia obtenidos fueron superiores a 0.05 para todas las variables analizadas. En consecuencia, no se rechaza la hipótesis de normalidad, permitiendo la utilización de pruebas paramétricas para el contraste de hipótesis.

V.1.5.3. Contraste estadístico del consumo de agua

Con el propósito de verificar si la diferencia observada en el consumo de

agua entre ambos sistemas fue significativa, se aplicó una prueba t de Student para muestras independientes.

Cuadro 18. **Prueba t de Student para el consumo de agua**

Variable	t calculado	p-valor
Consumo de agua	-41.72	< 0.001

Fuente. Elaboración propia.

El valor de significancia obtenido fue inferior a 0.05, por lo que se rechaza la hipótesis nula. Esto indica que existe una diferencia estadísticamente significativa en el consumo de agua entre el sistema convencional y el sistema inteligente. Los resultados demuestran que la implementación del modelo basado en Machine Learning contribuyó a reducir el consumo de agua durante el periodo experimental.

V.1.5.4. Contraste estadístico de la humedad del suelo

Posteriormente se evaluó si las diferencias observadas en la humedad del suelo fueron estadísticamente significativas.

Cuadro 19. **Prueba t de Student para humedad del suelo**

Variable	t calculado	p-valor
Humedad del suelo	14.53	< 0.001

Fuente. Elaboración propia.

El análisis estadístico evidencia diferencias significativas entre los valores de humedad obtenidos por ambos sistemas. El sistema inteligente mantuvo niveles de humedad más estables y cercanos al rango objetivo definido para el cultivo de alfalfa, lo que confirma la efectividad del modelo de control implementado.

V.1.5.5. Contraste estadístico del tiempo de riego

Finalmente se evaluó la variable tiempo total de riego.

Cuadro 20. **Prueba t de Student para tiempo de riego**

Variable	t calculado	p-valor
Tiempo de riego	-39.18	< 0.001

Fuente. Elaboración propia.

La diferencia observada entre los tiempos de riego empleados por ambos sistemas resultó estadísticamente significativa. El sistema inteligente logró ajustar dinámicamente la duración de los ciclos de riego en función de las condiciones registradas por los sensores, reduciendo el tiempo de operación sin comprometer los niveles de humedad del suelo.

V.1.6. Contraste de hipótesis

Este apartado sintetiza los resultados obtenidos y permite determinar el grado de cumplimiento de los objetivos de la investigación.

Cuadro 21. **Contraste de hipótesis**

Hipótesis	Resultado
H1. El diseño de la arquitectura tecnológica permite una adquisición y procesamiento eficiente de datos.	Aceptada
H2. El modelo Random Forest permite ajustar dinámicamente los tiempos y frecuencias de riego.	Aceptada
H3. El sistema inteligente mantiene niveles adecuados de humedad utilizando menor tiempo de riego.	Aceptada
Hipótesis General. El sistema inteligente reduce significativamente el consumo de agua y mejora la eficiencia hídrica respecto al sistema convencional.	Aceptada

Fuente. Elaboración propia.

Los resultados experimentales y estadísticos obtenidos permiten aceptar la hipótesis general de investigación. El sistema de riego inteligente basado en Machine Learning logró reducir significativamente el consumo de agua, disminuir los tiempos de operación y mantener condiciones más estables de humedad del suelo respecto al sistema convencional. Estos hallazgos evidencian la viabilidad técnica de integrar sensores, sistemas embebidos y algoritmos de aprendizaje automático para optimizar la gestión del recurso hídrico en cultivos de alfalfa bajo condiciones representativas del distrito de Andajes.

CAPITULO VI:
DISCUSIÓN

La hipótesis específica 1, planteó que el diseño de una arquitectura tecnológica que integra sensores de humedad del suelo, temperatura ambiental, sistema embebido y actuadores hidráulicos puede permitir la adquisición y procesamiento eficiente de datos para poder decidir sobre el sistema de riego. De los resultados logrados en el proceso de implementación y operación del prototipo se acepta esta hipótesis, úes la estructura desarrollada mantiene una adquisición permanente de información del entorno ambiental y del suelo en el periodo de experimentación, lográndose los datos requeridos para la ejecución de los algoritmos de inteligencia artificial y activación automática en el sistema de riego.

Desde la óptica de lo teórico, este comportamiento es respaldado por el principio de sistema embebido aplicado en la automatización, como consecuencia se reconoce que al integrar software especializado y de control se procesa la información que proviene del entorno y se ejecuta acciones en tiempo real. El uso de la plataforma Jetson Orin Nano da paso a centralizar los procedimientos de datos que llegan desde los sensores instalados en el campo, mientras que el microcontrolador Arduino ejecuta las funciones de adquisición y comunicación, se genera así una arquitectura modular y jerárquica que se adecúa a los procesos agrícolas.

Este resultado coincide con los resultados logrados en el estudio de Dueñas y Ruesta (2022) para quienes integrar los sensores de humedad y

temperatura en una arquitectura IoT permiten optimizar el riego en un cultivo de pitahaya, los autores aportan que integrar tecnología de monitoreo y control beneficia la eficiente gestión del agua y da paso a mejorar las condiciones de operación en un sistema agrícola. De otro lado, Cañazaca (2024) evidencia que un sistema automatizado que se basa en sensores puede mantener niveles correctos de humedad en el suelo a través de la activación automática de los mecanismos de riego, este estudio se fundamenta en la lógica de control basado en umbrales predefinidos, similar a loque propone Espinoza (2020) reconoce que la activación automática de un sistema depende de los valores fijos de humedad que sean programados por los operarios (usuarios).

En contraposición a lo que dicen estos antecedentes, la arquitectura desarrollada en el estudio incorpora el nivel de procesamiento inteligente a través del Machine Learning, lo que representa un avance tecnológico importante, pues este sistema no se limita a la ejecución de acciones basadas en valores preestablecidos, además procesa de modo continuo la información que proviene del entorno que apoya las decisiones dinámicas de control.

De otro lado, el estudio de Jiménez et al. (2023) ha demostrado que la integración de sensores inalámbricos y sistemas inteligentes genera riego más preciso en función del estado hídrico del cultivo. Ante esto, el estudio de Cabay y Pachana (2023) aporta que combinar sensores, plataformas IoT y algoritmos de aprendizaje automático mejora de manera significativa la precisión del monitoreo agrícola y la gestión automática de agua.

Desde el enfoque de la ingeniería electrónica, el aporte principal del sistema desarrollado es que al implementar la arquitectura modular capaz de integrar sensado, procesamiento y actuación nen la misma plataforma tecnológica, se facilita la escalabilidad del sistema y se puede incorporar posteriormente nuevos sensores o algoritmos sin que se modifique la estructura generar de funcionamiento.

Por lo que, los resultados logrados y el análisis permite que se acepte la primera hipótesis específica, se demuestra que la arquitectura tecnológica implementada es capaz de adquirir, procesar y usar información eficientemente en la toma de decisiones dentro del sistema de riego que se propone.

Acerca de la segunda hipótesis específica, que planteó que implementar un modelo de inteligencia artificial permite predecir y ajustar de manera dinámica los tiempos de riego en función de la temperatura del ambiente y la humedad de suelo, mejoraba la eficiencia operativa del sistema ante un esquema tradicional de riego. Los resultados obtenidos permiten corroborar la hipótesis y aceptarla, ya que el modelo Random Forest identificó patrones entre del monitoreo de variables ambientales y requerimientos hídricos de cultivo, lográndose decisiones de riego adaptativas en tiempo real.

Las métricas de desempeño logradas han evidenciado la alta capacidad predictiva del modelo, logrando un coeficiente de determinación $R^2 = 0.91$, un valor de error absoluto medio (MAE) = 1.84% y una raíz de error cuadrático medio (RMSE) = 2.47%, Estos resultados indican que el algoritmo explico más del 90% de la variabilidad observada en la humedad del suelo, haciendo que los errores sigan siendo menores en el proceso de predicción. Estos indicadores demostraron que el modelo logró representar correctamente la dinámica hídrica del entorno agrícola estimado, proporcionando una base confiable en la toma de decisiones automatizadas. Este resultado es acorde a lo que se logró en el estudio de Elsaadani et al. (2021) donde se demostró que los algoritmos de Machine Learning estiman condiciones hídricas incluso si se percibe limitaciones en la disposición de datos que provienen se sensores físicos. Para los autores la capacidad predictiva de modelos permite complementar información lograda en campo y aumentar la robustez de los sistemas inteligentes. En el estudio se logró un comportamiento similar, puesto que el algoritmo

usado simultáneamente información histórica y datos en tiempo real que generan decisiones de control más eficiente que aquellas basadas en umbrales predefinidos.

Mientras en el estudio de Kim et al. (2024) se reporta que el modelo de aprendizaje automático aplicado a la agricultura de precisión presenta una alta capacidad de estimación de la humedad del suelo cuando se incorpora variables ambientales y registro histórico. En el mismo estudio se reconoce que la adecuada selección de variables influye de manera directa en el desempeño predictivo del modelo, esto resulta consistente con la arquitectura desarrollada, pues la humedad del suelo y la temperatura constituyen la variable principal para el entrenamiento y operación del algoritmo. Del mismo modo en el estudio de han et al. (2023) se evaluó que diversos algoritmos de aprendizaje automático para a producción de humedad del suelo demostrándose que los métodos de ensamble, sobre todo el Random Forest mantienen desempeño superior respecto de los modelos tradicionales por la capacidad que tienen para modelar relaciones no lineales y reducir errores de predicción, resultado importante en entornos agrícolas pues las variables ambientales muestran amplia variabilidad y comportamiento dinámico.

Kone et al. (2023) proponen el desarrollo de modelos avanzados en Deep Learning para predecir la humedad de los suelos a través de arquitecturas hídricas CNN-LSTM, estos modelos a pesar de ser precisos requieren de mayor capacidad tecnológica y grandes volúmenes de datos para su implementación, ante esta afirmación la selección de Random Forest representó la alternativa técnica adecuada para entornos agrícolas rurales, pes ofrece equilibrio favorable de precisión, complejidad tecnológica y facilidad de implementación en plataformas embebidas.

El modelo predictivo integrado al sistema de control que gobierna la activación de electroválvulas automáticamente se alinea al aporte de Cabay y Pachana (2023) que en su estudio demostraron que implementar un

sistema inteligente de riego en sensores, IoT y Random Forest favorece la optimización del consumo de agua y mantenimiento de un niel adecuado de humedad de suelo. De otro lado Santa Rosa (2024) demostraron que la implementación de algoritmos mejora de manera significativa la capacidad de predicción de variables hidráulicas asociadas a una efectiva gestión del agua en sistemas agrícolas, los resultados de ambos estudios confirman el potencial del uso de IA como herramienta que apoya positivamente la toma de decisiones respecto de la eficiente distribución del agua.

Teóricamente, el aporte de Gerón (2022) propone que los algoritmos de ensamble representan múltiples opciones de decisión y combinan resultados para generar predicciones precisas y estables, reduciendo el riesgo de sobreajuste y mejorando la capacidad de generalizar el modelo ante nuevos datos. De otro lado Benos et al. (2021) sostiene que incorporar en agricultura las técnicas de Machine Learning permite que se transforme grandes volúmenes de datos en conocimiento valioso en la optimización de procesos productivos y fortalecimiento de la sostenibilidad de sistemas agrícolas.

Se reafirma que el uso de modelos de inteligencia artificial no solo debe ser aplicados a funciones de monitoreo y análisis estadístico, sino que representa aportes importantes en el ciclo de control de sistemas de riego.

La tercera hipótesis especifica planteó que el sistema de riego inteligente basado en IA adaptativa mantiene condiciones adecuadas de humedad del suelo usando menor tiempo de riego respecto a un sistema de riego convencional. Los resultados obtenidos en el periodo experimental permiten confirmar esta hipótesis, ya que se evidencia una reducción significativa de agua y mayor estabilidad de humedad del suelo respecto al sistema convencional evaluado en las mismas condiciones de operación. Los resultados muestran que el sistema inteligente presenta un consumo promedio diario de agua por debajo del sistema convencional, evidenciado una reducción de 31% aproximadamente del volumen total usado en 45

días de evaluación, se observó además una reducción de la frecuencia de activación de eventos de riego, puesto que el algoritmo identificó los momentos en los que el contenido hídrico del suelo se hallaba en rangos adecuados para cultivar, como consecuencia se evitó riesgos innecesarios y se optimizó el so del recurso hídrico disponible.

Desde un enfoque de perspectiva agronómica, reducir el consumo de agua representa un indicador principal de eficiencia en sistemas agrícolas de precisión. La FAO (2024) afirma que el uso eficiente de agua es uno de los mayores desafíos para la sostenibilidad de sistemas productivos agrícolas pues se ha incrementado la demanda hídrica y por los efectos del cambio climático respecto a la disponibilidad del recurso. Similar al aporte de Cabay y Pachana (2023) quienes al implementar un sistema de riego automatizado basado en Random Forest y sensores de humedad del suelo optimizaron la aplicación de agua y mantuvieron condiciones eficientes de humedad a través de procesos automatizados, del estudio se interpreta también que al incorporar algoritmo automatizados se reduce de manera significativa el desperdicio de agua y no se afecta las condiciones de desarrollo del cultivo.

Jiménez et al. (2023) reporta que el uso de sistemas inteligentes para la gestión hídrica faculta generar recomendaciones de riego más precisas respecto a condiciones reales de suelo y cultivo, se observó además una reducción de eventos de exceso hídrico y una mejora en la eficiencia global del sistema de riego. Estos hallazgos son consistentes con los resultados logrados en Andajes, puesto que el modelo productivo permite la reducción de activaciones no necesarias de las electroválvulas y conservar la humedad en un rango operativo adecuado. Del mismo modo Togneri et al. (2022) demostró en su estudio que un modelo predictivo basado en Machine Learning anticipa las necesidades hídricas de un cultivo de manera más precisa que un sistema convencional; los autores afirman que la capacidad de predecir la evolución de humedad del suelo representa un elemento cave que mejora la eficiencia de riego y minimiza el consumo de

agua. Al igual que en el estudio desarrollado el algoritmo se ajustó dinámicamente en tipos de riego respecto a las condiciones de tiempo real.

Kim et al. (2024) afirman que un modelo predictivo aplicado a la agricultura de precisión no solo permite la reducción de uso de agua, sino que estabiliza el contenido hídrico del suelo entre rangos óptimos para el desarrollo agrícola. Estos resultados experimentales demuestran comportamiento similar pues la variación diaria de humedad en el suelo es considerablemente menor en el sistema inteligente sobre el convencional, por lo que se muestra mayor estabilidad del ambiente radicular.

Los estudios desarrollados en la realdad peruana, como el de Cañazaca (2024) reportó que los sistemas automatizados se basan en sensores que aportan a mantener niveles correctos de humedad y mejorar la eficiencia del riego respecto a un método tradicional, pero también evidencia que el uso de estrategias de control basadas en umbrales fijos anticipa las necesidades futuras de riego, siendo capaces de adaptarse ante variaciones ambientales. Del mismo modo el estudio de Mendoza y Pérez (2024) sostiene que la automatización de riego a través de sensores reduce el desperdicio de agua y mejora la eficiencia operativa del sistema. Entonces, se reafirma que la integración de IA genera beneficios adicionales al permitir que las decisiones de riego dependan del comportamiento dinámica de variables monitoreadas y no únicamente de condiciones antes programadas.
Los resultados se alinean además con lo que aporta Dueñas y Ruesta (2022) para quienes mejorar la distribución de agua se logra a través de la implementación de tecnología IoT. Es decir que el sistema desarrollado en la investigación incorpora una capa adicional de inteligencia basada en Machine Learning para fortalecer la adaptación ante escenarios de variabilidad climática.

Un aspecto que no se debe dejar de lado es que no solo la reducción del consumo de agua se mejoró, sino que la variabilidad registrada en la

humedad del suelo sugiere que los sistemas inteligentes contribuyan a mantener condiciones estables para el desarrollo radicular de cultivos. En diversos estudios se ha demostrado que las fluctuaciones extremas de humedad generan estrés hídrico y afectan de manera negativo el crecimiento vegetal, por lo que se debe mantener rangos estables que constituyen un indicador adicional de eficiencia en agricultura y sostenibilidad productiva.

Si se observa desde el enfoque de la ingeniería electrónica aplicada a agricultura, estos resultados demuestran que integrar sensores, sistemas embebidos y algoritmos de aprendizaje automática desarrollan sistemas de control capaces de adaptarse de manera dinámica a condiciones del entorno, se optimice el uso de recursos sin que se incremente significativamente la complejidad del sistema.

Para cerrar la discusión, nos enfocamos en analizar la hipótesis general, que planteó que el diseño de un sistema de riego inteligente basado en IA adaptativa permite reducir de manera significativa el consumo de agua t mejorar la eficiencia hídrica respecto al riego tradicional en el distrito de Andajes, provincia de Churín en Lima. Los resultados experimentales permiten confirmar logrados en los 45 días de observación permitieron aceptar esta hipótesis, evidenciando que integrar sensores ambientales, procesamiento embebido y modelo de aprendizaje automático genera un sistema efectivo para optimizar la aplicación del recurso hídrico a través de decisiones dinámicas fundamentales en datos obtenidos en tiempo real.

Los resultados muestran una reducción aproximada de 31% del volumen total de agua usada respecto a un sistema convencional, acompañada de amenorar el tiempo diario de riego y menor frecuencia de activación de las electroválvulas. A la par el sistema mantuvo la humedad del suelo dentro del rango objetivo durante un mayor porcentaje del tiempo experimental, lo que demuestra que la reducción del consumo hídrico no compromete el desarrollo del cultivo.

Estos resultados se sostienen en el estudio de Togneri et al. (2022) que demostraron que los modelos predictivos basados en aprendizaje automático estiman con precisión las necesidades hídricas de los cultivos usando información de os sensores IoT. Igual que el estudio de Kim et al. (2024) para quien la integración de variables ambientales con algoritmos predictivos mejora la previsión en la estimación de humedad del suelo, favoreciendo la gestión eficiente del agua. Los resultados del estudio confirman los planteamientos, además incorporan valor experimental del modelo bajo condiciones reales de cultivo en la localidad de Andajes. Se alinea también el estudio de Jiménez et al. (2023) que demostraron que integrar sensores inalámbricos y sistemas inteligentes mejorar la gestión de riego y genera recomendaciones basadas en el estado hídrico del cultivo.

Desde un enfoque conceptual, los hallazgos se respaldan en los principios de agricultura de precisión, que para Benos et al. (2021), el uso de técnicas de Machine Learning transforma grandes cantidades de datos agrícolas en decisiones operativas que incrementan tanto la eficiencia como la sostenibilidad. Complementariamente, Géron (2022) menciona que los algoritmos de tipo ensemble tienen una alta capacidad de generalización gracias a la fusión de varios árboles de decisión, lo que explica la consistencia observada en el comportamiento del modelo a lo largo del periodo experimental.

Bajo el mismo enfoque, la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO, 2024) indica que uno de los retos más importantes de la agricultura actual es aumentar la eficiencia en el uso del agua mediante tecnologías que se adapten a un clima cada vez más variable. En este sentido, los resultados obtenidos son especialmente significativos para regiones altoandinas como Andajes, donde la disponibilidad de agua es escasa y las decisiones de riego siguen dependiendo en gran medida de la experiencia práctica del agricultor.

Desde la mirada de Ingeniería Electrónica, el aporte principal de esta

investigación no solo se centra en la creación de un algoritmo predictivo, sino en la combinación efectiva de tecnologías de sensado, procesamiento integrado, aprendizaje automático y control hidráulico en una estructura modular que funciona en tiempo real. Esta fusión permitió convertir información del entorno en acciones automáticas de control, mostrando la viabilidad de implementar soluciones de agricultura inteligente a través de plataformas tecnológicas accesibles y con posibilidad de escalabilidad hacia explotaciones más grandes.

De los aportes más destacados del estudio es evidenciar que la inclusión de inteligencia artificial en los sistemas de riego no debe verse solo como un recurso para mejorar la exactitud de las predicciones, sino también como un medio para promover la sostenibilidad de los sistemas agrícolas mediante un uso más eficiente del agua. En áreas donde el cambio climático aumenta la incertidumbre sobre la disponibilidad de este recurso, este tipo de soluciones ofrece una alternativa tecnológica con el potencial de mejorar la seguridad alimentaria y la resiliencia de los sistemas productivos rurales.

Los hallazgos que respaldan la hipótesis general de la investigación demuestran que el diseño y la implementación del sistema de riego inteligente basado en inteligencia artificial adaptativa mejoraron significativamente la eficiencia del uso del agua en comparación con el sistema tradicional. Esta mejora se basa en la integración de una robusta arquitectura electrónica, un modelo predictivo de Machine Learning y un sistema de control automático capaz de reaccionar dinámicamente a las condiciones reales del cultivo, constituyendo una propuesta técnicamente viable para su futura adopción en sistemas agrícolas de pequeña y mediana escala.

CAPITULO VII:
CONCLUSIONES

Conclusiones

Primera: Se diseño e implementó satisfactoriamente la arquitectura tecnológica integrada por sensores de humedad de suelo, de temperatura ambiental, microcontrolador Arduino, sistema embebido Nvidia Jetson Orin Nano y electroválvulas para el control de riego por goteo. A partir de la arquitectura se adquiere una secuencia se de datos, procesamiento en tiempo real, ejecución automática de decisiones de control y se demuestra el funcionamiento estable en el periodo experimental.

Segunda: La implementación del modelo Random Forest permitió analizar el comportamiento de la humedad de suelo y temperatura ambiental para estimar los requerimientos hídricos del cultivo de manera precisa. Las métricas de desempeño logradas (R^2 = 0,91; MAE = 1,84 % y RMSE = 2,47 %) permiten reconocer una correcta capacidad de predicción del modelo, ajustando de manera dinámica los tiempos y frecuencia de riego.

Tercera: A través de la evaluación experimental se demostró que el sistema inteligente reduce en promedio 31% del consumo de agua respecto a un sistema convencional, reduce el tiempo de riego y la frecuencia de activación de las electroválvulas, sin que se afecte la estabilidad de la humedad del suelo, evidenciando una mejora significativa en la eficiencia hídrica del sistema.

Cuarta: La integración de sensores ambientales, procesamiento embebido y modelo de IA como componentes de una arquitectura de control permite desarrollar un sistema de riego inteligente que optimiza el uso del recurso

hídrico en condiciones reales de cultivo en el distrito de Andajes. Este resultado confirma que la solución propuesta supera el desempeño de un sistema de riego convencional.

Quinta: Se demostró la viabilidad técnica de integración de algoritmos Machine Learning en un sistema embebido aplicado al control automático de riego en agricultura, diverso a un sistema tradicional que se basa en un programa fijo de umbrales predeterminados.

CAPITULO VIII:
RECOMENDACIONES

Recomendaciones

Ampliar en posteriores investigaciones el periodo de evaluación experimental en diversas estaciones del año, para incorporar condiciones climáticas de contraste que permitan comparaciones y análisis de comportamientos del modelo de inteligencia artificial respecto a una mayor variabilidad ambienta y el fortalecimiento de su capacidad de generalización.

Incorporar nuevas variables de entrada al modelo predictivo, como velocidad de viento, radiación solar, precipitaciones, entre otras a fin de incrementar la previsión de la predicción y optimización de las decisiones de riego.

Implementar la plataforma IoT para el almacenamiento y visualización remota de la información generada por el sistema, permitiendo que se monitoree continuamente los cultivos mediante aplicaciones web o dispositivos móviles, además de poder generar alertas automáticas para los agricultores.

Validar el sistema propuesto en cultivos de mayor extensión y diversas regiones agroecológicas del Perú, a fin de evaluar la escalabilidad, robustez y adaptabilidad ante diversas condiciones edafoclimáticas y necesidades hídricas.

Desarrollar nuevas investigaciones en los que se integre modelos predictivos de demanda hídrica con imágenes obtenidas a través de drones

o cámaras multiespectrales, que combinen visión artificial y aprendizaje automático, esto permitirá fortalecer la agricultura de precisión y mejorar la toma de decisiones en la misma.

CAPITULO IX:
BIBLIOGRAFÍA

Abbassi, T. E., Sahour, A., Benkherrat, M., & Brai, S. (2026). *Machine learning-based soil moisture prediction using meteorological data for enhanced irrigation management*. E3S Web of Conferences, 699, 03005. https://doi.org/10.1051/e3sconf/202669903005

Adeyemi, R., Yan, H., & Li, X. (2023). *Application of machine learning models for soil moisture prediction in smart irrigation systems*. Agricultural Water Management, 276, 108047. https://doi.org/10.1016/j.agwat.2022.108047

Adli, H. K., Remli, M. A., Wong, K. N. S. W. S., Ismail, N. A., González-Briones, A., Corchado, J. M., & Mohamad, M. S. (2023). *Recent Advancements and Challenges of AIoT Application in Smart Agriculture: A Review*. Sensors, 23(7), 3752. https://doi.org/10.3390/s23073752

Alexander, C. K., & Sadiku, M. N. O. (2016). Fundamentals of Electric Circuits. McGraw-Hill Education.

Assessment of a Spatiotemporal Deep Learning Approach for Soil Moisture Prediction and Filling the Gaps in Between Soil Moisture Observations ElSaadani, M. E., Habib, E., Abdelhameed, A. M., & Bayoumi, M. (2021). Assessment of a spatiotemporal deep learning approach for soil moisture prediction and filling the gaps in between soil moisture observations. *Frontiers in Artificial Intelligence, 4*, 636234. https://doi.org/10.3389/frai.2021.636234

Autoridad Nacional del Agua. (2020). *Gestión integrada de los recursos*

hídricos en el Perú. https://www.ana.gob.pe/

Babar, A. Z., & Akan, O. B. (2024). *Sustainable and Precision Agriculture with the Internet of Everything (IoE)*. arXiv. https://doi.org/10.48550/arXiv.2404.06341

Bello-Pavón, J. F., García-Montoya, K. E., & Lacayo-Arauz, K. A. (2021). Sistema de riego por goteo automatizado y sostenible en zonas rurales de Nicaragua. *Tecnología en Marcha, 34*(Especial LAEDC 2021), 23–30. https://doi.org/10.18845/tm.v34i6.5970

Benítez Baltazar, V. H. (2024). *Introducción a los sistemas embebidos*. Universidad de Sonora.

Benos, L., Tagarakis, A. C., Dolias, G., Berruto, R., Kateris, D., & Bochtis, D. (2021). *Machine learning in agriculture: A comprehensive updated review*. Sensors, 21(11), 3758. https://doi.org/10.3390/s21113758

Cabay Yanqui, E. F., & Panchana Merchán, K. J. (2023). *Sistema de riego inteligente usando Machine Learning* (Trabajo de titulación). Escuela Superior Politécnica del Litoral, Ecuador.

Camacho, E., & González, F. (2023). *La agricultura y la ganadería ante el reto del cambio climático: innovación y emprendimiento para un progreso sostenible*. En Fundación de Estudios Rurales (Ed.), *Anuario de la agricultura y ganadería familiar 2023*. Unión de Pequeños Agricultores y Ganaderos (UPA). https://www.upa.es/Anuario2023/024-Anuario-2023-Camacho-Gonzalez.pdf

Cañazaca Limachi, B. A. (2024). *Diseño e implementación de un sistema de control de riego tecnificado por goteo automatizado para la finca Patascachi en el distrito de Tilali - Moho* [Tesis de pregrado, Universidad Nacional del Altiplano]. Repositorio Institucional UNAP. https://repositorio.unap.edu.pe/handle/20.500.14082/22480

Dueñas Vara, O. I., & Ruesta Revoredo, P. O. (2022). *Aplicación IoT para un sistema de control de riego de pitahaya para la zona de cultivo del distrito de Chancay* [Tesis de pregrado, Universidad César Vallejo]. Repositorio Institucional UCV. https://hdl.handle.net/20.500.12692/112890

ElSaadani, M. E., Habib, E., Abdelhameed, A. M., & Bayoumi, M. (2021). Assessment of a spatiotemporal deep learning approach for soil moisture prediction. Frontiers in Artificial Intelligence, 4, 636234. https://doi.org/10.3389/frai.2021.636234

Espinoza Calderón, J. (2021). *Diseño e implementación de un sistema de riego automatizado basado en sensores de humedad del suelo y temperatura* [Tesis de pregrado, Universidad Nacional Jorge Basadre Grohmann]. Repositorio Institucional UNJBG. https://repositorio.unjbg.edu.pe/

FAO. (2021). *The State of the World's Land and Water Resources for Food and Agriculture – Systems at breaking point (SOLAW 2021)*. Food and Agriculture Organization of the United Nations. https://doi.org/10.4060/cb7654en

Food and Agriculture Organization of the United Nations (FAO). (2024). *The State of Food and Agriculture 2024: Value-driven transformation of agrifood systems*. FAO.

Géron, A. (2022). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow* (3rd ed.). O'Reilly Media.

Han, Q., Zeng, Y., Zhang, L., Cira, C. I., Prikaziuk, E., Duan, T., Wang, C., Szabó, B., Manfreda, S., Zhuang, R., & Su, B. (2023). *Ensemble of optimised machine learning algorithms for predicting surface soil moisture content at a global scale*. Geoscientific Model Development, 16, 5825–5845. https://doi.org/10.5194/gmd-16-5825-2023

Improving soil moisture prediction with deep learning and machine learning models. (2024). Computers and Electronics in Agriculture, 226, 109414. https://doi.org/10.1016/j.compag.2024.109414

Instituto Nacional de Innovación Agraria. (2020). *Tecnologías de riego para la agricultura peruana*. https://www.inia.gob.pe/

International Renewable Energy Agency (IRENA) & Food and Agriculture Organization (FAO). (2021). *Renewable energy for agri-food systems: Towards the Sustainable Development Goals and the Paris Agreement*. IRENA.

Javaid, M., Haleem, A., Singh, R. P., Khan, S., & Suman, R. (2023). Artificial intelligence applications for Industry 4.0: A literature-based study. *Journal of Industrial Integration and Management, 8*(1), 1–28.

Jiménez, A., Velásquez, F., & Puente, S. (2023). Sistema inteligente de prescripción de riego agrícola basado en redes de sensores y modelado de cultivos. *Visión Electrónica, 17*(1), 1-15.

Jovanovic, N., Pereira, L. S., Paredes, P., Pôças, I., Cantore, V., & Todorovic, M. (2020).
A review of strategies, methods and technologies to reduce non-beneficial consumptive water use on farms considering the FAO56 methods.
Agricultural Water Management, 239, 106267.

Kim, S., Evans, R. G., & Iversen, W. M. (2024). Soil moisture prediction using machine learning for precision irrigation. Computers and Electronics in Agriculture, 216, 108575.
https://doi.org/10.1016/j.compag.2023.108575

Klerkx, L., & Rose, D. C. (2024). Dealing with the game-changing technologies of Agriculture 4.0: How do we manage diversity and responsibility in food system transition pathways? *Global Food*

Security, 40, 100734. https://doi.org/10.1016/j.gfs.2023.100734

Koné, B. A. T., Grati, R., Bouaziz, B., & Boukadi, K. (2023). *A new long short-term memory based approach for soil moisture prediction*. Applied Intelligence, 15(3). https://doi.org/10.3233/AIS-230035

Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2020). *Machine learning in agriculture: A review*. Sensors, 20(10), 1–29. https://doi.org/10.3390/s20102861

Machine Learning in Agriculture: A Comprehensive Updated Review Benos, L., Tagarakis, A. C., Dolias, G., Berruto, R., Kateris, D., & Bochtis, D. (2021). Machine learning in agriculture: A comprehensive updated review. *Sensors, 21*(11), 3758. https://doi.org/10.3390/s21113758

Mendoza Soto, A. B., & Pérez Guevara, M. E. (2024). *Propuesta de un sistema de riego automatizado por microaspersión para las áreas verdes de la Universidad Nacional de Jaén* [Tesis de pregrado, Universidad Nacional de Jaén]. Repositorio Institucional UNJ.

Ministerio de Desarrollo Agrario y Riego. (2025). *Inteligencia artificial en el sector agrario*. https://repositorio.midagri.gob.pe/bitstream/20.500.13036/2056/1/Inteligencia-artificial-en-el-sector-agrario.pdf

Ministerio del Ambiente. (2021). *Estado del ambiente en el Perú 2021*. https://www.minam.gob.pe/

Montesinos López, O. A. (2024). *Inteligencia artificial en agricultura: Beneficios, desafíos y tendencias* [Presentación en PowerPoint]. ResearchGate. https://www.researchgate.net/publication/381341917_Inteligencia_Artificial_IA_en_Agricultura

NVIDIA. (2024). *Jetson Nano Developer Kit User Guide*. NVIDIA Corporation. https://developer.download.nvidia.com/

OECD & Food and Agriculture Organization of the United Nations. (2022). *OECD-FAO Agricultural Outlook 2022–2031*. OECD Publishing. https://doi.org/10.1787/f1b0b29c-en

Online MPC irrigation control using ML-based soil moisture prediction. (2026). Control Engineering Practice. https://doi.org/10.1016/j.conengprac.2026.106975

Ordoñez Huamán, Y. J., & Cieza Quispe, Y. D. (2024). *Diseño de un sistema de control automatizado mediante tecnología Arduino para el riego del vivero de la Municipalidad Provincial de Jaén – Perú* [Tesis de pregrado, Universidad Nacional de Jaén]. Repositorio Institucional UNJ.

Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2024). *Estrategia de la FAO sobre el cambio climático 2022–2031*. FAO.

Ortiz Hernández, A., & Mendoza Pérez, M. A. (2024). Propuesta de desarrollo de un sistema de riego inteligente, utilizando tecnología Pyboard. *Desarrollo Sustentable, Negocios, Emprendimiento y Educación, 6*(53), 31-42. https://doi.org/10.51896/rilcods.v6i53.473

Patiño Perdomo, O. F., Balanta Martínez, V. J., Patiño Perdomo, W. A., Pinto Lopera, J. E., & Sánchez Orozco, P. A. (2025). *Inteligencia artificial en la agricultura de precisión: Tendencias y direcciones futuras*. RIVAR, 12(37), 251–267. https://doi.org/10.35588/mwfneb13

Ranasinghe, R. y otros (2021), “Climate change information for regional impact and for risk assessment”, Climate Change 2021: The Physical Science Basis. Working Group I Contribution to the Sixth Assessment Report of the Intergovernmental Panel on Climate

Change, V. Masson-Delmotte y otros (eds.), Cambridge University Press, Grupo Intergubernamental de Expertos sobre el Cambio Climático (IPCC).

Santa Rosa Mañuico, L. S. (2024). *Desarrollo de un modelo predictivo de conductividad hidráulica para optimizar el sistema de riego Laguna Huanzo, distrito de Santiago, provincia de Huanca Sancos, Ayacucho* [Tesis de pregrado, Universidad Nacional de San Cristóbal de Huamanga]. Repositorio Institucional UNSCH.

Togneri, R., Santos, D. F., Camponogara, G., & Nagano, H. (2022). *Soil moisture forecast for smart irrigation: The primetime for machine learning*. Expert Systems with Applications, 207, 117653. https://doi.org/10.1016/j.eswa.2022.117653

Tovar-Quiroz, A. D. (2023). *Agricultura 4.0: uso de tecnologías de precisión y aplicación para pequeños productores*. Informador Técnico, 87(2), 195–211. https://doi.org/10.23850/22565035.5536

UNESCO. (2023). *United Nations World Water Development Report 2023: Partnerships and cooperation for water*. United Nations Educational, Scientific and Cultural Organization.

UNESCO. (2024). *The United Nations World Water Development Report 2024: Water for Prosperity and Peace*. UNESCO Publishing.

United States Geological Survey (USGS). (2023). *Groundwater depletion in agricultural regions*.

Vallejo-Gómez, D., Osorio, M., & Hincapié, C. A. (2023). *Smart Irrigation Systems in Agriculture: A Systematic Review*. Agronomy, 13(2), 342. https://doi.org/10.3390/agronomy13020342

World Resources Institute (WRI). (2022). *Aqueduct Water Risk Atlas*.

Yadav, D., Gangwar, S. P., Verma, G., Mishra, A. K., Srivastava, R. K., & Srivastava, S. K. (2024). *IoT and machine learning-based prediction*

of smart soil moisture monitoring and irrigation system. International Journal on Recent and Innovation Trends in Computing and Communication.

CAPITULO X:
ANEXOS

Anexo A

Evidencia fotográfica del estudio



Figura A.1. Imagen que muestra una instalación de sistema de riego por goteo tradicional.



Figura A.2. Imagen que muestra una instalación de sistema de riego por goteo con IA

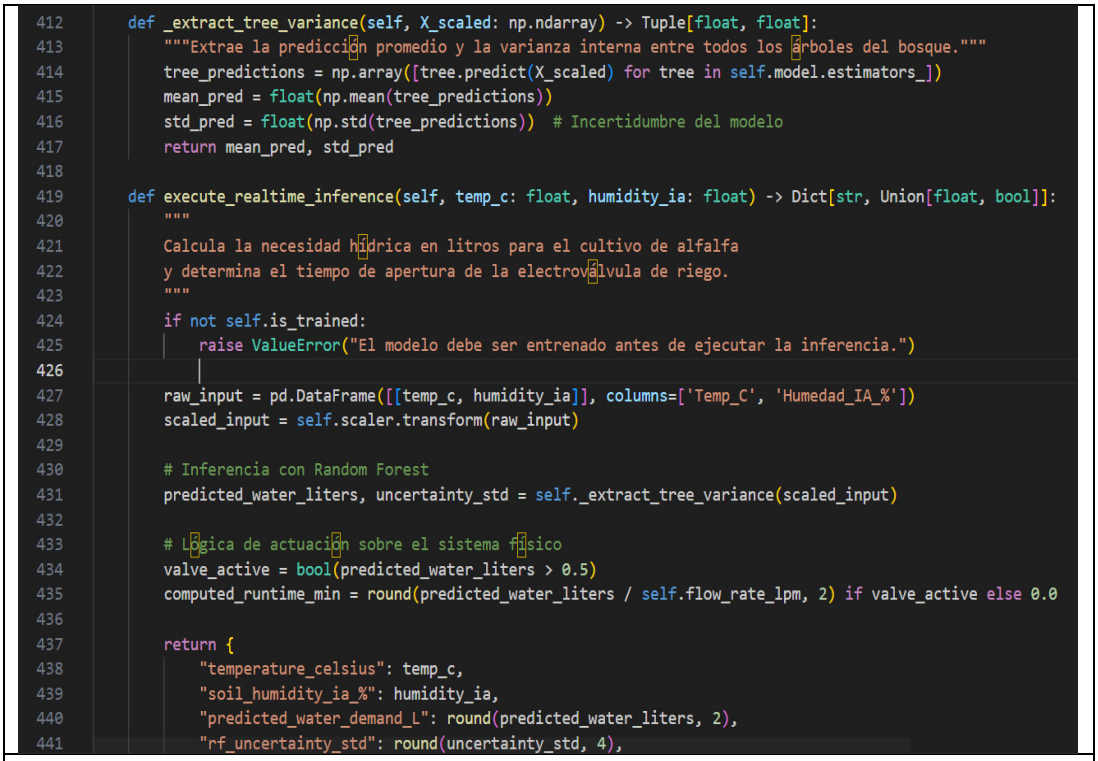

```python
    def _extract_tree_variance(self, X_scaled: np.ndarray) -> Tuple[float, float]:
        """Extrae la predicción promedio y la varianza interna entre todos los árboles del bosque."""
        tree_predictions = np.array([tree.predict(X_scaled) for tree in self.model.estimators_])
        mean_pred = float(np.mean(tree_predictions))
        std_pred = float(np.std(tree_predictions))  # Incertidumbre del modelo
        return mean_pred, std_pred

    def execute_realtime_inference(self, temp_c: float, humidity_ia: float) -> Dict[str, Union[float, bool]]:
        """
        Calcula la necesidad hídrica en litros para el cultivo de alfalfa
        y determina el tiempo de apertura de la electroválvula de riego.
        """
        if not self.is_trained:
            raise ValueError("El modelo debe ser entrenado antes de ejecutar la inferencia.")

        raw_input = pd.DataFrame([[temp_c, humidity_ia]], columns=['Temp_C', 'Humedad_IA_%'])
        scaled_input = self.scaler.transform(raw_input)

        # Inferencia con Random Forest
        predicted_water_liters, uncertainty_std = self._extract_tree_variance(scaled_input)

        # Lógica de actuación sobre el sistema físico
        valve_active = bool(predicted_water_liters > 0.5)
        computed_runtime_min = round(predicted_water_liters / self.flow_rate_lpm, 2) if valve_active else 0.0

        return {
            "temperature_celsius": temp_c,
            "soil_humidity_ia_%": humidity_ia,
            "predicted_water_demand_L": round(predicted_water_liters, 2),
            "rf_uncertainty_std": round(uncertainty_std, 4),
```

Figura A.3. Fragmento del código en Python que implementa la inferencia en tiempo real y el cálculo de la varianza del modelo Random Forest para estimar la demanda hídrica en la parcela de alfalfa

Anexo B
Data Sheet

Especificaciones	
Velocidad del reloj	12 MHz
Memoria flash	256 KB, (8 KB utilizados para gestor de arranque)
Memoria SRAM	8 KB
Memoria EEPROM	4 KB
Voltaje de operación	5 VCD
Voltaje de entrada	7 - 12 VCD
Pines de E/S digitales	54 (15 proporcionan salida PWM)
Pines de salidas analógicas	16
Corriente de CD por pin de E/S	40mA
Corriente de CD para el pin de 3.3V	50mA
Peso	37 g
Dimensiones	101.52 mm x 53.3 mm

Figura B.1. Data Sheet de Arduino Mega

NVIDIA Jetson Orin Nano Modules:

- Jetson Orin Nano 8GB (ON 8GB) - Ampere GPU + ARM Cortex-A78AE CPU + 8GB LPDDR5
- Jetson Orin Nano 4GB (ON 4GB) - Ampere GPU + ARM Cortex-A78AE CPU + 4GB LPDDR5

References to ON and Jetson Orin Nano can be read as Jetson Orin Nano 8GB and Jetson Orin Nano 4GB except where explicitly noted.

AI Performance

Jetson Orin Nano 8GB: Up to 40 (Sparse) INT8 TOPs and 20 (Dense) INT8 TOPs

Jetson Orin Nano 4GB: Up to 20 (Sparse) INT8 TOPs and 10 (Dense) INT8 TOPs

Ampere GPU

Jetson Orin Nano 8GB: 1024 NVIDIA® CUDA® cores | 32 Tensor cores

Jetson Orin Nano 4GB: 512 NVIDIA® CUDA® cores | 16 Tensor cores

End-to-end lossless compression | Tile Caching | OpenGL® 4.6 | OpenGL ES 3.2 | Vulkan™ 1.1[0] | CUDA 10

Maximum Operating Frequency: 625 MHz

ARM Cortex-A78AE CPU

Six-core (ON 8GB and ON 4GB) Cortex A78AE ARMv8.2 (64-bit) heterogeneous multi-processing (HMP) CPU architecture | 2x clusters (1x 4-core cluster + 128 KB L1 + 256KB L2 per core + 2MB L3) + 1x 2-core cluster (128 KB L1 + 256KB L2 per core + 2MB L3) | System Cache: 4 MB (shared across all clusters)

Audio

Dedicated programmable audio processor | ARM Cortex A9 with NEON | PDM in/out | Industry-standard High-Definition Audio (HDA) controller provides a multi-channel audio path to the HDMI® interface

Memory

ON 8GB: 8GB 128-bit LPDDR5 DRAM
ON 4GB: 4GB 64-bit LPDDR5 DRAM

Secure External Memory Access Using TrustZone® Technology | System MMU | Maximum Operating Frequency: 2133 MHz

Networking

10/100/1000 BASE-T Ethernet | Media Access Controller (MAC)

Imaging

Eight lanes MIPI CSI-2 | D-PHY 2.1 (20 Gbps)

Display Controller

1x4K30 DP 1.2 (+MST for 2x 1080p60), HDMI 1.4, eDP 1.4

*See the Display section for more details on additional compatibility to DP 1.4a and HDMI 2.1

Maximum Resolution (eDP/DP/HDMI): up to 3840x2160 at 30 Hz

Multi-Stream HD Video and JPEG

Video Decode:

- Standards supported: H.265 (HEVC), H.264, VP9, AV1
  - 1x4K60 (H.265)
  - 2x4K30 (H.265)
  - 5x1080p60 (H.265)
  - 11x1080p30 (H.265)

Video Encode:

- 1080p30 Supported via CPU Cores with Software

Peripheral Interfaces

xHCI host controller with integrated PHY (up to) 3x USB 3.2, 3x USB 2.0 | 3 x1 (or 1 x2 + 1 x1) + 1 x4 (GEN3) PCIe | 3x UART | 2x SPI | 4x I^2C | 1x CAN | DMIC | DSPK | 2x I^2S | 15x GPIOs

Storage

Supports External Storage (NVMe)

Mechanical

Module Size: 69.6 mm x 45 mm | 260 pin SO-DIMM Connector

Operating Requirements
Temp. Range (T_J)*: -25°C – 90°C | Supported Power Input: 5V – 20V
Jetson Orin Nano 8GB Modes: 7W | 15W
Jetson Orin Nano 4GB Modes: 5W | 10W

Figura B.2. Data Sheet de Jetson Orin Developer Nano

Anexo C
Matriz de Consistencia

Problemas	Objetivos	Hipótesis	Variables e indicadores	Metodología
Problema General: ¿Cómo el diseño e implementación de un prototipo de sistema de riego inteligente basado en inteligencia artificial adaptativa y el uso de sensores de humedad del suelo y temperatura ambiental permite superar la ineficiencia del riego tradicional y optimizar el uso del recurso hídrico en cultivos del distrito de Andajes, provincia de Churín, en el año 2026?	**Objetivo General:** Diseñar, implementar y evaluar experimentalmente un prototipo de sistema de riego inteligente basado en inteligencia artificial adaptativa, que permita optimizar el uso del recurso hídrico mediante el análisis de variables de humedad del suelo y temperatura ambiental en cultivos del distrito de Andajes, provincia de Churín, en el año 2026.	**Hipótesis General:** El diseño e implementación de un prototipo de sistema de riego inteligente basado en el algoritmo de inteligencia artificial Random Forest y el procesamiento embebido en borde reduce significativamente el consumo de agua (superando un 25% de ahorro) y estabiliza la humedad del suelo en comparación con el riego por goteo convencional en el cultivo de la parcela experimental en Andajes.	**VARIABLE INDEPENDIENTE (X):** • *Sistema de Riego Inteligente basado en IA Adaptativa* **Dimensiones e Indicadores:** 1. *Monitoreo ambiental:* • Temperatura ambiental (°C) • Humedad relativa del aire (%) • Humedad volumétrica del suelo (%) • Frecuencia de activación de electroválvulas (ciclos/día) • Tiempo de riego programado (min)	**Tipo y Nivel de Investigación:** • *Tipo:* Aplicada, tecnológica y cuantitativa. • *Nivel:* Explicativo - experimental. **Diseño de Investigación:** • Cuasi-experimental con diseño de control pretest-postest y grupo de control paralelo (Riego Convencional vs. Riego con IA). **Población y Muestra:** • *Población:* Parcelas de cultivo agrícola en la sierra del distrito de Andajes (Churín). • *Muestra:* Parcela experimental de 40 m² subdividida en dos sectores de 20 m² durante un período de evaluación continua de 45 días.

Problemas	Objetivos	Hipótesis	Variables e indicadores	Metodología
Problema Específico 1: ¿Cómo diseñar una arquitectura tecnológica adecuada que integre sensores de humedad del suelo, temperatura ambiental y actuadores hidráulicos en un prototipo de sistema de riego inteligente para las condiciones del distrito de Andajes?	**Objetivo Específico 1:** Diseñar una arquitectura tecnológica que integre sensores de humedad del suelo, temperatura ambiental, un sistema embebido y actuadores hidráulicos, adaptada a las condiciones del entorno de estudio.	**Hipótesis Específica 1:** La integración modular del sistema embebido NVIDIA Jetson Orin Nano, sensores capacitivos de suelo, sensores ambientales y electroválvulas de 12V permite la adquisición continuada de datos en tiempo real con un margen de fallo operativo menor al 1% en condiciones ambientales rurales.	**VARIABLE DEPENDIENTE (Y):** • *Eficiencia en el Uso del Recurso Hídrico y Desempeño Operativo* **Dimensiones e Indicadores:** 1. *Consumo Hídrico:* • Consumo acumulado de agua (Litros) • Consumo promedio diario (L/día) • Porcentaje de ahorro hídrico (%)	**Técnicas e Instrumentos de Recolección de Datos:** • *Técnicas:* Observación directa automatizada, registro continuo de telemetría y muestreo digital. • *Instrumentos:* Módulo de lectura de datos en Python, datalogger embebido en Jetson Orin Nano, sensores capacitivos de humedad, sensores DHT22/SHT31 y caudalímetros digitales de pulso.
Problema Específico 2: ¿Qué modelo de inteligencia artificial adaptativa es el más adecuado para analizar las variables de humedad y temperatura, permitiendo ajustar dinámicamente los tiempos y frecuencias de riego?	**Objetivo Específico 2:** Desarrollar e implementar un modelo de inteligencia artificial para predecir y ajustar los tiempos en función de la temperatura ambiental y humedad de suelo, mejorando la eficiencia operativa de sistema frente a esquemas tradicionales de riego.	**Hipótesis Específica 2:** El algoritmo de regresión basado en Random Forest Regressor alcanza una precisión predictiva con un $R^2 \geq 0.95$ y un RMSE ≤ 2.5 Litros, superando en adaptación y respuesta a los esquemas de control rígido o por umbrales fijos.	**VARIABLES DE CONTROL:** • Tipo de cultivo (Alfalfa - *Medicago sativa*). • Área física de la parcela (20 m²). • Tipo de emparcelado (Surcos y camas de siembra). • Tipo de emisor (Mangueras de goteo portagoteros con caudal nominal constante). • Tensión de alimentación y presión hidráulica del sistema.	**Métodos de Análisis Estadístico:** • *Estadística Descriptiva:* Promedio, desviación estándar, error típico y porcentajes de variación. • *Pruebas de Normalidad:* Test de Shapiro-Wilk para la verificación de distribución Gaussiana ($p > 0.05$). • *Estadística Inferencial / Contraste:* Prueba t de Student para muestras independientes (o Mann-Whitney U según

Problemas	Objetivos	Hipótesis	Variables e indicadores	Metodología
				distribución) para evaluar la diferencia significativa entre el consumo de agua (L) y la estabilidad de la humedad (%) entre ambos sistemas ($p < 0.05$).
Problema Específico 3: ¿Cómo diseñar el sistema de control para garantizar la adquisición de datos en tiempo real y la activación eficiente y confiable de las electroválvulas en el sistema de riego por goteo?	**Objetivo Específico 3:** Comparar el consumo de agua, la eficiencia hídrica y la estabilidad de la humedad del suelo entre el sistema de riego inteligente propuesto y un sistema de riego convencional mediante pruebas experimentales.	**Hipótesis Específica 3:** El sistema de control de lazo cerrado con decisiones generadas en la NVIDIA Jetson reduce en más de un 30% el tiempo total de apertura de las electroválvulas en comparación con el esquema convencional de programación fija, manteniendo la humedad del suelo dentro del rango óptimo.	*• Variable de Salida Físico-Mecánica: Estado ON/OFF de la electroválvula de 12V y tiempo total de riego (min).• Mecanismo de Acoplamiento: Relación directa entre la predicción hídrica del modelo Random Forest y la duración del ciclo del actuador hidráulico.*	***Protocolo de Prueba:*** *Muestreo comparativo continuo de 45 días mediante registro de flujo real (caudalímetros) y validación de tiempos de respuesta del sistema de control.*

Anexo D

Tabla D.1. **Base de datos (45 días)**

Dia	Temp_C	Humedad_Conv_%	Humedad_IA_%	Act_Conv	Act_IA	Tiempo_Conv_min	Tiempo_IA_min	Agua_Conv_L	Agua_IA_L	Ahorro_%
1	21.6	50	61	4	3	45	31	224	156	30.36
2	21.9	51	61	4	3	45	32	225	158	29.78
3	22.2	53	62	4	2	45	32	227	159	29.96
4	22.4	54	62	4	2	45	33	228	160	29.82
5	22.5	54	62	4	2	45	33	229	160	30.13
6	22.5	55	62	4	2	45	33	229	160	30.13
7	22.4	55	62	4	2	45	33	228	160	29.82
8	22.3	55	62	4	2	45	32	228	159	30.26
9	22.1	54	62	4	2	45	32	227	158	30.4
10	21.9	53	62	4	3	45	32	225	158	29.78
11	21.6	52	62	4	3	45	31	224	156	30.36
12	21.4	51	62	4	3	45	31	222	156	29.73
13	21.1	50	61	4	3	45	31	221	154	30.32
14	20.9	50	61	4	3	45	30	219	154	29.68
15	20.7	50	60	4	3	45	30	218	153	29.82
16	20.5	50	60	4	3	45	30	217	152	29.95
17	20.4	51	60	4	3	45	30	216	152	29.63
18	20.3	52	60	4	3	45	29	216	151	30.09
19	20.2	53	60	4	3	45	29	215	151	29.77
20	20.2	54	60	4	3	45	29	215	151	29.77
21	20.2	55	60	4	3	45	29	215	151	29.77
22	20.3	56	60	4	3	45	29	216	151	30.09
23	20.4	56	60	4	3	45	30	216	152	29.63
24	20.6	56	60	4	3	45	30	218	152	30.28
25	20.8	56	61	4	3	45	30	219	153	30.14

26	21	55	61	4	3	45	30	220	154	30
27	21.2	54	61	4	3	45	31	221	155	29.86
28	21.5	52	62	4	3	45	31	223	156	30.04
29	21.7	51	62	4	3	45	32	224	157	29.91
30	22	49	62	4	2	45	32	226	158	30.09
31	22.2	48	62	4	2	45	32	227	159	29.96
32	22.3	47	62	4	2	45	32	228	159	30.26
33	22.5	46	62	4	2	45	33	229	160	30.13
34	22.5	46	62	4	2	45	33	229	160	30.13
35	22.5	46	62	4	2	45	33	229	160	30.13
36	22.3	47	62	4	2	45	32	228	159	30.26
37	22.1	49	62	4	2	45	32	227	158	30.4
38	21.8	50	61	4	3	45	32	225	157	30.22
39	21.5	52	61	4	3	45	31	223	156	30.04
40	21.1	54	61	4	3	45	31	221	154	30.32
41	20.7	55	60	4	3	45	30	218	153	29.82
42	20.4	56	60	4	3	45	30	216	152	29.63
43	20	57	60	4	3	45	29	214	150	29.91
44	19.8	57	60	4	3	45	29	213	149	30.05
45	19.6	57	60	4	3	45	28	212	148	30.19