

**UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL DE
HUAMANGA**
FACULTAD DE INGENIERÍA DE MINAS, GEOLOGÍA Y CIVIL
ESCUELA PROFESIONAL DE INGENIERÍA CIVIL



“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 para optar el título profesional de:

Ingeniera Civil

Presentado por:

Bach. Linyan Shanny Santa Rosa Mañuico

Asesor:

Msc. Ing. Jaime Leonardo Bendezú Prado

Ayacucho - Perú

2024

DEDICATORIA

A Dios por bendecir mi camino y permitirme seguir logrando mis objetivos, a la memoria de mi abuela Micaela Velazque Arenas que desde el cielo siempre me guiara y cuidara. A mis padres; Agustín Santa Rosa Velazque y Julia Mañuico Huamani por su amor, apoyo incondicional y a mi hermano quien fue un verdadero amigo quien con sus ocurrencias y palabras de aliento me ayudaron a continuar sin desmayar en este proceso de mi formación académica.

AGRADECIMIENTOS

A mis Padres por estar ahí cuando más los necesite por su constante ayuda, motivación y cooperación.

A mi hermosa Universidad Nacional San Cristóbal de Huamanga, nuestra alma mater, y en especial a la escuela profesional de Ingeniería Civil, mi segunda casa, por haberme acogido en sus aulas durante mis años como estudiante.

Al Mcs.Ing. Jaime Leonardo Bendezú Prado por ser asesor del presente trabajo de investigación e ilustrarme con las pautas necesarias para su elaboración.

Al Ing.Rocky Escobar Bellido por brindarme principios técnicos para el desarrollo de la presente investigación y así mismo compartir sus conocimientos precisos de manera profesional e invaluable.

RESUMEN

El sistema de riego Laguna Huanzo en Santiago, provincia de Huanca Sancos, enfrenta retos en la administración del agua, debido a las variaciones de las propiedades del suelo y cambios climáticos. Para superar estos desafíos, se adoptaron modelos predictivos y algoritmos de aprendizaje automático, como la ecuación de Richards y el método K-NN, para optimizar la conductividad hidráulica y mejorar significativamente la eficiencia del riego. Un aspecto preocupante revelado por el estudio fue la variabilidad en la disponibilidad y distribución del agua, lo que resaltó la urgencia de adoptar enfoques más sofisticados en la gestión del recurso hídrico. Estas herramientas permitieron una mejora notable en la precisión de las predicciones de conductividad hidráulica, optimizando así la eficiencia del riego. La implementación de estas técnicas avanzadas ha resultado en una gestión más efectiva del agua, reduciendo las ineficiencias y potenciando la sostenibilidad del sistema de riego. La integración de la modelización matemática con el aprendizaje automático ha demostrado ser esencial para adaptarse a las complejidades hídricas del suelo, permitiendo estrategias de riego que se ajustan a las necesidades específicas de los cultivos y al clima variante. Este enfoque no solo ha permitido una administración más eficiente del agua, sino que también ha establecido un precedente para la implementación de soluciones innovadoras en la gestión de recursos hídricos en agricultura. A través de este proceso, se ha confirmado la importancia de integrar modelos predictivos y técnicas de optimización en la planificación y gestión del riego, preparando el sistema de riego Laguna Huanzo para enfrentar futuros desafíos con mayor resiliencia y sostenibilidad.

Palabras Claves: Agricultura, Algoritmos de aprendizaje automático K-NN, Conductividad hidráulica, Gestión del agua, Modelo matemático.

ABSTRACT

The Laguna Huanzo irrigation system in Santiago, Huanca Sancos province, faces water management challenges due to variations in soil properties and climatic changes. To overcome these challenges, predictive models and machine learning algorithms, such as the Richards equation and the K-NN method, were adopted to optimize hydraulic conductivity and significantly improve irrigation efficiency. A worrying aspect revealed by the study was the variability in water availability and distribution, which highlighted the urgency of adopting more sophisticated approaches to water resource management. These tools enabled a marked improvement in the accuracy of hydraulic conductivity predictions, thus optimizing irrigation efficiency. The implementation of these advanced techniques has resulted in more effective water management, reducing inefficiencies and enhancing the sustainability of the irrigation system. The integration of mathematical modeling with machine learning has proven essential in adapting to soil water complexities, enabling irrigation strategies that are tailored to specific crop needs and variant climate. This approach has not only allowed for more efficient water management, but has also set a precedent for the implementation of innovative solutions in water resource management in agriculture. Through this process, the importance of integrating predictive models and optimization techniques in irrigation planning and management has been confirmed, preparing the Laguna Huanzo irrigation system to face future challenges with greater resilience and sustainability.

Key words: Agriculture, K-NN machine learning algorithms, Hydraulic conductivity, Water management, Mathematical model.

INTRODUCCIÓN

La gestión eficiente de los recursos hídricos constituye un pilar fundamental para el desarrollo sostenible, especialmente en zonas agrícolas donde el agua es un recurso crítico tanto para la producción de alimentos como para el mantenimiento de ecosistemas saludables. En este contexto, el distrito de Santiago, ubicado en la provincia de Huanca Sancos, región de Ayacucho, Perú, enfrenta el desafío de optimizar el uso del agua ante las crecientes demandas agrícolas y los efectos adversos del cambio climático. Reconociendo la importancia estratégica del sistema de riego Laguna Huanzo, este estudio se centra en el desarrollo de un modelo predictivo de conductividad hidráulica para mejorar la eficiencia en la gestión del riego. Este estudio aborda la conductividad hidráulica del sistema de riego, analizando cómo las variaciones en las propiedades del suelo y las condiciones climáticas influyen en la dinámica del agua y, por consiguiente, en la eficiencia del riego. La adopción de técnicas avanzadas de modelización y algoritmos de aprendizaje automático, como la ecuación de Richards y el método K-NN, permite una evaluación detallada del comportamiento de la conductividad hidráulica, facilitando la identificación de oportunidades para optimizar la distribución del agua.

La investigación se distingue por su enfoque innovador en la gestión del agua en la agricultura, al emplear datos y modelos matemáticos para predecir y mejorar el uso del agua en el sistema de riego Laguna Huanzo. El objetivo es promover prácticas de riego que no solo satisfagan las necesidades actuales de los cultivos, sino que también analizar la influencia de la conductividad hidráulica en el recurso de riego para futuros años, asegurando así una gestión hídrica sostenible y eficiente que beneficie tanto al entorno natural como a las comunidades agrícolas locales.

La presente investigación se estructura de la siguiente manera: el primer capítulo introduce el problema de estudio, destacando la relevancia del sistema de riego Laguna Huanzo y estableciendo la justificación, las limitaciones y los objetivos de la investigación. El segundo capítulo proporciona un marco teórico, revisando investigaciones anteriores y literatura relevante en el ámbito de la gestión de recursos hídricos y la conductividad hidráulica. En el tercer capítulo, se describe la metodología empleada, incluyendo la recopilación de datos, el análisis estadístico y la aplicación de modelos predictivos. Los resultados obtenidos y su análisis se presentan en el cuarto capítulo, mientras que se concluye el estudio con un resumen de los hallazgos y propone recomendaciones basadas en los resultados, con el fin de mejorar la gestión del sistema de riego y promover un uso sostenible del agua en el distrito de Santiago.

ÍNDICE DE CONTENIDO

DEDICATORIA	ii
AGRADECIMIENTOS.....	iii
RESUMEN	iv
ABSTRACT	v
INTRODUCCIÓN.....	vi
ÍNDICE DE CONTENIDO	vii
ÍNDICE DE TABLAS.....	x
ÍNDICE DE FIGURAS.....	11
I. PLANTEAMIENTO DEL PROBLEMA.....	12
1.1. Descripción del problema	12
1.2. Delimitación del problema.....	13
1.2.1. Espacial (geográfica)	13
1.2.2. Temática y unidad de análisis	13
1.3. Formulación del problema	14
1.3.1. Problema general.....	14
1.3.2. Problemas específicos.....	14
1.4. Justificación e importancia.....	14
1.4.1. Justificación	14
1.4.2. Importancia	15
1.5. Limitaciones de la investigación	15
1.6. Objetivos.....	15
1.6.1. Objetivo general.....	15
1.6.2. Objetivos específicos.....	16
II. MARCO TEÓRICO	17
2.1. Antecedentes	17
2.1.1. Investigaciones internacionales.....	17
2.1.2. Investigaciones nacionales.....	18
2.2. Bases teóricas.....	19

2.1.1.	Sistemas de riego	19
2.1.2.	Generalidades sobre el suelo.....	20
2.1.3.	Conductividad hidráulica.....	25
2.1.4.	Machine Learning y algoritmos predictivos	26
2.1.5.	Movimiento del agua.....	32
2.3.	Marco Conceptual	36
2.3.1.	Modelos Predictivos.....	36
2.3.2.	Modelos Estadísticos.....	36
2.3.3.	Modelos Computacionales	36
2.3.4.	Impacto Ambiental	37
2.3.5.	Sostenibilidad.....	37
2.3.6.	Condición climática.....	37
III.	MÉTODO DE LA INVESTIGACIÓN.....	38
3.1.	Enfoque	38
3.2.	Alcance.....	38
3.3.	Diseño de investigación	38
3.4.	Población y muestra.....	39
3.4.1.	Población	39
3.4.2.	Muestra	39
3.5.	Hipótesis.....	39
3.5.1.	Hipótesis general	39
3.5.2.	Hipótesis específicas	39
3.6.	Operacionalización de variables, definición conceptual y operacional.....	40
3.7.	Técnicas e instrumentos	42
3.7.1.	Técnicas.....	42
3.7.2.	Instrumentos	42
3.8.	Técnicas estadísticas para el procesamiento de la información	42
3.9.	Desarrollo del trabajo de tesis	42
3.9.1.	Antecedente del área de estudio.....	42

3.9.2.	Ubicación del área en estudio	43
3.9.3.	Delimitación del Área de Estudio	45
3.9.4.	Acceso y vías de comunicación	46
3.9.5.	Metodología Propuesta.....	47
3.9.6.	Análisis de la región de estudio.....	49
3.9.7.	Desarrollo de la ecuación de Richards.....	56
3.9.8.	Estimación de la función $K\psi$ utilizando datos de retención de agua en el suelo	59
3.9.9.	Escenarios de valor de α para la Conductividad Hidráulica Relativa $K\theta$	65
3.9.10.	Error Máximo complementario.....	69
3.9.11.	Algoritmo de aprendizaje automático (K-NN).....	74
CAPÍTULO IV: Resultados y Discusión		87
4.1.	Análisis e Interpretación de los resultados	87
4.1.1.	Resultados de Proyección en 10 años futuros	89
CONCLUSIONES		94
RECOMENDACIONES.....		95
REFERENCIAS BIBLIOGRÁFICAS.....		96
ANEXOS		101

ÍNDICE DE TABLAS

Tabla 1 Cuadro de Operacionalización de variables.....	41
Tabla 2 Ubicación Política.....	43
Tabla 3 Acceso a la Zona de estudio.....	46
Tabla 4 Parámetros Geomorfológicos de la Cuenca Huanzo.....	49
Tabla 5 Humedad Media Relativa Mensual (%).....	50
Tabla 6 Resumen de los Ensayos de Permeabilidad.....	51
Tabla 7 Infiltración (MMC).....	52
Tabla 8 Temperatura Media Mensual.....	53
Tabla 9 Parámetros Químicos y Físicos.....	55
Tabla 10 Clasificación de la materia orgánica.....	56
Tabla 11 Coeficiente de conductividad térmica.....	71
Tabla 12 Coeficiente de Cultivo.....	90

ÍNDICE DE FIGURAS

Figura 1 Proceso de análisis de datos	27
Figura 2 Regresión lineal	28
Figura 3 Modelo de Red Neuronal de 3 capas	30
Figura 4 Support Vector Machines (SVM).....	31
Figura 5 Mapa de ubicación nacional y regional.....	44
Figura 6 Ubicación Provincial	45
Figura 7 Microcuenca del río Huanzo.....	46
Figura 8 Tramo a la zona de estudio.....	47
Figura 9 Metodología Propuesta de la Solución	48
Figura 10 Variación de la Humedad Media Relativa Mensual.....	51
Figura 11 Variación en la Infiltración Mensual (MMC)	53
Figura 12 Temperatura Media Mensual	54
Figura 13 Variación de la Conductividad Hidráulica Relativa	64
Figura 14 Variación de la Conductividad Hidráulica Relativa para un valor de $a=0.5$.	66
Figura 15 Variación de la Conductividad Hidráulica Relativa para un valor de $a=1.5$.	67
Figura 16 Variación de la Conductividad Hidráulica Relativa para un valor de $a=2.5$.	68
Figura 17 Variación de θ en función al error máximo	73
Figura 18 Pasos del algoritmo de aprendizaje automático K-NN.....	74
Figura 19 Generación de valores para θ	77
Figura 20 Eliminación de valores NaN	78
Figura 21 Datos de entrenamiento y prueba.....	79
Figura 22 Precisión del modelo	82
Figura 23 Precisión del modelo K-NN	83
Figura 24 Relación real vs la predicción de la conductividad hidráulica	86
Figura 25 Respuesta de la Conductividad Hidráulica	87
Figura 26 Proyecciones futuras de la Conductividad Hidráulica	88
Figura 27 Conductividad Hidráulica en función a K_c	92

I. PLANTEAMIENTO DEL PROBLEMA

1.1. Descripción del problema

El desarrollo de modelos predictivos en la gestión de recursos hídricos constituye una respuesta innovadora a los desafíos impuestos por el cambio climático y la creciente demanda de agua en la agricultura. En un contexto donde el 70% del agua disponible mundial se utiliza para riego, principalmente en el sector agrario, la optimización de los recursos hídricos se vuelve imperativa para garantizar la sostenibilidad y rentabilidad en la producción de alimentos esenciales (UNEP, 2018). La necesidad de modelos predictivos se hace aún más urgente en la medida que el cambio climático continúa afectando la disponibilidad, calidad y cantidad de agua, un recurso vital para la humanidad y, en particular, para la agricultura.

Un informe reciente de la UNESCO destaca que actualmente el 40% de la población mundial reside en áreas afectadas por estrés hídrico y se espera que, en 2025, más de dos tercios de la población global enfrente problemas de escasez de agua. Esto es alarmante, considerando que el consumo de agua se ha sextuplicado en el último siglo y sigue creciendo a un ritmo de 1% anual. De este volumen, entre el 75 y el 80% se utiliza en la agricultura, estas cifras subrayan la necesidad crítica de una gestión eficiente y sostenible del agua en el sector agrícola (UNESCO, 2020).

En América Latina, y específicamente en regiones como Ayacucho en Perú, la brecha en infraestructuras de riego y la tendencia ascendente en la demanda de sistemas de riego destacan la importancia de desarrollar metodologías basados en modelos predictivos para el aprovechamiento del agua, ya que este escenario se ve agravado por el cambio climático, que está reduciendo la disponibilidad de agua en cuencas altoandinas, una fuente vital para la agricultura de la región.

Dada la creciente demanda de alimentos y la necesidad de expandir las áreas de regadío para alimentar a una población mundial en aumento, el desarrollo de un modelo predictivo de conductividad hidráulica adquiere una importancia fundamental. Este modelo tiene el potencial de mejorar la eficiencia en la gestión del riego, facilitando la toma de decisiones sobre la irrigación en función de diversas variables ambientales. Al comprender y predecir mejor la dinámica del agua en el suelo, los agricultores podrían

ajustar sus prácticas de riego para maximizar la utilización del agua, minimizando el desperdicio y mejorando la productividad de los cultivos.

El uso de un modelo predictivo en la gestión del riego también puede contribuir a la conservación de los ecosistemas y la biodiversidad, puesto que el uso eficiente del agua no solo beneficia a la agricultura, sino que también ayuda a mantener los niveles de agua en ríos y lagos, lo cual es crucial para la supervivencia de muchas especies acuáticas y terrestres. Además, la reducción del uso excesivo de agua en la agricultura puede disminuir la contaminación por nitratos y fosfatos, derivada de los fertilizantes, protegiendo así la calidad del agua y la salud de los ecosistemas acuáticos.

El enfoque de la agricultura de precisión, que busca optimizar los recursos a través de la tecnología, puede integrarse eficazmente con el modelo predictivo. Mediante la recopilación y análisis de datos sobre el clima, el suelo y las necesidades de los cultivos, los agricultores pueden tomar decisiones informadas sobre cuándo y cuánto regar, lo que resulta en un uso más eficiente del agua y en una mayor producción de alimentos. Por lo tanto, el desarrollo de un modelo predictivo para optimizar el sistema de riego Laguna Huanzo representa un paso crucial hacia una agricultura más sostenible y eficiente en el uso del agua. Este modelo no solo tendría un impacto significativo en la provincia de Huanca Sancos en Ayacucho, sino que también podría servir como ejemplo para otras áreas que enfrentan desafíos similares.

1.2. Delimitación del problema

1.2.1. Espacial (geográfica)

La delimitación espacial de esta investigación se centra específicamente en el sistema de riego Laguna Huanzo, ubicado en el distrito de Santiago, dentro de la provincia de Huanca Sancos, región de Ayacucho.

1.2.2. Temática y unidad de análisis

La temática se enfoca en el desarrollo de un modelo predictivo de conductividad hidráulica. La investigación se centrará en entender y predecir cómo el agua se mueve a través del suelo en la zona específica del sistema de riego Laguna Huanzo.

La unidad de análisis será la conductividad hidráulica del suelo en la zona de estudio. Se analizarán las propiedades físicas y químicas del suelo, así como los patrones climáticos y de riego actuales, para entender cómo estos factores influyen en la conductividad hidráulica y, por ende, en la eficiencia del riego.

1.3. Formulación del problema

1.3.1. Problema general

¿Cómo desarrollar un modelo predictivo de conductividad hidráulica para optimizar la eficiencia del sistema de riego Laguna Huanzo en el distrito de Santiago, provincia de Huanca Sancos, Ayacucho?

1.3.2. Problemas específicos

- ¿Cuál es la correlación de las propiedades del suelo y condiciones climáticas con los patrones de conductividad hidráulica en el distrito de Santiago, provincia de Huanca Sancos?
- ¿Cómo se puede aplicar la ecuación de Richards para desarrollar un modelo matemático que describa el movimiento del agua en relación con la conductividad hidráulica?
- ¿De qué manera se puede integrar el modelo matemático con un algoritmo de aprendizaje automático (K-NN) para optimizar la precisión en la predicción de la conductividad hidráulica?
- ¿Cómo se pueden simular diferentes escenarios utilizando el modelo matemático y el algoritmo de aprendizaje automático (K-NN)?

1.4. Justificación e importancia

1.4.1. Justificación

La justificación de la presente investigación se fundamenta en la necesidad de gestionar de manera eficiente los recursos hídricos en la provincia de Huanca Sancos. En un contexto marcado por el cambio climático y la creciente demanda de alimentos, la optimización del uso del agua en la agricultura se ha convertido en un imperativo no solo para la sostenibilidad ambiental sino también para la seguridad alimentaria y la estabilidad económica de las comunidades locales. Al implementar un modelo predictivo

de conductividad hidráulica, se busca mejorar la precisión en la administración del riego, asegurando que el agua sea utilizada de manera óptima, minimizando el desperdicio y maximizando la productividad de los cultivos.

1.4.2. Importancia

La importancia de esta investigación radica en su impacto potencial en la sustentabilidad de la agricultura y la gestión eficiente del agua. En una era donde el cambio climático amenaza la disponibilidad y calidad del recurso hídrico, optimizar el riego se convierte en un pilar para la seguridad alimentaria y la conservación ambiental. Esta investigación permitirá no solo mejorar la eficiencia en el uso del agua, reduciendo el desperdicio y aumentando la productividad de los cultivos, sino también ofrecer un modelo aplicable a otras regiones con desafíos hídricos similares. Al integrar datos climáticos, edáficos y de riego en un modelo predictivo, se proporciona a los agricultores y gestores del agua una herramienta poderosa para tomar decisiones informadas, adaptándose a las dinámicas cambiantes del clima y asegurando un uso más sostenible del agua en la agricultura.

1.5. Limitaciones de la investigación

- El modelo se centrará exclusivamente en predecir la conductividad hidráulica, sin considerar otras variables hidrológicas.
- El análisis de las propiedades del suelo y las condiciones climáticas se limitará al área específica del distrito de Santiago.
- Solamente se utilizará la ecuación de Richards en el modelo matemático
- Las herramientas y técnicas de aprendizaje automático aplicadas en este proyecto estarán sujetas a las limitaciones intrínsecas del algoritmo K-NN.

1.6. Objetivos

1.6.1. Objetivo general

Desarrollar un modelo predictivo de conductividad hidráulica para optimizar la eficiencia del sistema de riego Laguna Huanzo en el distrito de Santiago, provincia de Huanca Sancos, Ayacucho.

1.6.2. Objetivos específicos

- Analizar la correlación de las propiedades del suelo y condiciones climáticas con los patrones de conductividad hidráulica en el distrito de Santiago, provincia de Huanca Sancos.
- Aplicar la ecuación de Richards para realizar un modelo matemático del movimiento del agua en la conductividad hidráulica.
- Combinar el modelo matemático con el algoritmo de aprendizaje automático (K-NN) para optimizar la predicción de conductividad hidráulica.
- Simular escenarios para validar las predicciones del modelo desarrollado.

II. MARCO TEÓRICO

2.1. Antecedentes

2.1.1. Investigaciones internacionales

Merino (2022) en su tesis *“Diseño e implementación de una estrategia de control para sistemas de riego utilizando aprendizaje reforzado”*, tuvo como objetivo desarrollar técnicas agrícolas eficientes en el uso del agua para enfrentar los desafíos del aumento poblacional y la escasez hídrica, enfocándose en la comunidad mapuche José Paineicura en la Región de la Araucanía, Chile. La metodología incluyó la simulación de un esquema de control de riego en cultivos, utilizando un modelo adaptado a la arquitectura de entornos Gym. Se evaluaron tres estrategias de aprendizaje reforzado: Proximal Policy Optimization (PPO), Deep Deterministic Policy Gradient (DDPG) y Twin Delay Deep Deterministic Policy Gradient (TD3), destacando por su habilidad para optimizar el uso del agua y adaptarse a variaciones en el cultivo. Los resultados mostraron que, aunque las estrategias de aprendizaje reforzado no superaron a las técnicas de balance hídrico en términos de maximizar rendimientos minimizando el uso del agua, el algoritmo PPO mostró el mejor desempeño entre las técnicas evaluadas.

Pousada (2021) en su tesis *“Aplicación de algoritmos predictivos para la eficiencia en la gestión del riego”*, tuvo como objetivo diseñar un sistema de riego inteligente que optimice la gestión hídrica en la agricultura, ante la previsión de escasez de agua. La metodología emplea tecnología de punta, integrando sensores para la adquisición de datos y métodos predictivos para el análisis. Se centra en un modelo de datos que predice necesidades de irrigación, considerando factores como las condiciones del terreno y climáticas. Los resultados indican que este sistema autónomo asegura una gestión eficaz del agua, superando a los sistemas convencionales. Las pruebas demuestran que el modelo predictivo favorece la automatización, reduce costes y promueve un uso sostenible del recurso hídrico, minimizando el impacto ambiental.

Del Vigo (2023) en su artículo *“Flujo de agua en el suelo bajo condiciones de simetría radial. Contraste entre modelos”*, tuvo como objetivo revisar modelos analíticos para la evolución del frente de avance del flujo de agua en suelos bajo riego por goteo superficial y proponer un nuevo modelo analítico basado en condiciones ideales de suelo. La metodología incluye un análisis de modelos existentes bajo suposiciones de homogeneidad e isotropía del suelo, ausencia de gravedad y sin acumulación superficial

de agua. Se introduce un modelo innovador derivado de la ecuación de Darcy y la ecuación de continuidad para flujos desde una fuente cuasi-puntual. Los resultados muestran una comparación entre los modelos revisados y simulaciones numéricas validadas, proporcionando un marco detallado para entender la dinámica del riego por goteo superficial.

2.1.2. Investigaciones nacionales

Portocarrero (2020) en su tesis *“Clasificación del territorio peruano de acuerdo con su potencial de agua subterránea utilizando algoritmos de aprendizaje automatizado”*, aborda la urgencia de una explotación sostenible del agua, focalizándose en identificar zonas con potencial hidrológico subterráneo en Perú. Se utiliza aprendizaje automatizado, específicamente modelos de bosques aleatorios y redes neuronales, para analizar acuíferos poco profundos sin recurrir a perforaciones. Variables como topografía, hidrología, y otras relevantes para la conductividad hidráulica y recarga de acuíferos son esenciales en el análisis. El modelo de bosques aleatorios mostró que el mejor desempeño, lo presento la conductividad hidráulica subterránea. Sin embargo, la escasez y distribución irregular de datos de pozos limita la precisión, resaltando la necesidad de mejorar el inventario de pozos para futuros modelos.

Rosales (2021) en su tesis *“Modelo de estimación de la conductividad hidráulica saturada in situ en función de las propiedades físicas del suelo en la localidad de Marian – 2021”*, se centra en estimar la conductividad hidráulica saturada del suelo, esencial para drenaje eficiente. Utilizando análisis de regresión lineal simple y múltiple, se correlaciona esta conductividad con propiedades físicas del suelo. Los resultados validan la precisión del modelo propuesto, comparando la conductividad obtenida en campo con la predicha por modelos empíricos de Kozeny-Carman y Slitcher. Los análisis estadísticos indican una mayor homogeneidad en los datos de campo. El modelo más ajustado para la estimación es una ecuación que integra límite líquido y plástico, mostrando un alto coeficiente de correlación, por lo que se sugiere ampliar la investigación comparando diferentes métodos de campo y laboratorio para enriquecer la validez del modelo actual.

Leyva (2019) en su tesis *“Estimación de la conductividad hidráulica saturada en campo en la localidad de Tingua – 2017”*, apunta a estimar la conductividad hidráulica

saturada in situ, crucial para entender la infiltración y redistribución de agua en suelos. Se aplicaron tres métodos de prueba: infiltrometro de doble anillo, Porchet y permeámetro de Guelph. Se seleccionaron 14 sitios en Tingua, caracterizados por suelos finos, para realizar pruebas en cultivos de alfalfa y maíz. Los resultados varían según el tipo de suelo, con conductividades que oscilan entre 0.0076 y 0.0799 m/día, indicando una movilidad del agua de lenta a muy lenta; estos hallazgos son fundamentales para la gestión agrícola y de recursos hídricos en la región.

2.2. Bases teóricas

2.1.1. Sistemas de riego

Los sistemas de riego comprenden la estructura esencial diseñada para transportar, repartir y optimizar el uso del agua de forma eficaz a través del área cultivada completa.

2.1.1.1. Sistemas de riego por tiempo

Hoy en día, el método de riego más prevalente es el programado según el tiempo. Este enfoque simplemente controla el encendido y apagado de las electroválvulas, permitiendo al agricultor regar en horarios preestablecidos o en los momentos diarios requeridos según el tipo de cultivo, las características del suelo y la ubicación geográfica, eliminando la necesidad de estar presente físicamente en el campo. Aunque esta automatización representó un avance significativo, en ciertas ocasiones, puede conducir a un riego excesivo e innecesario de los cultivos. Es crucial, para el análisis futuro, reconocer que los sistemas de programación basados en tiempo o frecuencia pueden malgastar recursos. Esto se debe a que, considerando varios factores que analizaremos más adelante, la irrigación puede resultar innecesaria si el suelo ya posee la humedad adecuada o si las condiciones meteorológicas anticipan lluvias, entre otros aspectos (Pousada, 2021).

2.1.1.2. Sistemas de riego inteligente

En la agricultura moderna, la integración de tecnologías avanzadas en sistemas de riego ha revolucionado la gestión del agua, promoviendo una utilización más eficiente. El riego inteligente emplea tecnologías de información y comunicación para optimizar la irrigación. A través del Internet, se están implementando sensores

conectados a la red que facilitan el intercambio de datos y comunicaciones, permitiendo una gestión más eficaz y contribuyendo a mejorar el rendimiento de los cultivos, la rentabilidad agrícola y reducir el impacto ambiental (Calvo, 2019).

Los avances tecnológicos en este campo mejoran la toma de decisiones mediante la monitorización de variables clave y, con la incorporación del aprendizaje automático, se pueden predecir patrones y optimizar aún más estas decisiones. Así, las TICs se convierten en herramientas cruciales para aumentar la eficiencia hídrica, determinando el momento óptimo, la frecuencia y la duración del riego para promover un desarrollo saludable de los cultivos utilizando la cantidad exacta de agua necesaria (Pousada, 2021).

Existen dos categorías principales de sistemas de riego inteligente, diferenciadas por el tipo de información que emplean para determinar cuándo y cuánto regar un área específica de tierra o parcela.

- **Sistemas de riego inteligente orientados al clima:** Estos dispositivos de irrigación ajustan su funcionamiento según las condiciones meteorológicas, calculando la cantidad de agua necesaria basándose en datos como la velocidad del viento, la humedad ambiental, la radiación solar y la temperatura.
- **Sistemas de riego inteligente con sensores de humedad del suelo:** Estos sistemas proporcionan una medición exacta de la humedad en puntos específicos del suelo, optimizando el uso del agua al asegurarse de que solo se riegue cuando sea necesario para el desarrollo adecuado de los cultivos.

Estos sistemas pueden configurarse para que activen el riego cuando la humedad del suelo cae por debajo de un nivel predeterminado, o, inversamente, para suspender el riego programado si el suelo alcanza el nivel de humedad ideal previamente establecido.

2.1.2. Generalidades sobre el suelo

Brady y Weil (2010) definen el suelo como un conjunto de cuerpos naturales que se ha desarrollado a partir de material mineral y orgánico. Se encuentra en la superficie terrestre y sirve como medio natural para el crecimiento de las plantas. Sus propiedades

son el resultado de la interacción del clima, la materia viva y el material parental a lo largo del tiempo.

A. Características del suelo:

- Es una mezcla de materiales en estado natural.
- Se encuentra en la parte superficial de la corteza terrestre.
- Contiene diversos organismos.
- Desempeña una función importante en el desarrollo de las plantas.
- Tiene un límite superior en la atmósfera y las aguas poco profundas.
- Su límite inferior está en las rocas duras y continuas.
- Su profundidad máxima es de aproximadamente 2 metros

B. Importancia del suelo:

Salgado et al. (2010) afirman que el suelo es el segundo capital más importante de un país después de los recursos humanos. Es la base de la producción de alimentos, tanto vegetal como animal. La vida en el planeta depende del suelo, ya que no existe tecnología que pueda reemplazarlo en cuanto a la calidad, cantidad o variedad de productos que se obtienen de él.

C. Vulnerabilidad del suelo:

El suelo es un sistema complejo y heterogéneo, susceptible a la degradación por prácticas agrícolas inadecuadas. López y Estrada (2015) señalan que la heterogeneidad de sus componentes, la gran cantidad de interacciones entre sus factores y la variabilidad del sistema afectan el rendimiento de los cultivos, disminuyen el potencial agrícola del suelo y pueden provocar desertificación.

D. Conservación del suelo:

Para proteger el suelo, es necesario implementar prácticas agroecológicas como el reciclaje de materia orgánica, la labranza mínima y la diversificación de cultivos. Además, es importante realizar un manejo controlado de las propiedades del suelo para evitar problemas de degradación y mantener altos rendimientos de manera sostenible.

E. Componentes del suelo:

El suelo es un recurso natural compuesto por minerales, materia orgánica, aire, agua, organismos vegetales y animales. La FAO (1996) lo define como una porción delgada de la corteza terrestre formada por la descomposición de las rocas superficiales. Los restos de la flora y fauna que habitan el suelo también contribuyen a su formación al descomponerse y convertirse en materia orgánica.

2.1.2.1. Propiedades físicas del suelo

El suelo es un sistema complejo y dinámico compuesto por tres fases: sólida, líquida y gaseosa. Sus propiedades físicas, químicas y biológicas interactúan entre sí para mantener un ambiente idóneo para el crecimiento de las plantas.

Las Propiedades físicas según (Brady y Weil, 2010; Salgado et al., 2010; López y Estrada, 2015) son las siguientes:

A. Textura:

- La composición volumétrica del suelo, determinada por el tamaño de las partículas que lo componen (arena, limo y arcilla).
- Afecta la capacidad de retención de agua y aireación del suelo.
- Los suelos arenosos tienen baja retención de agua y alta aireación, mientras que los arcillosos tienen alta retención de agua y baja aireación.

B. Estructura:

- La disposición de las partículas del suelo en agregados.
- Influye en la aireación, el movimiento del agua, el crecimiento radicular y la resistencia a la erosión.
- Los agregados estables entre 2 y 5 mm son considerados de buena calidad del suelo.

C. Color:

- Indicador de la mineralogía, procesos edáficos, materia orgánica y otros.
- En suelos agrícolas, el color está influenciado por la materia orgánica.
- Se utiliza el sistema Munsell para determinar el color del suelo.

D. Carbonatos de calcio:

- Influyen en el pH, la estructura, la actividad biológica, el almacenamiento de nutrientes y la disponibilidad de elementos para las plantas.
- Un contenido alto de carbonatos asegura un pH elevado del suelo.
- El carbonato de calcio puede ser utilizado como correctivo del pH de los suelos ácidos.

E. Pedregosidad y/o gravosidad:

- Afecta el uso y manejo del suelo, las labores de cultivo y cosecha.
- Las piedras y bloques pedregosos sobre la superficie interfieren las labores de cultivo.

F. Densidad del suelo:

- Relación entre la masa del suelo y su volumen total.
- Los suelos arenosos tienen mayor densidad que los arcillosos.
- Se distinguen dos tipos: densidad aparente (D_a) y densidad real (D_p).

G. Espacio poroso:

- Porcentaje del volumen del suelo no ocupado por sólidos.
- Se divide en macroporos (drenaje y aireación) y microporos (retención de agua).
- Una porosidad total entre 40 y 50% del volumen del suelo es considerada satisfactoria para el desarrollo de las plantas.

H. Profundidad:

- Espesor del suelo donde las raíces pueden penetrar y encontrar agua y nutrientes.
- Se considera hasta 2 metros o hasta la capa limitante (roca, arcilla densa, napa freática).
- La profundidad efectiva del suelo también es denominada como solum.

2.1.2.2. Propiedades químicas del suelo

Según estos autores (Jordán, 2010; Lamz y González, 2013; Porta et al., 2003) las propiedades químicas más estudiadas del suelo son las siguientes:

A. El pH del suelo:

- **Definición:** Es la medida de la acidez o basicidad del suelo. Se expresa como el logaritmo negativo de la concentración de iones hidrógeno (H⁺) (Lamz y González, 2013).
- **Rango ideal:** Para la agricultura, el pH ideal del suelo está entre 5,5 y 8,5.
- **Factores que lo afectan:** El clima, el estado de desarrollo de las plantas, la materia orgánica y el dióxido de carbono del suelo.
- **Efectos:** Influye en la dispersión de las arcillas, la estructura del suelo, la porosidad, la conductividad eléctrica, la disponibilidad de nutrientes, la actividad microbiana y la absorción de agua por las plantas.

B. Salinidad del suelo:

- **Definición:** Es la acumulación excesiva de sales solubles en agua en el suelo (Jordán, 2010).
- **Problema:** La salinidad del suelo es un problema creciente que afecta la producción de alimentos a nivel mundial.
- **Causas:** El clima árido, el riego con aguas salinas, el uso excesivo de fertilizantes y la actividad industrial inadecuada.
- **Efectos:** Disminuye la porosidad, la aireación y la permeabilidad del suelo, lo que dificulta el crecimiento de las plantas.
- **Indicadores:** La presencia de una costra superficial salina y la conductividad eléctrica del suelo.
- **Manejo:** Se puede controlar la salinidad mediante el drenaje adecuado, el uso de aguas de buena calidad y la selección de cultivos tolerantes a la sal.

C. Capacidad de intercambio catiónico (CIC):

- **Definición:** Es la capacidad del suelo para retener cationes (Ca⁺⁺, Mg⁺⁺, K⁺, Na⁺, etc.) en su superficie (Porta et al., 2003).
- **Importancia:** La CIC determina la cantidad de nutrientes que el suelo puede poner a disposición de las plantas.
- **Valor ideal:** Un valor ideal de CIC está entre 15 y 25 cmol.kg⁻¹ o me.100 g⁻¹ de suelo.

- **Factores que la afectan:** La cantidad de arcilla y materia orgánica del suelo.

2.1.3. Conductividad hidráulica

La conductividad hidráulica puede evaluarse por medio de pruebas de laboratorio con muestras de suelo, directamente en el campo (in situ), o estimándola a partir de ciertos atributos del suelo. Las dos primeras técnicas aplican condiciones específicas de flujo al suelo, donde la conductividad hidráulica, K , se determina midiendo la tasa de flujo y aplicando una fórmula que vincula este valor con las condiciones de flujo y la tasa de flujo observada. El tercer enfoque es más inferencial y se basa en establecer una relación entre la conductividad hidráulica y la distribución del tamaño de los poros o partículas del suelo (Villón, 2005).

Ángel y Pineda (2019) añaden que “la conductividad hidráulica describe la movilidad de las aguas subterráneas o superficiales, propiedad adyacente de un medio poroso que depende de la permeabilidad interna del medio, la porosidad y el grado de saturación”. En consecuencia, los suelos de grano fino como el limo y la arcilla tienen una conductividad hidráulica menor en comparación con los suelos de grano grueso como la mayoría de las arenas y gravas. Como se dijo anteriormente, la permeabilidad y la conductividad están estrechamente relacionadas, de hecho “la baja conductividad hidráulica aumenta la erosión al aumentar el escurrimiento debido a la reducción de la permeabilidad del suelo” (Pérez y García, 2015). El concepto de conductividad hidráulica es un desarrollo de lo que originalmente Henry Darcy llamó permeabilidad, entendida como la constante de proporcionalidad de cualquier material. Pérez y García (2015) mencionan que la medición de la conductividad hidráulica es un reflejo fiel. en condiciones de campo, especialmente cuando se determina a diferentes profundidades para tener en cuenta las diferencias en los horizontes del suelo, ya que este parámetro depende profundamente de la estructura del suelo. Los mismos autores destacan la conductividad hidráulica como “un parámetro importante para determinar el movimiento del agua en el suelo”, lo que la convierte también en un factor fundamental para resolver problemas relacionados con el flujo de agua en el suelo.

2.1.3.1. Método para estimar la conductividad hidráulica

La técnica del anillo doble implica insertar parcialmente dos cilindros abiertos, uno dentro del otro, hasta la profundidad deseada, seguido de un periodo de saturación inicial. Una cantidad específica de agua se añade a ambos anillos, y luego se mide la velocidad a la que el agua se infiltra en el suelo desde el anillo más interno. Es crucial

que ambos anillos mantengan el mismo nivel de agua para prevenir flujos laterales entre ellos. La medición puede realizarse de dos formas: mediante un nivel variable, registrando el descenso del agua a lo largo del tiempo, o manteniendo un nivel constante, rellenando el agua absorbida para preservar el nivel original. En ambos métodos, se continúa la observación hasta que la tasa de infiltración se estabiliza. La metodología estándar propuesta por la American Society for Testing and Materials (ASTM) está detallada en la norma D 3385 – 9403 para pruebas con nivel constante. En este particular estudio, se optó por utilizar el método de nivel variable (Macías et al., 2018).

Existen diversas técnicas para calcular la conductividad hidráulica de campo (Kfs) usando los resultados del ensayo. Una de estas técnicas postula que la conductividad hidráulica Kfs es equivalente a la tasa de infiltración que se estabiliza, siguiendo ciertas deducciones teóricas (Macías et al., 2018).

Teniendo en cuenta la forma del anillo y sabiendo que el caudal que se infiltra en la zona del anillo interno (de radio r) se determina por el cambio en el nivel del agua (Δh) durante un intervalo de tiempo (Δt) y el área del anillo, se obtiene la siguiente ecuación:

$$Q = \frac{-\Delta h \pi r^2}{\Delta t}$$

2.1.4. Machine Learning y algoritmos predictivos

El Aprendizaje Automático se refiere a la habilidad de un sistema o máquina para aprender y reconocer patrones complejos a través del procesamiento de grandes cantidades de datos utilizando algoritmos específicos. Además, es notable la variedad de software/herramientas disponibles para implementar estos algoritmos, siendo Python y R los lenguajes más comunes para este propósito (Dellot y Balaram, 2019). Python, en particular, ofrece librerías especializadas como SciPy, incluyendo NumPy y Pandas para operaciones de álgebra lineal, y Scikit Learn, una biblioteca de código abierto para algoritmos de aprendizaje supervisado y no supervisado.

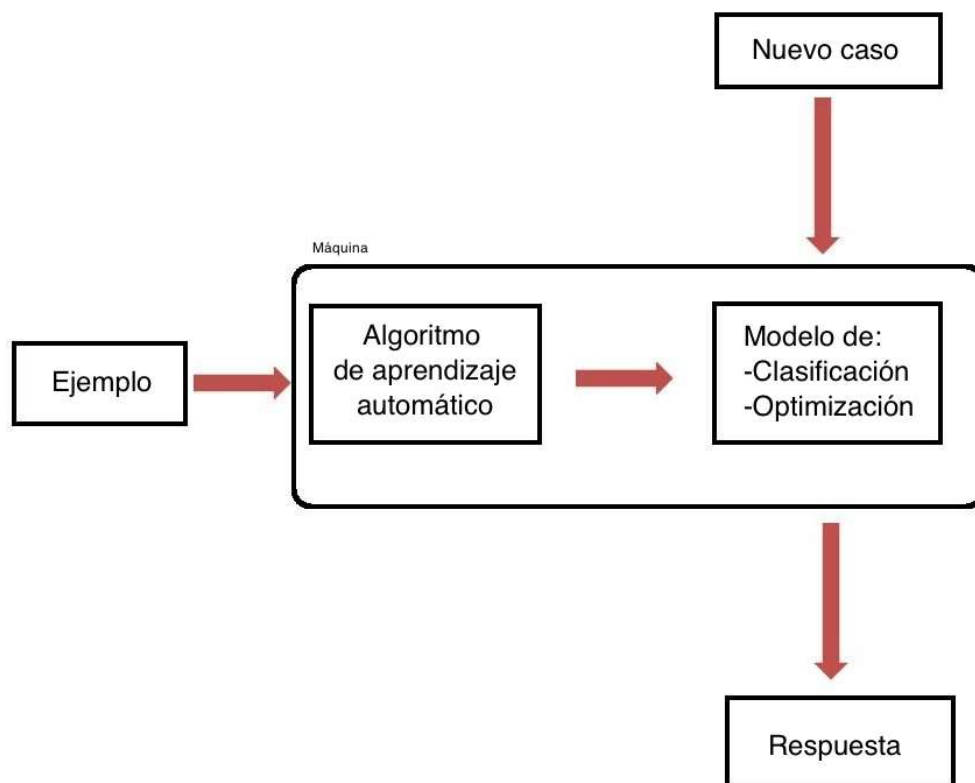
También existen plataformas, como IBM Watson Analytics, que proveen interfaces amigables y herramientas para facilitar la implementación y análisis, permitiendo, por ejemplo, cargar archivos en la nube y manipularlos para obtener insights. Dentro del Aprendizaje Automático, el análisis predictivo es comúnmente

utilizado, empleando técnicas matemáticas para interpretar datos existentes y prever eventos o resultados futuros basándose en la información procesada (Agrawal et al., 2019).

Para analizar datos, se puede optar por dos enfoques de aprendizaje automático:

- En el **aprendizaje supervisado**, los algoritmos operan con datos previamente “etiquetados”, buscando una función que asocie correctamente una etiqueta de salida a partir de las variables de entrada. Durante el entrenamiento, el algoritmo se ajusta usando un conjunto de entrenamiento (training set) con el fin de predecir la salida para un conjunto de prueba (test set) dado (Dellot y Balaram, 2019).
- Por otro lado, **en el aprendizaje no supervisado**, se trabaja con datos de entrada sin etiquetas asociadas. Dado que las salidas no están predefinidas para los inputs, el objetivo es explorar la estructura interna de los datos para identificar patrones o grupos comunes, como se realiza en técnicas de agrupación (clustering) (Dellot y Balaram, 2019).

Figura 1
Proceso de análisis de datos




Nota. Ejemplo de un proceso de aprendizaje Automático. Fuente (Blanco, 2015).

Tras el procesamiento y análisis de datos, el sistema adquiere conocimientos que permiten evaluar y mejorar la toma de decisiones. Así, en el contexto de la agricultura, esta información se puede utilizar para maximizar la eficiencia en la administración de recursos hídricos. Este procedimiento se ilustra en la figura mostrada anteriormente.

2.1.4.1. Regresión Lineal

El modelo de regresión lineal estudia la vinculación entre una variable dependiente y varias variables independientes, representando esta asociación a través de una ecuación lineal en relación con los parámetros. La finalidad del algoritmo consiste en determinar los parámetros que minimizan la suma total de los cuadrados de las diferencias entre los valores observados y los pronosticados por el modelo. En otras palabras, busca ajustar la línea recta que mejor se aproxime a los datos, en un proceso conocido como el método de mínimos cuadrados, como se visualiza en la figura siguiente (Cortés y Rubalcava, 1983).

Figura 2
Regresión lineal



Nota. Fuente (Pousada, 2021).

2.1.4.2. Árboles de decisión

En la informática, los árboles se emplean ampliamente para modelar distintas situaciones y estructuras, especialmente para representaciones jerárquicas que facilitan operaciones y recorridos de manera recursiva. Un árbol está compuesto por un nodo

principal denominado raíz, seguido de ramas, nodos secundarios y nodos terminales conocidos como hojas (Bonaccorso, 2018).

Un árbol de decisión, que se extiende descendiendo desde un nodo raíz, utiliza nodos para representar decisiones. Cada nodo comprueba ciertos atributos, cuyos resultados guían el flujo a través de las ramas hacia otros nodos, donde se toman más decisiones, o hacia un resultado final (Larose y Larose, 2014).

Para que un árbol de decisión sea efectivo en clasificación, debe cumplir tres condiciones esenciales:

- Disponer de un conjunto de datos de entrenamiento que respalde el aprendizaje supervisado enfocado en una variable objetivo
- Asegurar que el conjunto de datos de entrenamiento sea diverso y no esté sesgado
- Predecir que la variable sea de naturaleza discreta.

2.1.4.3. Redes neuronales

El cerebro humano, con sus aproximadamente 100 mil millones de neuronas interconectadas, es excepcionalmente hábil en el reconocimiento de patrones y controla gran parte de las funciones del cuerpo. Tanto científicos como matemáticos han intentado desentrañar y modelar matemáticamente su compleja mecánica.

El campo de las Redes Neuronales (NN) o Redes Neuronales Artificiales (ANN) tiene sus raíces hace cerca de 80 años. En 1943, el neurofisiólogo Warren McCulloch y el matemático Walter Pitts propusieron una teoría sobre el funcionamiento neuronal, creando una NN básica con circuitos electrónicos.

En 1957, Frank Rosenblatt dio un paso significativo al desarrollar el perceptrón, precursor de la neurona moderna, que era capaz de aprender y reconocer nuevos patrones tras ser expuesto a patrones similares, aunque tenía limitaciones en la clasificación de clases no linealmente separables.

Una red neuronal típica se compone de tres capas: una de entrada para los datos, una oculta donde se procesan los datos mediante funciones de activación, y una de salida que presenta los resultados. Estas redes varían en su complejidad, dependiendo del número de capas y la cantidad de neuronas en cada una. Un ejemplo de una red de tres capas se puede visualizar en la imagen proporcionada, con la primera capa conteniendo cuatro neuronas, la segunda con dos, y la tercera con una única neurona que entrega el resultado (Srinivas, 2021).


2.1.4.4. Máquina de vectores de soporte (SVM)

La Support Vector Machine (SVM), o Máquina de Vectores de Soporte, es una técnica de aprendizaje supervisado ideada por Vladimir Vapnik, aplicable tanto en tareas de clasificación como de regresión.

Este algoritmo es especialmente eficaz en contextos de alta dimensionalidad. Su principal objetivo es establecer un límite de decisión que distinga eficientemente entre distintas categorías de datos (Liu., 2022).

La SVM opera creando hiperplanos que separan las categorías de datos, buscando maximizar la distancia entre estos hiperplanos y los puntos más cercanos de cada categoría, denominados Vectores de Soporte. Dentro de las SVM, existen variantes, como la SVM lineal que es adecuada para datos que pueden ser divididos en dos categorías mediante una línea recta, conocidos como datos linealmente separables y la no lineal el cual se utiliza para separar datos que se pueden clasificar en línea recta (Nazarathy y Klok, 2021).

Figura 4
Support Vector Machines (SVM)



Nota. Fuente (Nazarathy y Klok, 2021).

2.1.4.5. K-NN vecinos más cercanos

K-NN, conocido como k-vecinos más cercanos, es una técnica de aprendizaje supervisado aplicable a tareas de clasificación y regresión. Funciona considerando los k ejemplos de entrenamiento más próximos en el espacio de características (Liu., 2022).

Para clasificación en K-NN, el algoritmo asigna una clase al objeto basándose en la mayoría de votos de sus k vecinos más cercanos. Si k es igual a 1, el objeto se clasifica según su único vecino más cercano.

$$y = \text{mode}\{y_1, y_2, \dots, y_k\}$$

Donde y representa la clase pronosticada y y_1, y_2, \dots, y_k son las clases de los k vecinos más próximos.

$$y = \frac{1}{k} \sum_{i=1}^k y_i$$

Aquí, y es el valor pronosticado, y y_1, y_2, \dots, y_k son los valores de los k vecinos más próximos.

K-NN se clasifica como aprendizaje basado en instancia o perezoso ya que no genera una función discriminativa concreta, sino que memoriza las instancias de entrenamiento para utilizarlas durante la predicción.

La elección de k es fundamental en este algoritmo, ya que un k pequeño puede ser susceptible a anomalías, mientras que un k grande puede diluir las fronteras entre clases.

Comúnmente, la distancia entre los puntos se mide con la distancia euclidiana, especialmente en espacios de múltiples dimensiones:

$$d(p, q) = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2}$$

2.1.5. Movimiento del agua

2.1.5.1. Flujo en suelos saturados

Si el agua se mueve en un suelo donde todos los poros están constantemente cubiertos de agua, es decir, saturados, este fenómeno se denomina flujo saturado. Este tipo de movimiento de fluido se debe a un gradiente hidráulico y sigue la ley de Darcy; Puede aparecer tras lluvias, riegos o malas condiciones de drenaje del suelo (Salazar y

Nájera,2011). La relación física que explica este comportamiento se representa en la siguiente ecuación:

$$Q = vA_t$$

Donde:

Q : es el flujo

v : es la velocidad del agua

A_t : es el área transversal

Según Briaud (2013), la relación anterior se utiliza como sustituto porque es difícil determinar el vacío real para encontrar la relación entre la tasa de filtración y la tasa de descarga, es por ello que se utiliza la siguiente ecuación:

$$vA_t = v_s A_v; \text{ o bien } v = nv_s$$

Donde:

v : es la velocidad real del fluido

A_t : es el área transversal al flujo

v_s : es la velocidad de filtración

A_v : es el área real de vacíos

n : es la porosidad del suelo

La distribución de altura del fluido del suelo en este estado saturado es lineal, por lo que el gradiente hidráulico, que representa la pérdida de energía a lo largo del camino del agua, es constante. Este gradiente es igual a la velocidad del flujo dividida por la conductividad hidráulica (Lu y Likos, 2004). De manera similar, Sánchez (2008) señala que la ley de Darcy se aplica a flujo saturado, como se muestra en la siguiente ecuación, la cual resulta de la aplicación simultánea de la ley de Darcy y la ley de conservación de masa.

$$q = -k_s \times \frac{dh}{dl}$$

Donde:

k_s :es la conductividad hidráulica

q : es el caudal que circula por cada m² de sección

$\frac{dh}{dl}$: es el gradiente hidráulico

Un signo negativo indica que el flujo es desde un punto de mayor carga hacia un punto de menor carga.

2.1.5.2. Flujo en suelos no saturados

El flujo no saturado se produce en suelos cuyos poros no están completamente llenos de agua, pero donde coexisten agua y aire. En esta situación, las condiciones representadas por varios parámetros de control del flujo son diferentes de las que se encuentran en un ambiente saturado, por lo que se deben reexaminar los modelos físicos y matemáticos que describen el comportamiento del flujo. Antes de describir el comportamiento de los suelos insaturados, es necesario entender por qué es importante estudiarlos. Al respecto, Meza (2011) señala que uno de los principales problemas asociados a los suelos no saturados son los suelos expansivos o activos, que son “suelos arcillosos que cambian de volumen debido a cambios en el contenido de humedad”. “Estos cambios de volumen conducen a daños como grietas en estructuras relativamente ligeras como casas, pavimentos, alcantarillas, etc.

Para comprender mejor el efecto del grado de saturación y el grado de succión sobre la conductividad hidráulica, se muestra la siguiente ecuación.

$$vA_t = v_s A_w; \text{ o bien } v = S n v_s$$

Donde:

S : es el grado de saturación

A_w : es el área de poros que contienen agua

n : corresponde a la porosidad del suelo

Dado que ahora se sabe que la conductividad hidráulica del agua en suelos no saturados es una función matemática y, por lo tanto, la forma básica de la ley de Darcy no describe correctamente esta condición, es necesario aplicar una modificación para incluir una función. Al respecto, Espinoza (2005) sugiere que la relación equivalente es la ley de Darcy Buckingham, es la siguiente ecuación que se muestra a continuación:

$$v = -k\theta \frac{dh}{dl} \quad \text{o} \quad v = -k(\psi) \frac{dh}{dl}$$

Donde:

$k\theta$: es la conductividad hidráulica en función del grado de saturación

$k(\psi)$: es la conductividad hidráulica en función de la succión

$\frac{dh}{dt}$: corresponde al gradiente hidráulico

2.1.5.3. Ecuación de Richards

Por tanto, la ecuación de Richards es una relación equivalente para resolver problemas de flujo en suelos no saturados. Esta ecuación supone las funciones de conductividad en escenarios de saturación. En este sentido, Lu y Likos (2004) sugieren que se ha desarrollado un gran número de modelos matemáticos basados en una función no de conductividad hidráulica insaturada, conjuntos de datos experimentales limitados para predecir esta función, o particularmente la curva característica suelo-agua.

Tomando en consideración la ley de la conservación de la masa, nos dice que la masa total de un sistema cerrado se mantiene constante. En el caso de un fluido, esto significa que la masa que entra en un volumen determinado debe ser igual a la masa que sale del mismo volumen. Considerando esto, la suma de los cambios en el flujo de masa en las direcciones x, y, z (representados por pv) debe ser igual a la tasa de cambio de la masa de fluido en un volumen determinado ($p\theta$).

$$\frac{d(pv)_x}{dx} + \frac{d(pv)_y}{dy} + \frac{d(pv)_z}{dz} = \frac{d(p\theta)}{dt}$$

La ecuación anterior se puede expresar también de la siguiente forma:

$$\frac{d vx}{dx} + \frac{d vy}{dy} + \frac{d vz}{dz} = \frac{d \theta}{dt}$$

Al sustituir la ley de Darcy Buckingham en la ecuación anterior se genera la ecuación de Richards en tres dimensiones, esta ecuación se representa de la siguiente manera:

$$\frac{d}{dt} \left(k(\psi) \cdot \frac{d\psi}{dx} \right) + \frac{d}{dt} \left(k(\psi) \cdot \frac{d\psi}{dy} \right) + \frac{d}{dt} \left(k(\psi) \cdot \frac{d\psi}{dz} + 1 \right) = C(\psi) \frac{d\psi}{dt}$$

Donde:

$C(\psi) \frac{d\psi}{dt}$: Es la capacidad específica del suelo

2.3. Marco Conceptual

2.3.1. Modelos Predictivos

Los modelos predictivos son herramientas estadísticas y matemáticas que analizan patrones históricos y actuales de datos para prever futuros comportamientos o resultados. Utilizando algoritmos y técnicas como la regresión, clasificación y aprendizaje automático, estos modelos identifican relaciones y tendencias subyacentes en los datos. Son ampliamente aplicados en diversos campos como finanzas, salud y climatología, ayudando en la toma de decisiones informadas, ya que su capacidad para anticipar eventos futuros los hace esenciales en la planificación y optimización de procesos (Parisi et al., 2003).

2.3.2. Modelos Estadísticos

Los modelos estadísticos son representaciones matemáticas que describen la relación entre variables en un conjunto de datos. Sirven para analizar y predecir fenómenos, asumiendo ciertas condiciones y patrones en la información. Estos modelos utilizan técnicas como la regresión, análisis de varianza y series temporales para inferir, testear hipótesis y estimar parámetros. Son fundamentales en campos como la economía, biología y ciencias sociales, facilitando la comprensión de complejidades y la toma de decisiones basada en datos. Su precisión y fiabilidad dependen de la calidad y cantidad de datos disponibles (Núñez et al., 2011).

2.3.3. Modelos Computacionales

Los modelos computacionales son representaciones simuladas de sistemas reales, creados mediante algoritmos y ejecutados en computadoras. Permiten la experimentación y análisis de fenómenos complejos en un entorno virtual controlado. Estos modelos pueden ser desde simples ecuaciones matemáticas hasta simulaciones detalladas de procesos físicos, biológicos o sociales. Son esenciales en áreas como la meteorología, ingeniería y ciencias cognitivas, proporcionando insights profundos, optimizando procesos y prediciendo resultados. Su efectividad se potencia con el avance tecnológico, permitiendo simulaciones cada vez más precisas y detalladas (Núñez et al., 2011).

2.3.4. Impacto Ambiental

El impacto ambiental se refiere a las alteraciones en el medio ambiente provocadas por la acción humana o fenómenos naturales. Incluye cambios en la biodiversidad, recursos hídricos, calidad del aire, suelos y ecosistemas. Puede ser positivo o negativo, aunque frecuentemente se asocia con daños como contaminación, deforestación y extinción de especies. La evaluación de impacto ambiental es crucial para planificar y mitigar efectos adversos en proyectos de desarrollo (Guillén et al., 2020).

2.3.5. Sostenibilidad

La sostenibilidad es una filosofía y práctica de desarrollo que busca satisfacer las necesidades actuales sin comprometer la capacidad de futuras generaciones para atender las suyas. Integra aspectos económicos, sociales y ambientales, promoviendo un equilibrio entre crecimiento y conservación. Su enfoque abarca la gestión responsable de recursos, reducción de la huella ambiental y fomento de la equidad social. Aplicada en múltiples sectores, desde la agricultura hasta la industria, la sostenibilidad es clave para un futuro resiliente y próspero, asegurando la armonía entre la humanidad y el planeta (Guillén et al., 2020).

2.3.6. Condición climática

Las condiciones climáticas son el estado actual de la atmósfera en un lugar determinado. Están definidos por varias variables como la temperatura, la presión atmosférica, la humedad, el viento, las precipitaciones y la nubosidad. Estas variables pueden variar de un lugar a otro y de un momento a otro. Estas variaciones pueden deberse a varios factores como la latitud, la altitud, la distancia al mar, las corrientes marinas y la topografía (Guillén et al., 2020).

III. MÉTODO DE LA INVESTIGACIÓN

3.1. Enfoque

La presente investigación presenta un enfoque cuantitativo. Según Hernández et al. (2014), un enfoque cuantitativo se centra en la recopilación y análisis de datos numéricos para establecer patrones, probar teorías o hipótesis, y producir resultados precisos y confiables.

Este enfoque permite una evaluación objetiva y precisa del rendimiento del sistema, facilitando la toma de decisiones basada en datos concretos. Al emplear modelos matemáticos y estadísticos, la investigación cuantifica el impacto de distintos factores en la eficiencia del riego, promoviendo soluciones basadas en evidencia para la optimización de recursos hídricos.

3.2. Alcance

Este estudio se caracteriza por tener un alcance explicativo y aplicado. De acuerdo con Tamayo (2003) este tipo de alcance se enfoca en entender las causas y efectos de fenómenos específicos y en aplicar ese conocimiento para resolver problemas prácticos

Desde una perspectiva explicativa, busca entender y establecer las relaciones causales entre la conductividad hidráulica y el rendimiento del sistema de riego, utilizando un modelo predictivo para detallar cómo diversos factores interactúan y afectan este sistema.

Desde el punto de vista aplicado, el estudio trasciende la teoría al implementar el modelo predictivo desarrollado para mejorar prácticamente el sistema de riego en la Laguna Huanzo. Esto implica no solo predecir comportamientos bajo ciertas condiciones sino también aplicar estos conocimientos para optimizar el uso del agua en la agricultura, lo cual puede tener un impacto directo y significativo en la eficiencia del riego, la productividad agrícola, y la sostenibilidad de los recursos hídricos en la región.

3.3. Diseño de investigación

Esta investigación presenta un diseño de investigación no experimental. Según Hernández et al. (2014), este tipo de diseño de investigación se centra en analizar fenómenos tal como ocurren naturalmente, sin intervención o manipulación por parte del investigador.

La creación de un modelo predictivo a menudo implica recopilar y analizar datos existentes para identificar patrones y relaciones, en lugar de controlar activamente las variables de interés, como se haría en un diseño experimental. En este caso, se recogerían y analizarían datos sobre la conductividad hidráulica para desarrollar el modelo predictivo, sin alterar intencionadamente las condiciones del sistema de riego durante la fase de recolección de datos.

3.4. Población y muestra

3.4.1. Población

Todos los sistemas de riego ubicados dentro de la jurisdicción de la Autoridad Administrativa del Agua XI Pampas - Apurímac, específicamente bajo la Administración Local del Agua Bajo Apurímac - Pampas.

3.4.2. Muestra

La muestra en esta investigación es el sistema de riego Laguna Huanzo, ubicando en el Distrito de Santiago de Lucanamarca, entre las comunidades de Santa Rosa de Ccocha, Lucanamarca y Asunción de Erpa

Para hallar la muestra se ha utilizado el muestreo por conveniencia debido a la facilidad de acceso de información que se posee sobre el sistema de riego Laguna Huanzo para el desarrollo de esta investigación.

3.5. Hipótesis

3.5.1. Hipótesis general

La aplicación de un modelo predictivo de conductividad hidráulica mejorará la eficiencia del sistema de riego Laguna Huanzo, optimizando el uso del agua en el distrito de Santiago, provincia de Huanca Sancos, Ayacucho.

3.5.2. Hipótesis específicas

- Las propiedades del suelo y las condiciones climáticas en el distrito de Santiago, provincia de Huanca Sancos, tienen una correlación significativa con los patrones de conductividad hidráulica, lo que permite su utilización como predictores confiables en el modelo.

- La aplicación de la ecuación de Richards para modelar el movimiento del agua mejora significativamente la precisión de las estimaciones de conductividad hidráulica en comparación con modelos que no consideran la dinámica del movimiento del agua.
- La integración del modelo matemático basado en la ecuación de Richards con el algoritmo de aprendizaje automático K-NN resulta en una optimización significativa de la predicción de la conductividad hidráulica.
- Las simulaciones de escenarios utilizando el modelo desarrollado confirman su validez, mostrando que las predicciones de conductividad hidráulica se alinean estrechamente con los datos observados en condiciones variadas.

3.6. Operacionalización de variables, definición conceptual y operacional

a) **Variable Independiente:** Características del sistema de riego

Definición Operacional: Es el conjunto de atributos o características funcionales que componen el sistema de riego. Estas características se evalúan mediante condiciones climáticas, características físicas y químicas que estén relacionados con operadores del sistema, con el objetivo de identificar factores clave que influyen en la conductividad hidráulica y, por ende, en la eficacia del riego en la zona de estudio.

b) **Variable Dependiente:** Conductividad hidráulica

Definición Operacional: Es la medida de la capacidad del suelo para permitir el paso del agua a través de sus poros, bajo condiciones controladas. Se cuantificará mediante técnicas como la ecuación de Richards y algoritmos de aprendizaje. Estos datos permitirán evaluar cómo las características físicas y químicas del suelo impactan en su capacidad para conducir agua, esencial para la optimización del sistema de riego en el área de estudio.

Tabla 1

Cuadro de Operacionalización de variables

Operacionalización de las Variables: "DESARROLLO DE UN MODELO PREDICTIVO DE CONDUCTIVIDAD HIDRÁULICA PARA OPTIMIZAR EL SISTEMA DE RIEGO LAGUNA HUANZO, DISTRITO DE SANTIAGO - PROVINCIA DE HUANCA SANCOS -AYACUCHO"								
VARIABLES	DEFINICION CONCEPTUAL	TIPO	NATURALEZA	MEDICIÓN	DIMENSIÓN	INDICADORES	UNIDAD DE MEDIDA	INSTRUMENTO
Características del sistema de riego	Los parámetros del suelo y del sistema de riego interactúan entre sí para determinar la relación con las necesidades del cultivo, y el uso de recursos hídricos.	Independiente	Cuantitativa	Nominal	Condición climática	Precipitación Temperatura	mm °C	Ficha de registro de recolección de datos.
					Características físicas	Porosidad del suelo Estructura del suelo	%	
					Características químicas	Salinidad pH del suelo	dS/m	
Conductividad hidráulica	Es la capacidad de un material, como el suelo o una roca, para transmitir agua. Cuantifica la facilidad con la que el agua se mueve a través de los poros o fisuras del material bajo un gradiente de presión, influyendo directamente en la dinámica del flujo subterráneo.	Dependiente	Cuantitativa	Nominal	Capacidad de simular y predecir el movimiento del agua en el suelo	Ecuación de Richards	m ³ /s	Software estadístico (R y Excel)
						Algoritmo de aprendizaje K-NN	%	Software de Machine Learning (Python)
						Movimiento del agua	m ³ /s	

Nota. Elaboración propia

3.7. Técnicas e instrumentos

3.7.1. Técnicas

- **Revisión de registros de Datos Secundarios:** Revisión de estudios previos, informes técnicos y publicaciones científicas sobre la conductividad hidráulica en áreas similares o en la misma región.
- **Análisis Estadístico:** Empleo de técnicas estadísticas para analizar y predecir patrones de conductividad hidráulica a partir de un conjunto de datos.
- **Machine Learning:** Aplicación de algoritmos de aprendizaje automático para desarrollar modelos predictivos basados en grandes volúmenes de datos históricos.

3.7.2. Instrumentos

- Software estadístico (R y Excel)
- Software de Machine Learning (Python)
- Fichas de registro de recolección de datos

3.8. Técnicas estadísticas para el procesamiento de la información

- **Análisis descriptivo:** Estadísticas básicas como media, mediana, moda, desviación estándar, y rango para entender las características generales de los datos.
- **Análisis multivariante:** Análisis de componentes principales (PCA) para reducir la dimensionalidad de los datos y detectar las estructuras subyacentes.
- **Modelado predictivo y Machine Learning:** Algoritmos de aprendizaje supervisado como regresión logística, bosques aleatorios y redes neuronales para construir modelos predictivos.

3.9. Desarrollo del trabajo de tesis

3.9.1. Antecedente del área de estudio

Ubicado en la provincia de Huanca Sancos, en la región de Ayacucho, el distrito de Lucanamarca se distingue por sus variadas condiciones agroclimáticas que favorecen una amplia gama de cultivos y la cría de ganado, gracias a su particular geografía. La economía local se basa principalmente en la agricultura y la ganadería,

enfrentándose a desafíos que restringen su expansión y avance, siendo la falta de recursos hídricos para la agricultura una de las principales limitantes. En el contexto de esfuerzos previos para proveer agua a las comunidades de Santa Rosa de Ccocha, Lucanamarca y Asunción de Erpa, se destacan iniciativas como:

- En 2013, el Proyecto Especial Sierra Centro Sur, perteneciente al Ministerio de Agricultura y Riego, realizó la formulación de estudios de pre-inversión a nivel de perfil para el proyecto “Instalación del Servicio de Agua del Sistema de Riego de la Laguna Huanzo, Distrito de Lucanamarca, Provincia de Huanca Sancos, Región Ayacucho”, que fue aprobado.
- Posteriormente, en 2015, el mismo proyecto lanzó un proceso de selección bajo el código “AMC - N°005-2015-MINAGRI” para elaborar el estudio de factibilidad sobre la “Instalación del Servicio de Agua del Sistema de Riego de la Laguna Huanzo” en el mismo distrito.

3.9.2. Ubicación del área en estudio

3.9.2.1. Ubicación Política

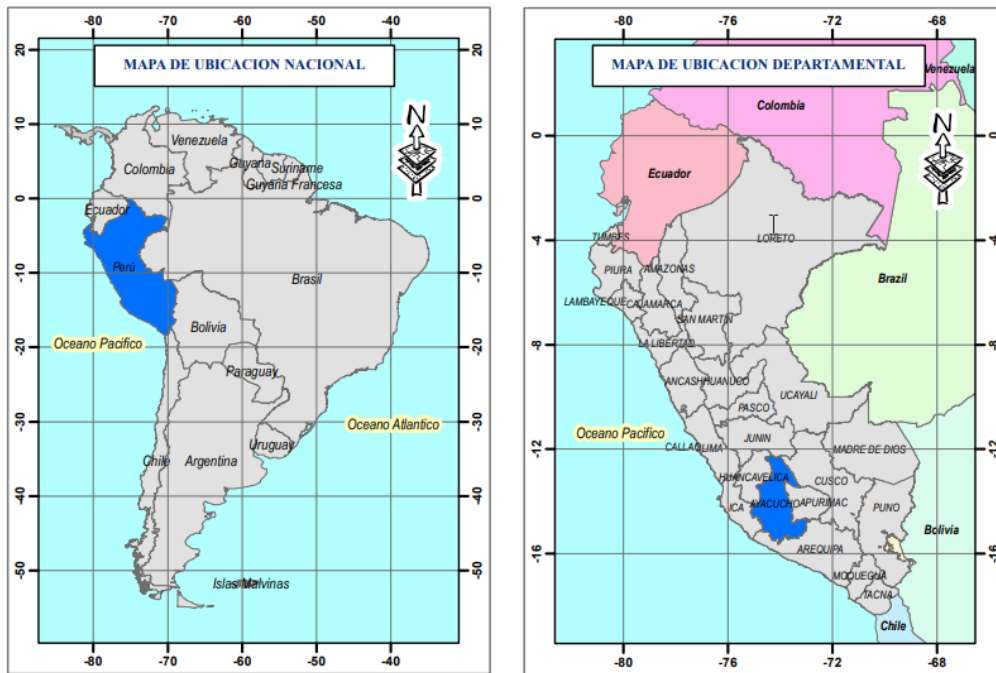
El sistema de Riego de la Laguna Huanzo se encuentra ubicado en:

Tabla 2
Ubicación Política

Departamento	Ayacucho.
Provincia	Huanca Sancos
Distrito	Santiago de Lucanamarca
C. Campesina	Lucanamarca
Sectores	Santa Rosa de Ccocha, Lucanamarca y Asunción de Erpa.

Nota. Elaboración Propia

Figura 5
 Mapa de ubicación nacional y regional



Nota. Tomado de (Auccasi, 2021).

El distrito de Lucanamarca se encuentra en la provincia de Huanca Sancos, dentro del departamento de Ayacucho. Cuenta con una superficie de 658.26 kilómetros cuadrados y alberga a 2,068 residentes. Sus fronteras geográficas y políticas son las siguientes:

- Por el Norte: Provincia de Víctor Fajardo.
- Por el Sur: Distrito de Sancos.
- Por el Este: Provincia de Víctor Fajardo y Distrito de Carapo.
- Por el Oeste: Distrito de Sancos

El proyecto principal que beneficia la región se sitúa en el distrito de Santiago de Lucanamarca. A nivel comunitario, este proyecto impacta las áreas de las comunidades de Santa Rosa de Ccocha, Lucanamarca y Asunción de Erpa, aprovechando los recursos hídricos de la microcuenca de la Laguna Huanzo, cuyas aguas fluyen hacia el río Pampas.

Figura 6
Ubicación Provincial



Nota. Tomado de (Auccasi, 2021).

3.9.2.2. Ubicación Administrativa

Según la información proporcionada por la Autoridad Administrativa del Agua (AAA), el proyecto se encuentra en la zona que pertenece a la jurisdicción de la Autoridad Administrativa del Agua XI Pampas - Apurímac y está bajo la gestión de la Administración Local del Agua Bajo Apurímac - Pampas.

3.9.3. Delimitación del Área de Estudio

La cuenca Huanzo se origina en las quebradas Angostura y Paria, dando lugar al río Mayocancar. Este río, en su curso hacia aguas abajo, recibe diferentes nombres: primero como río Poccohuaycco, luego como río Lucanamarca, posteriormente como río Caracha, antes de finalmente desembocar en el río Pampas. La delimitación de la microcuenca del río Huanzo incluye los cerros Huamanripayoc, Yuracc Orcco, Yana Ucsha, Salcantuyoc, Orpuna, Jatun Jenhua y Jeronta, abarcando un patrón de drenaje dendrítico. Esta microcuenca tiene una forma generalmente circular, ampliándose hacia la parte superior, con un área total de drenaje de 34.97 km² y una longitud máxima de 9.78 km desde sus fuentes. El proyecto de embalse propuesto se sitúa en la cuenca Huanzo, reforzado por el trasvase de las cuencas Yanacollpa y Huaccrahuaycco, que cubren un área de 48.09 km² y una longitud de 10.09 km.

Figura 7

Microcuenca del río Huanzo



Nota. Elaboración Propia

3.9.4. Acceso y vías de comunicación

El área de estudio se puede alcanzar partiendo desde la ciudad de Ayacucho, tomando la ruta Ayacucho - Cangallo - Huancapi - Huancasancos - Lucanamarca - Presa Huanzo, con un tiempo estimado de viaje de aproximadamente 5 horas. De manera similar, desde la ciudad de Ica, el acceso se realiza a través de la ruta Ica - Palpa Huac-Huas - Huancasancos - Lucanamarca - Presa Huanzo, lo cual toma alrededor de 7 horas.

Tabla 3

Acceso a la Zona de estudio

Tramos	Longitud	Horas	Tipo de Vía
Ayacucho Huanca - Sancos	148 km	4.00 hrs	Carretera Asfaltada
Huanca Sancos - Lucanamarca	40 km	2.00 hrs	Carretera Asfaltada
Lucanamarca - Laguna	30 km	1.00 hrs	Trocha carrozable
Total	218 km	6.00 hrs	

Nota. Elaboración Propia

Figura 8

Tramo a la zona de estudio



Nota. Elaboración Propia

3.9.5. Metodología Propuesta

La metodología utilizada en esta investigación consta del desarrollo de los objetivos específicos, los cuales presentan la siguiente conexión:

- **OBJ. 1: Correlación de las propiedades del suelo y condiciones climáticas**
Este objetivo se enfoca en entender cómo los parámetros la temperatura, humedad, permeabilidad del suelo interactúan con las condiciones climáticas para influir en la conductividad hidráulica.
- **OBJ. 2: Ecuación de Richards para realizar un modelo matemático del movimiento del agua**

La Ecuación de Richards es una ecuación diferencial parcial que describe el flujo de agua a través de medios porosos, como el suelo. Este objetivo se centra en la aplicación de esta ecuación para desarrollar un modelo matemático que pueda simular el movimiento del agua a través del suelo en función de las propiedades y condiciones identificadas en el OBJ. 1.

▪ **OBJ. 3: Desarrollo de algoritmo de aprendizaje automático (K-NN)**

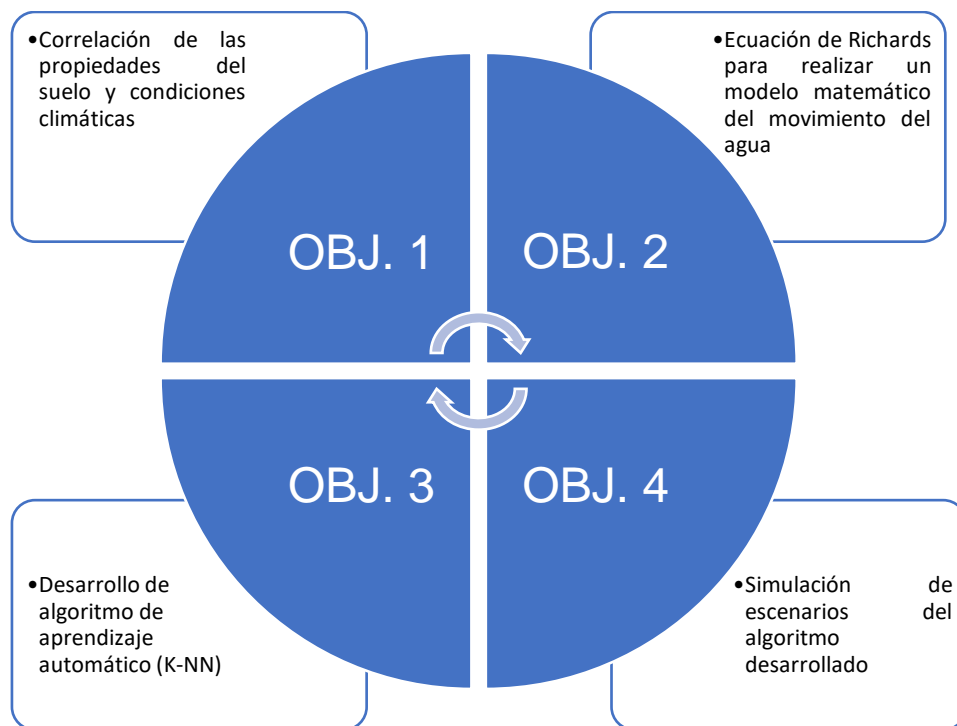
Aquí, el enfoque se traslada a la construcción de un algoritmo de aprendizaje automático utilizando K-Nearest Neighbors (K-NN), un método de aprendizaje supervisado. El objetivo es crear un algoritmo que pueda predecir la conductividad hidráulica a partir de los datos de entrada, utilizando las correlaciones y los modelos matemáticos previamente establecidos.

▪ **OBJ. 4: Simulación de escenarios del algoritmo desarrollado**

El último objetivo se enfoca en la simulación de escenarios utilizando el algoritmo de K-NN desarrollado.

Figura 9

Metodología Propuesta de la Solución



Nota. Elaboración Propia

Para evaluar algunos parámetros del suelo y condiciones climáticas según la metodología de la solución, se realizó una visita de campo a la zona de estudio (Ver Anexo N° 8).

3.9.6. Análisis de la región de estudio

3.9.6.1. Parámetros Geomorfológicos

Los parámetros geomorfológicos clave evaluados para la cuenca de la Presa Huanzo incluyen:

a) Aspectos relacionados con la configuración de la cuenca, tales como el coeficiente de compacidad (Kc), el factor de forma (Kf) y características del sistema de drenaje (como tipos de corrientes, clasificación de las corrientes por su orden y la densidad de drenaje).

b) Atributos del relieve de la cuenca, que abarcan la curva hipsométrica, la altitud promedio de la cuenca, la inclinación general de la cuenca, el rectángulo equivalente y la pendiente del curso de agua principal.

Tabla 4
Parámetros Geomorfológicos de la Cuenca Huanzo

NOMBRE DE CUENCA	PERÍMETRO (m)	ÁREA (m ²)	Rectángulo Equivalente		L (m)	L _{CG} (m)	FACTOR DE FORMA F = A/L ²	INDICE DE COMPACIDAD K = 0.28P/√A
			L'	I'				
CUENCA HUANZO	30215.958	34966375.4	2853.311	12254.668	9771.6315	5779.082	0.366	1.431

NOMBRE DE CUENCA	Sistema de Drenaje			Elevación Media de la Cuenca	COTA MAYOR	COTA MENOR	DH (m)	Pendiente del Cauce Principal
	Orden de Corriente	Tipos de corriente	Densidad de Drenaje					
CUENCA HUANZO	30215.958	34966375.4	2853.311	12254.668	9771.6315	5779.082	0.366	1.431

Nota. Estudio Hidrológico del Proyecto. Fuente (AGUA Y AGRO ASESORES ASOCIADOS S.A.C.)

Este fenómeno contribuye a la ocurrencia de lluvias moderadas de forma constante durante todo el año, al mismo tiempo que disminuye significativamente los procesos de evaporación y evapotranspiración.

En cuanto a la estación Pampahuasi, se detalla la humedad relativa mensual en el cuadro proporcionado, destacando su fluctuación a lo largo de los distintos meses, lo que permite un análisis más detallado de las condiciones climáticas prevalecientes.

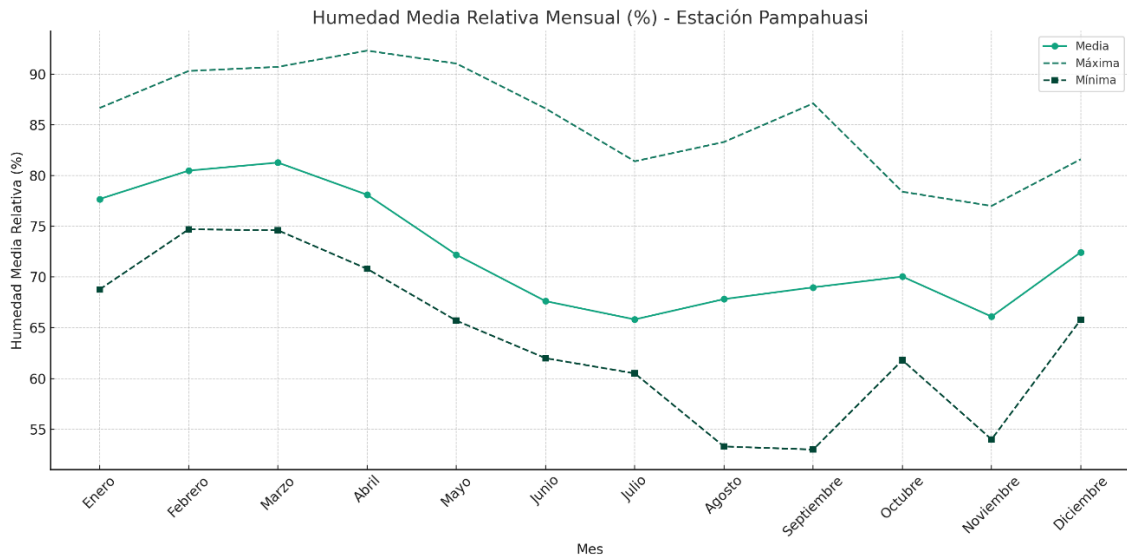
A continuación, se muestra la humedad relativa mensual en porcentaje (%).

Tabla 5*Humedad Media Relativa Mensual (%)*

"Humedad Media Relativa Mensual (%) - Estación Pampahuasi"												
ESTACIÓN: PAMPAHUASI CÓDIGO: 008			DISTRITO: LUCANAS		ALTITUD: 3650 msnm							
			PROVINCIA: LUCANAS		LATITUD: 14°30'00" S							
			DEPARTAMENTO: AYACUCHO		LONGITUD: 74°15'00"O							
AÑO	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC
1995	S/D	75.80	78.60	75.00	65.70	64.70	61.20	60.30	65.90	61.80	70.20	70.60
1996	81.00	84.10	81.40	77.60	70.50	63.80	60.50	68.90	69.40	73.30	67.60	78.20
1997	79.90	82.30	83.80	76.30	72.30	62.00	63.50	73.30	69.50	72.40	77.00	81.60
1998	86.65	90.30	90.70	92.30	91.03	86.60	81.40	83.30	87.10	78.40	61.70	66.00
1999	68.77	75.70	74.60	76.60	67.60	65.20	62.50	53.30	53.00	64.30	54.00	65.80
2000	72.06	74.70	78.50	70.80	66.00	63.40	S/D	S/D	S/D	S/D	S/D	S/D
MED.	77.68	80.48	81.27	78.10	72.19	67.62	65.82	67.82	68.98	70.04	66.10	72.44
MAX.	86.65	90.30	90.30	92.30	91.03	86.60	81.40	83.30	87.10	78.40	77.00	81.60
MIN.	68.77	74.70	74.60	70.80	65.70	62.00	60.50	53.30	53.00	61.80	54.00	65.80
D.S.	32.36	6.18	5.56	7.35	9.59	9.37	28.00	29.57	30.20	29.24	28.09	30.26

Nota. Elaboración propia con datos del SENAMHI. Fuente PESCS (Proyecto Especial Sierra Centro Sur) y De La Cruz (2022).

Figura 10
Variación de la Humedad Media Relativa Mensual



Nota. Elaboración Propia

3.9.6.2. Pérdida por Infiltración

La estimación de la infiltración se ha basado en los datos obtenidos a partir de los ensayos de permeabilidad como se observa en la tabla 6.

Tabla 6
Resumen de los Ensayos de Permeabilidad

SONDAJE	Nº DE ENSAYO	PROFUNDIDAD (m)	GRADO DE PERMEABILIDAD	TIPO DE ENSAYO
P - 01	1	3.00 - 5.00	3.20E-04 cm/s	Lefranc
	2	8.00 - 10.00	1.45E-04 cm/s	Lefranc
	3	13.00 - 15.00	2.02E-05 cm/s	Lefranc
	4	18.00 - 20.00	2.63E-05 cm/s	Lefranc
	5	23.00 - 25.00	4.28E-04 cm/s	Lefranc
	6	28.00 - 30.00	2.50E-04 cm/s	Lefranc
P - 02	1	3.00 - 5.00	2.62E-04 cm/s	Lefranc
	2	8.00 - 10.00	3.17E-05 cm/s	*Lefranc V
	3	13.00 - 15.00	3.88E-03 cm/s	*Lefranc V
	4	18.00 - 20.00	4.36E-05 cm/s	*Lefranc V
	5	23.00 - 25.00	2.68E-05 cm/s	*Lefranc V

	6	28.00 - 30.00	1.79E-03 cm/s	*Lefranc V
P - 03	1	3.00 - 5.00	1.16E-03 cm/s	Lefranc
	2	8.00 - 10.00	5.02E-04 cm/s	Lefranc
	3	13.00 - 15.00	6.26E-04 cm/s	Lefranc
	4	18.00 - 20.00	4.67E-04 cm/s	Lefranc
	5	23.00 - 25.00	2.50E-04 cm/s	Lefranc
	6	28.00 - 30.00	1.96E-04 cm/s	Lefranc
P - 04	1	3.00 - 5.00	1.50E-04 cm/s	Lefranc
	2	8.00 - 10.00	4.53E-04 cm/s	Lefranc
	3	13.00 - 15.00	1.89E-04 cm/s	Lefranc
	4	18.00 - 20.00	1.83E-04 cm/s	Lefranc
	5	23.00 - 25.00	2.02E-04 cm/s	Lefranc
	6	28.00 - 30.00	1.77E-04 cm/s	Lefranc
P - 05	1	3.00 - 5.00	4.11E-04 cm/s	Lefranc
	2	8.00 - 10.00	1.94E-04 cm/s	Lefranc
	3	13.00 - 15.00	6.09E-04 cm/s	Lefranc
	4	18.00 - 20.00	2.85E-04 cm/s	Lefranc
	5	23.00 - 25.00	3.35E-05 cm/s	Lefranc
	6	28.00 - 30.00	3.73E-05 cm/s	Lefranc

Nota. Datos tomados del informe técnico N° 0015-2022-ANA-AAA.PA/HTP. Fuente PESCS (Proyecto Especial Sierra Centro Sur) y De La Cruz (2022).


Se ha establecido un Coeficiente de Permeabilidad de 3×10^{-5} cm /s, junto con un área de infiltración de $5000 m^2$. Los resultados de la infiltración mensual estimada se presentan en la tabla siguiente:

Tabla 7
Infiltración (MMC)

MES	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC
PROM	0.00402	0.00363	0.00402	0.00389	0.00402	0.00389	0.00402	0.00402	0.00389	0.00402	0.00389	0.00402

Nota. Datos tomados del informe técnico N° 0015-2022-ANA-AAA.PA/HTP. Fuente PESCS (Proyecto Especial Sierra Centro Sur) y De La Cruz (2022).

Figura 11
Variación en la Infiltración Mensual (MMC)



Nota. Elaboración Propia

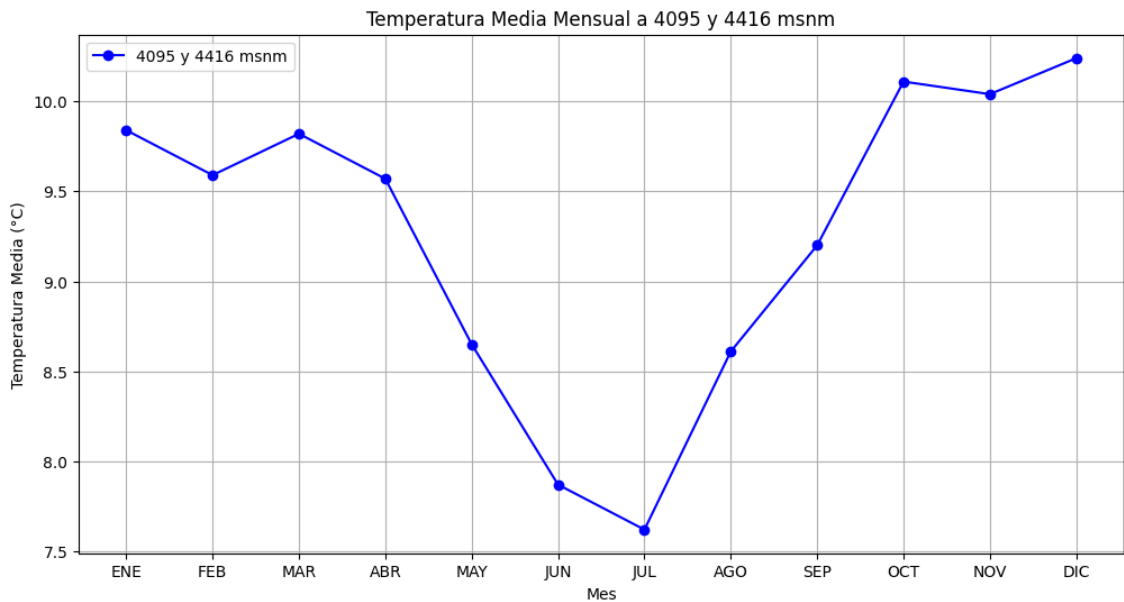
La tabla 8 proporciona un registro de la temperatura media mensual generada en dos localidades una a 4095 metros sobre el nivel del mar (msnm) y otra a 4416 msnm. A estas alturas, las temperaturas son notablemente más bajas que en áreas más bajas debido a la disminución de la presión atmosférica y los cambios en la composición del aire.

Tabla 8
Temperatura Media Mensual

TEMPERATURA MEDIA MENSUAL GENERADA A 4095 msnm													
Temperatura Media (°C)													
Años	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC	Prom.
Prom.	9.84	9.59	9.82	9.57	8.65	7.87	7.62	8.61	9.2	10.11	10.04	10.24	9.26
TEMPERATURAS MEDIAS MENSUALES A 4416 msnm													
ESTACIÓN	ALTITUD (msnm)	MESES											
		ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC
GENERADA	4416	9.84	9.59	9.82	9.57	8.65	7.87	7.62	8.61	9.20	10.11	10.04	10.24

Nota. Datos tomados del informe técnico N° 0015-2022-ANA-AAA.PA/HTP. Fuente PESCS (Proyecto Especial Sierra Centro Sur) y De La Cruz (2022).

Figura 12
Temperatura Media Mensual



Nota. Elaboración Propia

3.9.6.3. Análisis Físicos y Químicos

La tabla 9 proporciona una descripción detallada de la composición química y física del agua en el Sistema de Riego Laguna Huanzo, en términos de los cationes y aniones que contiene, así como varias otras medidas que son críticas para evaluar su calidad para diversos usos, especialmente en la agricultura.

En la sección de cationes, que son los iones con carga positiva, encontramos que el calcio (Ca^{2+}) y el magnesio (Mg^{2+}) están presentes en concentraciones relativamente altas, con 10.7 y 3.5 miliequivalentes por litro (meq/L), respectivamente. Estos elementos son importantes para el agua, ya que afectan su dureza y pueden tener implicaciones en el uso del agua para riego, dado que pueden influir en el suelo y en la salud de las plantas. El potasio (K^+), un nutriente esencial para las plantas, y el sodio (Na^+), que puede afectar negativamente la estructura del suelo a altas concentraciones, se encuentran en concentraciones mucho más bajas. El amonio (NH_4^+) no está presente en el agua según los datos proporcionados.

En cuanto a los aniones, que son iones con carga negativa, el bicarbonato (HCO_3^-) es el más prevalente con 6.05 meq/L, seguido por los sulfatos (SO_4^{2-}) con 8.79 meq/L. La presencia de estos aniones es relevante para el equilibrio del pH y la salinidad del agua. Los cloruros (Cl^-) están presentes en una concentración más baja, y tanto los carbonatos (CO_3^{2-}) como los fosfatos (PO_4^{3-}) y los nitratos (NO_3^-) están ausentes.

Entre las otras determinaciones, el pH de 7.28 indica que el agua está ligeramente alcalina, lo cual puede afectar la disponibilidad de nutrientes en el suelo. La conductividad eléctrica (CE) es de 1.63 deciSiemens por metro (dS/m), lo que sugiere una salinidad moderada; este es un aspecto importante a considerar para el riego, ya que la salinidad excesiva puede dañar las plantas y degradar la calidad del suelo. Los sólidos en suspensión y las sales solubles totales, con valores de 0.282 gramos por litro y 1489 partes por millón, respectivamente, ofrecen información adicional sobre la cantidad de material suspendido y soluble en el agua. La relación de adsorción de sodio (4.66) y la dureza total (110 ppm de CaCO_3) son factores adicionales que influyen en la calidad del agua para el riego, ya que altas concentraciones de sodio pueden afectar adversamente la estructura del suelo, mientras que el agua dura puede depositar calcio y magnesio, que también pueden impactar el suelo y la infraestructura de riego.

Tabla 9
Parámetros Químicos y Físicos

DETERMINACIONES	Unidad	Valor
CATIONES (meq/Litro)		
CALCIO (Ca^{2+})	meq/L	10.7
MAGNESIO (Mg^{2+})	meq/L	3.5
POTASIO (K^+)	meq/L	0.26
SODIO (Na^+)	meq/L	2.48
AMONIO (NH_4^+)	meq/L	0
ANIONES (meq/Litro)		
BICARBONATOS (HCO_3^-)	meq/L	6.05
CARBONATOS (CO_3^{2-})	meq/L	0
CLORUROS (Cl^-)	meq/L	2.06
FOSFATOS (PO_4^{3-})	meq/L	0
NITRATOS (NO_3^-)	meq/L	0
SULFATOS (SO_4^{2-})	meq/L	8.79
OTRAS DETERMINACIONES		
pH		7.28
M.O.	mg/L	1.02
CE (dS/m)	dS/m	1.63
Sólidos en Suspensión (g/litro)	g/litro	0.282
Sales Solubles Totales (ppm)	ppm	1489

Relación de Adsorción de Sodio		4.66
Dureza Total (ppm CaCO₃)	ppm CaCO ₃	110
CLASIFICACIÓN		C3-S1

Nota. Elaboración a partir de la información presentada en el Anexo 6.

La clasificación de la calidad del agua como C3-S1 sugiere que esta agua tiene una salinidad alta (C3) pero una baja peligrosidad de sodio (S1), lo que implica que puede ser usada para riego en suelos con buen drenaje y donde los cultivos sean moderadamente tolerantes a la sal. Sin embargo, puede ser necesario un manejo cuidadoso del agua y del suelo, y posiblemente tratar el agua o ajustar las prácticas de riego para evitar daños a largo plazo a los cultivos y al suelo.

La materia orgánica se define en un valor de 1.02, esto indica una similitud al parámetro de 1.2, presentada en la tabla 10, lo que demuestra que tiene una textura franco arenosa, con una densidad aparente de $1.80g \cdot cm^{-3}$.

Tabla 10
Clasificación de la materia orgánica

Superficie	Arena	Limo	Arcilla	Materia orgánica	Carbonatos totales	Textura	Densidad aparente
	----- % -----						g cm ⁻³
Bosque	76	16	8	11.5	2.58	Franco arenosa	1.02
Pradera	68	14	18	6.2	3.80	Franco arenosa	1.50
Semi-desnuda	82	6	12	1.4	5.97	Franco arenosa	1.80

Nota. Información extraída de (González et al., 2011).

3.9.7. Desarrollo de la ecuación de Richards

Para derivar la Ecuación de Richards, inicialmente se combina la Ley de Darcy, que describe el flujo de agua en condiciones de no saturación dentro del suelo.

$$q = -K\nabla H \quad \text{Ecuación (1)}$$

Donde:

q = Densidad del flujo o descarga por unidad de área (cm/s)

K = Conductividad Hidráulica (cm/s)

H = Cabezal Hidráulico

∇ = Operador Diferencial

Esta derivación se representa de la siguiente forma:

$$q_i = -K(\theta) \frac{\partial H}{\partial x_i} \quad \text{Ecuación (2)}$$

El cabezal Hidráulico en la ecuación de Richards se interpreta mediante el símbolo ψ entonces la ecuación vendría a ser de la siguiente forma:

$$q_i = -K(\theta) \frac{\partial \psi}{\partial x_i} \quad \text{Ecuación (3)}$$

Donde:

$$q_i = q_x, q_y, y q_z$$

Para $i = 1,2,3$ y en conjunto con la Ecuación de Continuidad, que es la Ley de Conservación de la Masa.

$$\frac{\partial \theta}{\partial t} = -\nabla q \quad \text{Ecuación (4)}$$

Para crear lo que se conoce como la Ecuación General de Flujo No Saturado.

$$\frac{\partial \theta}{\partial t} = \frac{\partial}{\partial x} \left(K(\theta) \frac{\partial H}{\partial x} \right) + \frac{\partial}{\partial y} \left(K(\theta) \frac{\partial H}{\partial y} \right) + \frac{\partial}{\partial z} \left(K(\theta) \frac{\partial H}{\partial z} \right) \quad \text{Ecuación (5)}$$

Finalmente, la Ecuación de Richards que se utilizará en la presente investigación se forma al sustituir el Cabezal Hidráulico H con $\psi + z$ en la ecuación (5), de esta forma obtenemos:

$$\frac{\partial \theta}{\partial t} = \frac{\partial}{\partial x} \left(K(\theta) \frac{\partial \psi}{\partial x} \right) + \frac{\partial}{\partial y} \left(K(\theta) \frac{\partial \psi}{\partial y} \right) + \frac{\partial}{\partial z} \left(K(\theta) \frac{\partial \psi}{\partial z} + K(\theta) \right) \quad \text{Ecuación (6)}$$

Dado que θ se relaciona con ψ a través de la curva de retención agua-suelo, también es posible representar $K(\theta)$ como $K(\psi)$. Esto se logra mediante la introducción de la Capacidad Específica de Agua $C(\psi)$, lo que permite transformar la ecuación en una forma con una única variable dependiente.

$$\frac{\partial \theta}{\partial t} = \frac{d\theta}{d\psi} \cdot \frac{\partial \psi}{\partial y} = C(\psi) \frac{\partial \psi}{\partial t} \quad \text{Ecuación (7)}$$

Donde:

$C(\psi)$ = Capacidad específica de agua

Igualando a $\frac{d\theta}{d\psi}$ para la curva de retención agua-suelo

Reemplazando $K(\theta)$ y $K(\psi)$ y al reemplazar la ecuación (7) en la (6), se obtiene la siguiente ecuación:

$$C(\psi) \frac{\partial \theta}{\partial t} = \frac{\partial}{\partial x} \left(K(\psi) \frac{\partial \psi}{\partial x} \right) + \frac{\partial}{\partial y} \left(K(\psi) \frac{\partial \psi}{\partial y} \right) + \frac{\partial}{\partial z} \left(K(\psi) \frac{\partial \psi}{\partial z} \right) + \frac{\partial K(\psi)}{\partial z} \quad \text{Ecuación (8)}$$

La ecuación (8) representa la ecuación de Richards

En el caso de un flujo que sea horizontal y lineal, la ecuación (9) se simplifica a.

$$\frac{\partial \theta}{\partial t} = \frac{\partial}{\partial x} \left(K(\psi) \frac{\partial \psi}{\partial x} \right) \quad \text{Ecuación (9)}$$

En el caso de un flujo que sea vertical y no lineal, la ecuación (10) se simplifica a.

$$\frac{\partial \theta}{\partial t} = \frac{\partial}{\partial x} \left[K(\psi) \left(\frac{\partial \psi}{\partial x} + 1 \right) \right] \quad \text{Ecuación (10)}$$

Igualando a $\frac{\partial \psi}{\partial z}$ se puede representar de la siguiente forma:

$$\frac{\partial \psi}{\partial z} = \frac{\partial \psi}{\partial \theta} \cdot \frac{\partial \theta}{\partial z} \quad \text{Ecuación (11)}$$

Donde:

$\frac{\partial \psi}{\partial \theta}$ = Pendiente de la gráfica que representa la humedad (cantidad de agua o θ)

Para encontrar la difusividad del agua en el suelo reemplazamos la ecuación (11) en la (10), y de esta forma obtenemos lo siguiente:

$$\begin{aligned} \frac{\partial \theta}{\partial t} &= \frac{\partial}{\partial z} \left[K(\theta) \left(\frac{\partial \psi}{\partial \theta} \cdot \frac{\partial \theta}{\partial z} + 1 \right) \right] \\ \rightarrow \frac{\partial \theta}{\partial t} &= \frac{\partial}{\partial z} \left[D(\theta) \frac{\partial \theta}{\partial z} + K(\theta) \right] \\ \frac{\partial \theta}{\partial t} &= \frac{\partial}{\partial z} \left[D(\theta) \frac{\partial \theta}{\partial z} \right] + \frac{\partial}{\partial z} K(\theta) \end{aligned} \quad \text{Ecuación (12)}$$

Donde:

$D(\theta) = K(\theta) \frac{\partial \psi}{\partial \theta}$, es la difusividad del agua en el suelo

Observamos que la derivada parcial de ψ con respecto a θ , representada como $\frac{\partial \psi}{\partial \theta} = C(\theta)^{-1}$ corresponde al inverso de la capacidad específica del agua en el suelo, la cual es:

$$C(\theta) = \frac{\partial \theta}{\partial \psi}$$

Así, de forma análoga, la difusividad del contenido de agua puede expresarse de esta manera.

$$D(\theta) = \frac{K(\theta)}{C(\theta)} \quad \text{Ecuación (13)}$$

Para llevar a cabo un modelo matemático que describa el movimiento del agua en la conductividad hidráulica, se optará por un enfoque indirecto. Este enfoque, conocido como Métodos Indirectos, se basa fundamentalmente en el uso de métodos de regresión que dependen de datos obtenidos a través de técnicas directas. Dentro de esta categoría de métodos, encontramos una aplicación práctica especialmente útil para estimar la conductividad hidráulica en función del contenido de humedad del suelo, $K(\theta)$.

La ventaja de estos métodos radica en su capacidad para proporcionar estimaciones de $K(\theta)$ aprovechando conjuntos de datos previamente recolectados, lo que permite una modelización más eficiente y menos invasiva del comportamiento hidráulico del suelo. Al utilizar técnicas de regresión, es posible ajustar los modelos a los datos observados, optimizando la precisión de las estimaciones de la conductividad hidráulica bajo diferentes condiciones de humedad del suelo.

3.9.8. Estimación de la función $K(\psi)$ utilizando datos de retención de agua en el suelo

La curva de retención de agua en el suelo se representa utilizando la ecuación de Van Genuchten:

$$\theta = \theta_r + \frac{\theta_s - \theta_r}{(1 + |\alpha\psi|^n)^m} \quad \text{Ecuación (14)}$$

Donde:

θ_r = Representa el contenido de agua residual en el suelo, que ocurre cuando el potencial de presión se reduce a un valor extremadamente bajo.

θ_s = Denota el contenido de agua en el suelo cuando está completamente saturado

a = Representa el parámetro de forma

n = Representa el parámetro de forma adimensional

$$m = 1 - \frac{1}{n}$$

Luego para poder aplicar la curva de retención de agua en el modelo matemático de conductividad hidráulica, reemplazamos la ecuación (14) en la (10), y obtenemos lo siguiente:

$$K(\psi) = K_s \frac{[1 - |a\psi|^{n-1}(1 + |a\psi|^n)^{-m}]^2}{[1 + |a\psi|^n]^{m\lambda}} \quad \text{Ecuación (15)}$$

Donde:

K_s = Conductividad hidráulica saturada (cm/s)

λ = un parámetro de forma que se basa en la derivada de K respecto a ψ .

A partir de la ecuación (15) encontramos la Conductividad hidráulica relativa $K(\theta)$ el cual representa cómo la capacidad del suelo para transmitir agua varía en función del contenido de humedad. Esta relación es crucial para comprender y modelar el movimiento del agua a través de medios porosos, especialmente en condiciones no saturadas.

Además, se considera que el valor para la Conductividad Hidráulica Relativa $K(\theta)$ se representa de la siguiente forma:

$$K(\theta) \cong e^{a\theta}, 0 < a \leq 3, a \in \mathbb{R}$$

Donde el valor de a se encuentra en el intervalo de 0 a 3.0 esto con el fin de mantener la estabilidad de la solución numérica.

La Conductividad hidráulica relativa $K(\theta)$ es dada de la siguiente forma:

Ecuación (16)

$$K(\theta) = K_s \frac{[1 - |a\theta|^{\rho-1}(1 + |a\theta|^\rho)^{-\mu}]^2}{[1 + |a\theta|^\rho]^{\mu\lambda}}$$

Para poder encontrar el valor de la Conductividad Hidráulica Saturada K_s aplicamos la ley de Darcy mencionada en la ecuación (1).

Para este caso se utilizará la ley de Darcy para flujo estacionario, que relaciona la tasa de flujo de agua a través del suelo con la conductividad hidráulica del suelo, el gradiente hidráulico y el área de flujo, el cual se representa de la siguiente forma:

$$Q = -K_s \cdot A \cdot \frac{\Delta h}{L} \quad \text{Ecuación (17)}$$

Donde:

Q = Es la tasa de flujo (volumen por unidad de tiempo)

K_s = Es la conductividad hidráulica saturada

A = Es el área de la sección transversal a través de la cual se mueve el agua

Δh = Es la diferencia de carga hidráulica

L = Es la longitud del suelo a través de la cual fluye el agua.

Re arreglando la ecuación para resolver para K_s da la siguiente expresión:

$$K_s = \frac{Q \cdot L}{A \cdot \Delta h} \quad \text{Ecuación (18)}$$

Esto en términos de la tabla N°6 de ensayos de permeabilidad se puede escribir de la siguiente forma:

$$K_s = \frac{\sum(\text{Valores de Permeabilidad})}{\text{número de valores}} \quad \text{Ecuación (19)}$$

Se procede a calcular desde el sondaje P-01 al P-03, para esto se utilizó la herramienta estadística de Python, como se presenta en el siguiente código:

```
# Datos de permeabilidad para cada ensayo en cm/s
permeability_data = [
    3.20e-04, 1.45e-04, 2.62e-04, 4.28e-04, 2.50e-04, # P-01
    2.62e-04, 3.17e-05, 3.88e-03, 4.36e-05, 2.68e-05, # P-02
    6.52e-04, 4.67e-04, 2.50e-04, 1.96e-04 # P-03
]

# Calculo del promedio de los datos de permeabilidad
average_permeability = np.mean(permeability_data)
average_permeability
```

El código simulado nos da como resultado el siguiente valor:

$$K_s = 0.0005152928571428572$$

Una vez obtenido el valor de K_s , encontramos los valores de a, ρ, μ y λ . Para encontrar el valor de μ aplicamos la denotación de la ecuación (14).

$$\mu = 1 - \frac{1}{\rho}$$

Siendo el valor de $\rho = 2$, entonces $\mu = 0.5$

Siendo un parámetro de forma que se basa en la derivada de K respecto a ψ , como se menciona en la ecuación (15), decimos que su valor corresponde a 0.5, debido a que en la ecuación de Van Genuchten y otras relacionadas con la conductividad hidráulica, λ controla la forma de la curva que describe la relación entre la conductividad hidráulica y el contenido de humedad del suelo. El valor de λ afecta cómo la conductividad hidráulica disminuye cuando el suelo pasa de saturado (cuando todos los poros del suelo están llenos de agua) a seco (cuando la mayoría del agua ha sido removida del suelo).

Un valor de $\lambda = 0.5$ es una elección común para suelos que no son ni demasiado arenosos ni demasiado arcillosos, lo que indica una disminución moderada de la conductividad hidráulica con la disminución del contenido de agua. Valores más altos de λ indicarían una disminución más rápida (curva más empinada), común en suelos más arcillosos, mientras que valores más bajos de λ indicarían una disminución más gradual (curva más suave), que podría ser más típica de suelos arenosos.

Sabiendo que el suelo en el sistema de riego laguna Huanzo en base a los datos climáticos, de permeabilidad, químicos y físicos descritas en las Tablas N°6, N°8 y N°9, retiene agua más fuertemente que uno arenoso (que tendría un a más bajo, como 0.5), pero no tan fuertemente como uno arcilloso (que tendría un a más alto, cerca de 3.0), presenta un valor de 1.2. Esto indica que está asociada con un suelo franco, que es un tipo de suelo que tiene proporciones relativamente equilibradas de arena, limo y arcilla. Esto representa un dato correcto, ya que los suelos francos son conocidos por tener buenas propiedades de retención de agua y aireación, lo que los hace ideales para la agricultura.

Una vez demostrado el valor de λ , se procede a calcular la Conductividad hidráulica relativa $K(\theta)$, aplicando la ecuación (16).

```

import numpy as np
import matplotlib.pyplot as plt

# Parámetros para la conductividad hidráulica relativa
Ks = 0.0005152928571428572 # Valor de la conductividad hidráulica
saturada en cm/s
alpha = 1.2 # Coeficiente de alpha
rho = 2 # Coeficiente rho
mu = 0.5 # Coeficiente mu
lambda = 0.5 # Coeficiente lambda

# Rango para theta desde 0 a 1
theta_values = np.linspace(0, 1, 100, endpoint=False)

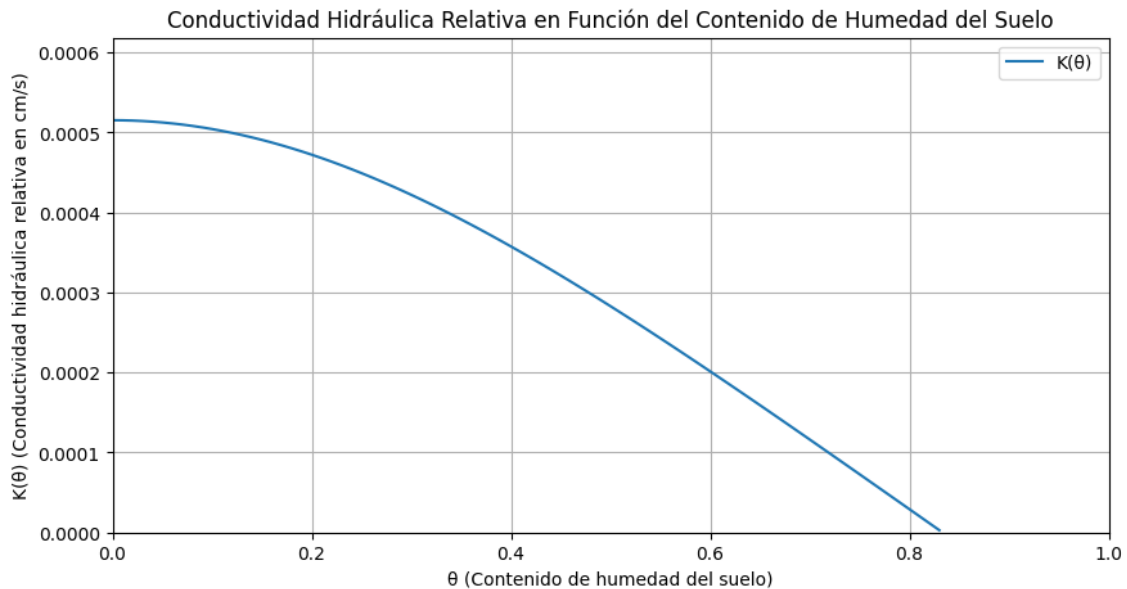
# Calculo de K(theta)
K_theta = Ks * (((1 - np.abs(alpha * theta_values) ** rho) ** (1 -
1/rho)) /
                ((1 + np.abs(alpha * theta_values) ** rho) ** (mu *
lambda))) ** 2

# Grafica de la conductividad hidráulica relativa
plt.figure(figsize=(10, 5))
plt.plot(theta_values, K_theta, label='K(θ)')
plt.xlabel('θ (Contenido de humedad del suelo)')
plt.ylabel('K(θ) (Conductividad hidráulica relativa en cm/s)')
plt.title('Conductividad Hidráulica Relativa en Función del Contenido
de Humedad del Suelo')
plt.legend()
plt.grid(True)
plt.xlim(0, 1) # Establecer el límite del eje x hasta 1
plt.ylim(0, max(K_theta)*1.2) # Aumentar el rango del eje y en un 20%
por encima del valor máximo
plt.show()

```

Figura 13

Variación de la Conductividad Hidráulica Relativa



Nota. Elaboración Propia

La figura 13, muestra la conductividad hidráulica relativa $K(\theta)$ en función del contenido de humedad del suelo θ . La interpretación se da de la siguiente forma:

- **Decremento en Conductividad con el Secado del Suelo:** La Figura 13 indica que la conductividad hidráulica relativa disminuye a medida que aumenta el contenido de humedad del suelo. A medida que θ aumenta, $K(\theta)$ disminuye gradualmente, lo que sugiere que la capacidad del suelo para transmitir agua se reduce conforme se acerca a la saturación, es decir, a medida que el suelo se satura y el contenido de humedad aumenta, los espacios porosos se llenan de agua y la resistencia al flujo de agua aumenta, resultando en una disminución de la conductividad hidráulica relativa.
- **Relación No Lineal:** La relación entre $K(\theta)$ y θ no es lineal. La figura muestra una disminución rápida a medida que θ se reduce desde un valor alto hasta aproximadamente 0.4, después de lo cual la tasa de disminución es más lenta. Esto indica que hay un umbral de humedad del suelo a partir del cual la disminución de la conductividad hidráulica es menos sensible a los cambios en θ .
- **Comportamiento de Suelos Típicos:** El comportamiento mostrado en la figura es típico para muchos tipos de suelo. En general, los suelos con una estructura más porosa y bien agregada tendrán una conductividad hidráulica más alta

cuando están secos en comparación con los suelos compactados o con alta arcilla. Sin embargo, a medida que el suelo se satura, la conductividad disminuye debido a la reducción del espacio poroso disponible para el movimiento del agua.

- **Implicaciones para la Ingeniería y la Agricultura:** Desde una perspectiva de ingeniería par el diseño de sistemas de drenaje y manejo de agua, es crucial entender cómo varía la conductividad hidráulica con la humedad del suelo. Un conocimiento preciso de esta relación permite diseñar sistemas más eficientes y evitar problemas como la saturación del suelo y la erosión. Mientras que en la en la agricultura, conocer la conductividad hidráulica en función del contenido de humedad ayuda a optimizar los sistemas de riego. Un riego adecuado debe mantener el suelo en un rango de humedad que maximice la conductividad hidráulica y, por tanto, la disponibilidad de agua para las plantas.

3.9.9. Escenarios de valor de α para la Conductividad Hidráulica Relativa $K(\theta)$

Sabiendo que el valor de α se encuentra en el intervalo de 0 a 3.0 esto con el fin de mantener la estabilidad de la solución numérica, aplicamos una simulación de tres escenarios para valores de 0.5, 1.5 y 2.5.

En el contexto de las ecuaciones de conductividad hidráulica del suelo, como la fórmula de Van Genuchten, el parámetro α es crítico porque afecta cómo se modela la curva de retención de agua del suelo. Esta curva representa la relación entre la tensión del agua del suelo (o potencial matricial) y el contenido de humedad del suelo.

El rango de valores para α de 0 a 3.0 se elige para garantizar la estabilidad de las soluciones numéricas. Valores fuera de este rango podrían llevar a resultados físicamente no realistas o a problemas en la convergencia del modelo cuando se computa numéricamente.


La lógica detrás de la elección de los valores de α para la simulación puede explicarse de la siguiente manera:

- **Valor de α Bajo (0.5):** Con un valor de α bajo, la curva de la conductividad hidráulica relativa $K(\theta)$ descenderá más rápidamente a medida que el contenido de humedad disminuye. Esto significa que incluso con una pequeña reducción

en la humedad del suelo, la capacidad del suelo para transmitir agua se reduce significativamente. El valor de α bajo (0.5) indica una rápida disminución de la conductividad hidráulica relativa con la reducción del contenido de humedad en el suelo. Esto implica que el suelo pierde su capacidad de transmisión de agua más rápidamente, afectando la gestión de riegos y la previsión del comportamiento hidráulico del suelo (Ver figura 14).

Figura 14

Variación de la Conductividad Hidráulica Relativa para un valor de $\alpha=0.5$



Nota. Elaboración Propia


La figura 14 muestra cómo varía la conductividad hidráulica relativa en función del contenido de humedad del suelo. La conductividad hidráulica es mayor cuando el suelo está más húmedo y disminuye a medida que el contenido de humedad disminuye.

- **Valor de α Bajo (1.5):** El valor intermedio de 1.5 en el contexto de la retención y el movimiento del agua en el suelo sugiere un equilibrio entre las propiedades de retención de agua y de drenaje. Este valor es indicativo de un suelo franco o loam, que es conocido por su capacidad para mantener la humedad a la vez que permite una adecuada aireación y drenaje. Los suelos francos son altamente valorados en la agricultura debido a su contenido equilibrado de limo, arena y arcilla, lo que resulta en una estructura de suelo óptima que soporta un robusto crecimiento de las raíces y facilita la administración eficiente de los nutrientes. Además, un valor de 1.5 puede reflejar una heterogeneidad en la distribución del

tamaño de los poros del suelo. Esta diversidad en la porosidad facilita la retención de agua necesaria para los procesos biológicos de las plantas mientras mantiene la capacidad del suelo para drenar el exceso de agua y prevenir condiciones de anoxia en las raíces. (Ver figura 15).

Figura 15

Variación de la Conductividad Hidráulica Relativa para un valor de $a=1.5$




Nota. Elaboración Propia

La figura 15, muestra que en suelos con un valor de a de 1.5, la conductividad hidráulica relativa disminuye a medida que aumenta el contenido de humedad del suelo. Esto refleja el comportamiento típico de un suelo franco, que equilibra eficazmente la retención de agua y el drenaje, optimizando tanto el crecimiento de las plantas como la administración de nutrientes.

- **Valor de a Bajo (2.5):** Un valor alto de a indica que el suelo retiene el agua más fuertemente y que la tensión del agua del suelo necesita aumentar significativamente antes de que se libere más agua. Esto es característico de suelos con poros más pequeños, como los suelos arcillosos, que retienen el agua con más fuerza y, por lo tanto, tienen una menor conductividad hidráulica a bajos contenidos de humedad.

Figura 16

Variación de la Conductividad Hidráulica Relativa para un valor de $a=2.5$



Nota. Elaboración Propia

La figura 16, indica que para un valor de $a = 2.5$ sugiere una menor capacidad de retención de agua en comparación con valores más bajos de a . Este valor refleja un suelo que pierde su capacidad de transmitir agua rápidamente a medida que se humedece.

- **Retención de Agua Fuerte:** Un a alto indica que el suelo retiene agua más fuertemente, este comportamiento puede ser indicativo de un suelo con alta proporción de partículas gruesas (arena) y baja capacidad de retención de agua. La rápida disminución de $K(\theta)$ con un aumento moderado en la humedad indica que el suelo no mantiene bien el agua y permite que se drene rápidamente. Este tipo de suelo puede no ser ideal para cultivos que requieren un suministro constante de agua, ya que el agua se perdería rápidamente por percolación.
- **Implicaciones Prácticas:** En la agricultura suelos con este valor de a pueden necesitar riegos más frecuentes y técnicas que mejoren la retención de agua, como la adición de materia orgánica o el uso de coberturas vegetales. A su vez, para el manejo de agua la gestión de recursos hídricos en áreas con suelos de alta conductividad hidráulica relativa y baja retención de agua necesita estrategias para evitar la rápida pérdida de agua, como la construcción de

barreras de infiltración o el uso de sistemas de riego que minimicen la percolación profunda.

3.9.10. Error Máximo complementario

Se calculará el error máximo para validar que los datos usados en la presente investigación para confirmar la precisión y la fiabilidad de los datos recolectados, esto se correlacionara con la humedad y temperatura presentes en la zona de estudio, de tal forma que los datos son consistentes y se alinean bien con las expectativas teóricas. Para hallar el error máximo se considera la Ecuación de Richards de la forma:

$$\frac{\partial \theta}{\partial t} = \frac{\partial}{\partial z} \left[D \frac{\partial \theta}{\partial z} \right] - \frac{\partial k}{\partial z} \quad \text{Ecuación (20)}$$

Con D y $K = \frac{\partial k}{\partial z}$ constantes, definiéndolo de la siguiente forma:

$$\theta^* = [\theta(z, t) + C]e^{(Az+Bt)} \quad \text{Ecuación (21)}$$

Se puede simplificar la Ecuación de Richards a través de varias sustituciones, logrando así reducirla a la Ecuación de Difusión.

$$\frac{\partial \theta^*}{\partial t} = D \frac{\partial^2 \theta^*}{\partial z^2} \quad \text{Ecuación (22)}$$

A continuación, finaliza el problema estableciendo las Condiciones de Frontera y la Condición Inicial, expresadas en términos de θ , y esto se traduce de la siguiente forma:

$$C. F = \begin{cases} \theta^*(0, t) = (\theta_w - \theta_d)e^{Bt} \\ \theta^*(\infty, t) = 0 \\ \theta^*(z, t) = 0 \end{cases} \quad \text{Ecuación (23)}$$

Para concluir se aplica las condiciones de frontera y condición inicial de la ecuación (23), para determinar la Solución Producto que cumple con las Condiciones de Frontera empleando el método de Separación de Variables. Este enfoque es eficaz

porque permite descomponer la ecuación en partes más manejables, cada una dependiente de una sola variable, facilitando así la búsqueda de soluciones específicas.

$$\theta^*(z, t) = \frac{(\theta_w - \theta_d)}{2} e^{Bt} \left(e^{-z\left(\frac{B}{D}\right)^{0.5}} \operatorname{erfc}\left(\frac{z}{2(Dt)^{0.5}} - (Bt)^{0.5}\right) + e^{z\left(\frac{B}{D}\right)^{0.5}} \operatorname{erfc}\left(\frac{z}{2(Dt)^{0.5}} + (Bt)^{0.5}\right) \right) \quad \text{Ecuación (24)}$$

Resolviendo la ecuación (24) utilizando como solución inicial, la solución escrita anteriormente aplicando las condiciones de frontera y condición inicial, se obtiene la siguiente expresión:

$$\theta^*(z, t) = \frac{(\theta_w - \theta_d)}{2} e^{Bt} \left(\operatorname{erfc}\left(\frac{z}{2(Dt)^{1/2}} - \frac{(kt^{1/2})}{2D^{1/2}}\right) + e^{\frac{(kz)}{D}} \operatorname{erfc}\left(\frac{z}{2(Dt)^{1/2}} + \frac{(kt^{1/2})}{2D^{1/2}}\right) \right)$$

Donde:

erfc = Representa la función complementaria del error.

θ_d = Es la condición inicial o de frontera para θ en $z = 0$

θ_w = Es la condición de frontera para θ en $z = \infty$

D = Es el coeficiente de difusividad

k = Difusión de la humedad

La solución analítica expresada en términos de θ se simplifica a:

La función complementaria de error expresado en términos más simples se define la siguiente forma:

$$\operatorname{erfc}(x) = 1 - \operatorname{erf}(x) = \frac{2}{\pi} \int_x^\infty e^{-t^2} dt$$

Una vez definida la ecuación se define los valores iniciales de θ_d , θ_w , D y k

El valor inicial de θ_d se define tomando la temperatura media inicial como es la humedad del suelo en la superficie o en la interfaz de inicio, en este caso al considerar como temperatura inicial se parte desde el valor de 1°C, debido a que este valor representa una condición de normalización o una condición de referencia estandarizada en la que las mediciones de humedad o temperatura se inician.

El valor inicial de θ_w se define considerando la humedad, donde el suelo está completamente saturado y la temperatura se establece lejos de la fuente de calor, para encontrar este dato se considera la Tabla N°5 de las temperaturas medias mensuales,

donde el promedio de las temperaturas para los meses de enero a diciembre es 9.26°C, con lo cual se considera este valor.

Para calcular el valor de D se aplica la ecuación (13), donde la capacidad específica del agua en el suelo conocido como la capacidad térmica a temperatura ambiente α o definida en la ecuación de Richards como $C(\theta)$ es 0.14×10^{-6} como lo muestra la siguiente tabla:

Tabla 11
Coefficiente de conductividad térmica

Material	α (m ² /s)	Material	α (m ² /s)
Plata	149×10^{-6}	Concreto	0.75×10^{-6}
Oro	127×10^{-6}	Ladrillo	0.52×10^{-6}
Cobre	113×10^{-6}	Suelo macizo	0.52×10^{-6}
Aluminio	97.5×10^{-6}	Vidrio	0.34×10^{-6}
Hierro	22.8×10^{-6}	Lana de vidrio	0.23×10^{-6}
Mercurio	4.7×10^{-6}	Agua	0.14×10^{-6}
Mármol	1.2×10^{-6}	Carne de res	0.14×10^{-6}
Hielo	1.2×10^{-6}	Madera	0.13×10^{-6}

Nota. Extraída de Área Ciencias (2021).

A partir de ese dato calculamos el coeficiente de difusividad:

```
import numpy as np

# Parámetros
Ks = 0.0005152928571428572 # Conductividad hidráulica saturada en
cm/s
alpha = 1.2 # Coeficiente de alpha
rho = 2 # Coeficiente rho
mu = 0.5 # Coeficiente mu
lambda = 0.5 # Coeficiente lambda
Cs = 0.14e-6 # Coeficiente de capacidad específica o conductividad
termica

# Valor de theta
theta = 0.2 # Considera theta = 0.2

# Calculo de K(theta) para el valor dado de theta
```

```

K_theta_value = Ks * (((1 - np.abs(alpha * theta) ** rho) ** (1 -
1/rho)) /
                    ((1 + np.abs(alpha * theta) ** rho) ** (mu *
lambda))) ** 2

# Calculo de D(theta) para el valor dado de theta
D_theta_value = K_theta_value * Cs

Print("El valor de D(theta) para theta =", theta, "es:",
D_theta_value)

```

Dando como resultado un valor de difusividad $D(\theta) = 3372.8780812597515$.

Para calcular el valor de k se toma en cuenta el promedio de la desviación estándar de la humedad mostrada en la Tabla N°5, debido a que la desviación estándar proporciona una medida de la variabilidad o volatilidad de las mediciones de humedad a lo largo del tiempo. Utilizando la desviación estándar, se puede estimar k para reflejar la estabilidad o inestabilidad de las mediciones de humedad y así calibrar modelos predictivos o de simulación que son sensibles a la dispersión de los datos.

Es por ello que el valor de k es de 20.48. A continuación se muestra el código utilizado para encontrar el error máximo a partir de la ecuación de Richards.

```

import numpy as np
import matplotlib.pyplot as plt
from scipy.special import erfc

# Parametros
theta_d = 1
theta_w = 9.26
D = 3372.8780812597515
k = 20.48
t_example = 1

# Definición de la función theta(z, t) sin el término e^(kt/2)
def theta_corrected(z, t, theta_d, theta_w, D, k):
    return theta_d + (theta_w - theta_d) / 2 * (
        erfc(z / (2 * np.sqrt(D * t)) - np.sqrt(k * t) / (2 *
np.sqrt(D))) +
        np.exp(k * z / D) * erfc(z / (2 * np.sqrt(D * t)) + np.sqrt(k
* t) / (2 * np.sqrt(D)))
    )

# Rango de z para evaluar la función theta
z_values = np.linspace(0, 1, 100)

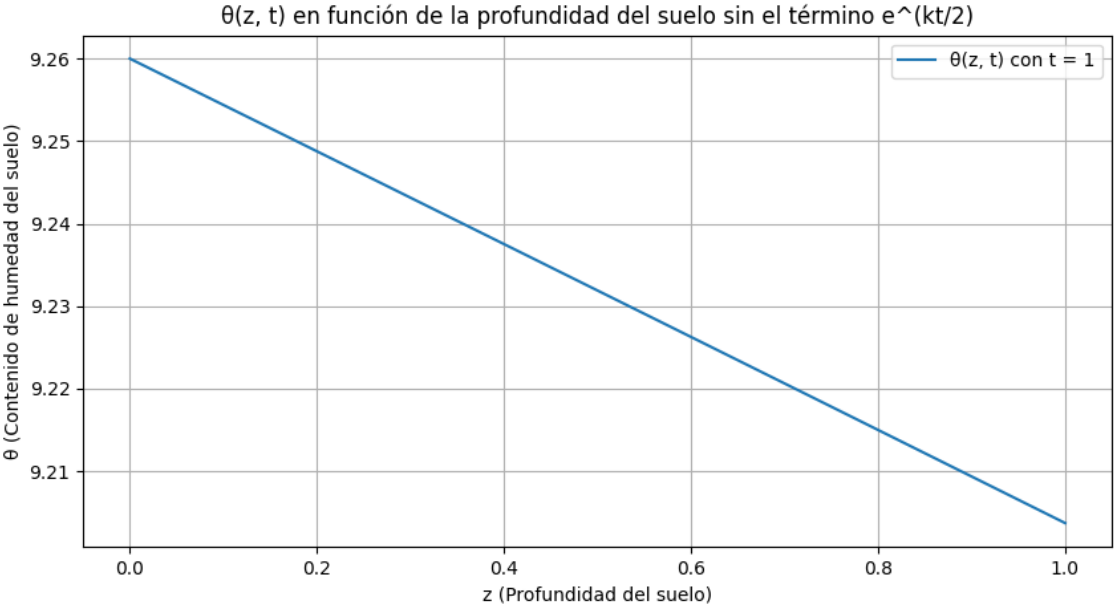
# Cálculo de theta(z, t) para el rango de z y el tiempo t especificado
theta_values_corrected = theta_corrected(z_values, t_example,
theta_d, theta_w, D, k)

```

```
# Visualización de los resultados
plt.figure(figsize=(10, 5))
plt.plot(z_values, theta_values_corrected, label=f'θ(z, t) con t = {t_example}')
plt.xlabel('z (Profundidad del suelo)')
plt.ylabel('θ (Contenido de humedad del suelo)')
plt.title('θ(z, t) en función de la profundidad del suelo sin el término e^(kt/2)')
plt.legend()
plt.grid(True)
plt.show()
```

Reemplazando todos los datos en la ecuación resultante de la expresión (24), obtenemos el siguiente resultado.

Figura 17
Variación de θ en función al error máximo



Nota. Elaboración Propia

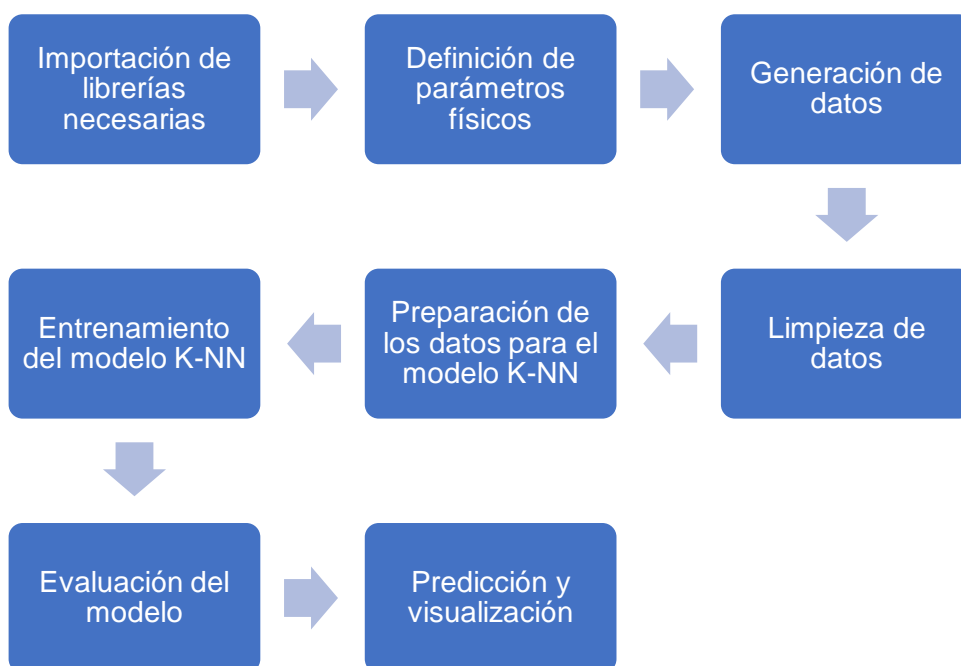
La figura 17, muestra una recta lineal decreciente, esto indica que el patrón de error disminuye con la profundidad y que la variabilidad del error es baja, lo que implica que la confianza en las mediciones, de los datos obtenidos confirman su precisión y fiabilidad.

3.9.11. Algoritmo de aprendizaje automático (K-NN)

Para el desarrollo del algoritmo de aprendizaje se ha realizado un código para modelar y predecir la conductividad hidráulica del suelo $K(\theta)$ en función del contenido de humedad del suelo (θ) usando el algoritmo K-Nearest Neighbors (K-NN) como técnica aprendizaje automático.

Figura 18

Pasos del algoritmo de aprendizaje automático K-NN



Nota. Elaboración Propia

Paso 1: Importación de librerías necesarias

Para el desarrollo del código se han utilizado las siguientes librerías:

- **numpy para cálculos numéricos y manipulación de arrays:** numpy es una biblioteca esencial en el ecosistema de Python para la ciencia de datos y el aprendizaje automático. Ofrece una estructura de datos de array multidimensional (ndarray) que permite realizar operaciones matemáticas y lógicas a nivel de array de manera eficiente y con una sintaxis conveniente. En el código, numpy se utiliza para crear el rango de valores de (θ) y para calcular $K(\theta)$ mediante operaciones matemáticas que se aplican elemento por elemento sobre los arrays de manera vectorizada.

- **matplotlib.pyplot para graficar los resultados:** matplotlib.pyplot es una librería de visualización en Python que proporciona una manera cómoda y flexible de crear gráficos y visualizaciones de datos. Es ampliamente utilizado para la exploración de datos y la presentación de los resultados del análisis. En el código, se emplea para mostrar la relación entre el contenido de humedad del suelo y la conductividad hidráulica, tanto para los datos reales como para las predicciones del modelo, permitiendo una interpretación visual del rendimiento del modelo.
- **KNeighborsRegressor de scikit-learn para utilizar el modelo K-NN para regresión:** Scikit-learn es una biblioteca de aprendizaje automático para Python que ofrece una amplia gama de algoritmos de modelado estadístico y de aprendizaje automático. KNeighborsRegressor implementa el algoritmo de K-Nearest Neighbors (K-NN) para regresión, que predice el valor de una variable objetivo basándose en las K observaciones más cercanas en el espacio de características. Este método es particularmente útil para capturar relaciones no lineales sin necesidad de un modelo explícito entre las variables independientes y dependientes. En el código, se utiliza para predecir $K(\theta)$ basado en nuevos valores de θ .
- **train_test_split para dividir los datos en conjuntos de entrenamiento y prueba:** train_test_split es una función de scikit-learn que facilita la división de datos en conjuntos de entrenamiento y prueba. Esta práctica es fundamental en el aprendizaje automático para evaluar la capacidad de generalización de un modelo: el modelo se entrena en un conjunto de datos y luego se prueba en un conjunto diferente para verificar su rendimiento en datos no vistos. Ayuda a detectar problemas como el sobreajuste, donde el modelo se desempeña bien en los datos de entrenamiento, pero mal en datos nuevos.
- **StandardScaler para normalizar los datos antes de alimentarlos al modelo K-NN:** StandardScaler es una herramienta de preprocesamiento de scikit-learn que normaliza los datos eliminando la media y escalando a varianza unitaria asegurando que todas las características en el código se contribuyan por igual al resultado del modelo, independientemente de su escala original.

Paso 2: Definición de parámetros físicos

Para la definición de los parámetros físicos se definieron los coeficientes hallados en la ecuación de Richards para valores de a, ρ, μ, λ y la conductividad hidráulica saturada K_s que se utilizan para calcular $K(\theta)$.

```
# Parámetros para la conductividad hidráulica relativa
alpha = 1.2 # Coeficiente de alpha
rho = 2 # Coeficiente rho
mu = 0.5 # Coeficiente mu
lambda = 0.5 # Coeficiente lambda
Ks = 0.0005152928571428572 # Valor de la conductividad hidráulica
saturada en cm/s
```

Paso 3: Generación de datos

La generación de datos en el contexto de la agrupación de parámetros de agrupación K-NN involucra dos componentes principales: la creación de un conjunto de valores representando el contenido de humedad del suelo (θ) y el cálculo de la conductividad hidráulica $K(\theta)$ en función de esos valores. Estos pasos son necesarios para modelar el comportamiento de la conductividad hidráulica relativa a diferentes niveles de humedad del suelo.

- **Generación de valores de θ :** Los valores de θ , que representan el contenido de humedad del suelo, se generan utilizando `np.linspace(0, 1, 100, endpoint=False)`. Esta función crea un array de 100 puntos equidistantes que empiezan en 0 y terminan justo antes de 1, cubriendo así un rango completo de suelo seco (0) a suelo completamente saturado (cercano a 1) sin incluir el valor exacto de 1. Este rango es elegido porque en la realidad, el contenido de humedad del suelo varía dentro de estos límites, siendo 0 un suelo completamente seco y 1 (o 100%) un suelo completamente saturado de agua. La elección de no incluir el punto final permite estudiar el comportamiento justo antes de la saturación completa.

```
# Rango para theta desde 0 a 1
theta_values = np.linspace(0, 1, 100, endpoint=False)
```

Figura 19
Generación de valores para θ

```
# Parámetros para la conductividad hidráulica relativa
alpha = 1.2 # Coeficiente de alpha
rho = 2     # Coeficiente rho
mu = 0.5   # Coeficiente mu
lambda = 0.5 # Coeficiente lambda
Ks = 0.0005152928571428572 # Valor de la conductividad hidráulica saturada en cm/s

# Rango para theta desde 0 a 1
theta_values = np.linspace(0, 1, 100, endpoint=False)

print(theta_values)
```

```
[0.  0.01 0.02 0.03 0.04 0.05 0.06 0.07 0.08 0.09 0.1  0.11 0.12 0.13
 0.14 0.15 0.16 0.17 0.18 0.19 0.2  0.21 0.22 0.23 0.24 0.25 0.26 0.27
 0.28 0.29 0.3  0.31 0.32 0.33 0.34 0.35 0.36 0.37 0.38 0.39 0.4  0.41
 0.42 0.43 0.44 0.45 0.46 0.47 0.48 0.49 0.5  0.51 0.52 0.53 0.54 0.55
 0.56 0.57 0.58 0.59 0.6  0.61 0.62 0.63 0.64 0.65 0.66 0.67 0.68 0.69
 0.7  0.71 0.72 0.73 0.74 0.75 0.76 0.77 0.78 0.79 0.8  0.81 0.82 0.83
 0.84 0.85 0.86 0.87 0.88 0.89 0.9  0.91 0.92 0.93 0.94 0.95 0.96 0.97
 0.98 0.99]
```

Nota. Elaboración Propia

- **Cálculo de $K(\theta)$:** La ecuación de la conductividad hidráulica es la misma que se halló en la ecuación Richards el cual modela la complejidad del fenómeno físico donde la capacidad del suelo para conducir agua varía no linealmente con el contenido de humedad.

```
# Calculo de K(theta)
K_theta = Ks * (((1 - np.abs(alpha * theta_values) ** rho) ** (1 -
1/rho)) /
                ((1 + np.abs(alpha * theta_values) ** rho) ** (mu *
lambda))) ** 2
```

Paso 4: Limpieza de datos

Para el código del algoritmo K-NN, la limpieza de datos se refiere específicamente a la eliminación de valores NaN (Not a Number) en la serie de datos de $K(\theta)$ y sus correspondientes valores de θ . Esta acción es esencial por varias razones:

- **Integridad de los Datos:** Los valores NaN pueden surgir por diversas razones durante el cálculo de $K(\theta)$, como el resultado de operaciones indefinidas o divisiones por cero en la fórmula usada para calcular la conductividad hidráulica. Estos valores NaN representan datos faltantes o erróneos que no pueden ser interpretados por modelos de aprendizaje automático. Mantener estos valores

en el dataset podría introducir sesgos o errores en el entrenamiento y evaluación del modelo, conduciendo a predicciones inexactas o fallidas.

- **Consistencia de los Datos:** Al eliminar los valores NaN de $K(\theta)$, es necesario también eliminar los correspondientes valores de θ para mantener la consistencia del dataset. Esto asegura que cada entrada de $K(\theta)$ tenga su correspondiente valor de θ , manteniendo una relación uno a uno entre los datos de entrada (features) y los datos de salida (targets).
- **Optimización del Rendimiento:** Eliminar datos no válidos antes del entrenamiento ayuda a optimizar el rendimiento del modelo reduciendo el ruido en los datos. Esto permite que el algoritmo de aprendizaje automático se concentre en aprender las verdaderas relaciones subyacentes en los datos.

Para realizar la limpieza de datos se utiliza la siguiente expresión:

```
# Eliminar cualquier NaN en K_theta y los correspondientes theta_values  
  
valid_indices = ~np.isnan(K_theta)  
K_theta = K_theta[valid_indices]  
theta_values_clean = theta_values[valid_indices]
```

Figura 20

Eliminación de valores NaN

```
[ 5.15292857e-04  5.15181563e-04  5.14847794e-04  5.14291884e-04  
 5.13514394e-04  5.12516103e-04  5.11298008e-04  5.09861322e-04  
 5.08207469e-04  5.06338079e-04  5.04254981e-04  5.01960202e-04  
 4.99455955e-04  4.96744635e-04  4.93828810e-04  4.90711216e-04  
 4.87394743e-04  4.83882433e-04  4.80177467e-04  4.76283156e-04  
 4.72202931e-04  4.67940339e-04  4.63499025e-04  4.58882728e-04  
 4.54095271e-04  4.49140549e-04  4.44022522e-04  4.38745203e-04  
 4.33312651e-04  4.27728963e-04  4.21998263e-04  4.16124691e-04  
 4.10112403e-04  4.03965555e-04  3.97688300e-04  3.91284777e-04  
 3.84759111e-04  3.78115396e-04  3.71357701e-04  3.64490054e-04  
 3.57516443e-04  3.50440806e-04  3.43267033e-04  3.35998955e-04  
 3.28640345e-04  3.21194912e-04  3.13666297e-04  3.06058073e-04  
 2.98373741e-04  2.90616729e-04  2.82790387e-04  2.74897989e-04  
 2.66942729e-04  2.58927723e-04  2.50856005e-04  2.42730529e-04  
 2.34554167e-04  2.26329710e-04  2.18059866e-04  2.09747264e-04  
 2.01394452e-04  1.93003897e-04  1.84577988e-04  1.76119033e-04  
 1.67629266e-04  1.59110842e-04  1.50565841e-04  1.41996271e-04  
 1.33404064e-04  1.24791085e-04  1.16159126e-04  1.07509911e-04  
 9.88450991e-05  9.01662826e-05  8.14749909e-05  7.27726912e-05  
 6.40607905e-05  5.53406371e-05  4.66135222e-05  3.78806817e-05  
 2.91432975e-05  2.04024996e-05  1.16593672e-05  2.91493074e-06]
```

Nota. Elaboración Propia

Como se muestra en la Figura 20, la eliminación de valores NaN resulta en una matriz completamente numérica, lo que significa que la matriz no presenta ningún dato faltante.

Paso 5: Preparación de los datos para el modelo K-NN

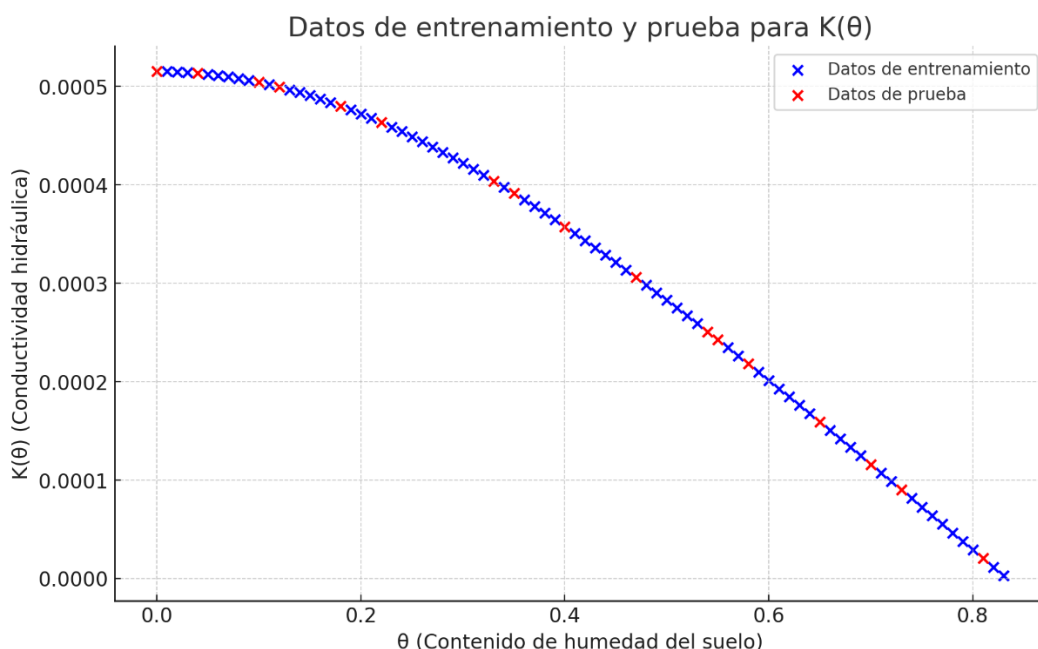
La preparación de datos para el modelo K-NN incluye dos pasos esenciales: la división de los datos y su normalización.

- **División de los datos en conjuntos de entrenamiento y prueba:** Este paso utiliza la función `train_test_split` para dividir los datos en dos grupos: uno para entrenar el modelo (conjunto de entrenamiento) y otro para evaluar su rendimiento (conjunto de prueba). Esta división es crucial para el desarrollo del modelo de aprendizaje automático ya que permite validar la capacidad del modelo para generalizar a nuevos datos, es decir, su capacidad para realizar predicciones precisas en datos que no ha visto durante el entrenamiento. El código utilizado para dividir los datos en entrenamiento y prueba es el siguiente:

```
# Dividir los datos en entrenamiento y prueba

X = theta_values_clean.reshape(-1, 1) # Convertimos a 2D array para
scikit-learn
X_train, X_test, y_train, y_test = train_test_split(X, K_theta,
test_size=0.2, random_state=42)
```

Figura 21
Datos de entrenamiento y prueba



La figura 21, muestra la distribución y el rango de valores tanto para el entrenamiento como para la prueba.

- **Normalización de los datos usando StandardScaler:** La normalización de los datos se refiere al proceso de ajustar la escala de las características para que tengan una media de cero y una desviación estándar de uno. Esto se realiza utilizando StandardScaler, una herramienta de preprocesamiento que transforma cada característica de manera que tenga una distribución normal estándar. Esta normalización es particularmente importante para el algoritmo K-NN porque se basa en medidas de distancia (como la distancia euclidiana) para encontrar los “vecinos más cercanos”, ya que, si las características están en escalas significativamente diferentes, las distancias podrían estar dominadas por las características con valores más grandes, sesgando el modelo. Es por ello que se ha normalizado los datos para asegurar que todas las características contribuyan equitativamente al resultado, mejorando significativamente el rendimiento y la precisión del modelo K-NN.

El código utilizado para normalizar los datos es el siguiente:

```
# Normalización de los datos

scaler = StandardScaler()
X_train_scaled = scaler.fit_transform(X_train)
X_test_scaled = scaler.transform(X_test)
```

Paso 6: Entrenamiento del modelo K-NN

Se entrena un modelo K-NN con los datos de entrenamiento escalados, para obtener las características inherentes al algoritmo K-NN, las cuales serían las siguientes:

- **Naturaleza del Algoritmo K-NN:** El algoritmo K-NN funciona identificando los K puntos de datos más cercanos (vecinos) a un punto de consulta.
- **Importancia de Escalar los Datos:** Escalar los datos de entrenamiento es crucial para poder validar y no tener incongruencias en el código de aprendizaje K-NN, ya que asegura que todas las características contribuyan equitativamente al cálculo de la distancia, dado que, sin escalar, las características con rangos

numéricos grandes dominarán la medida de distancia, lo que puede llevar a un rendimiento subóptimo del modelo.

- **Beneficios de Usar Datos Escalados:** Al utilizar datos escalados para entrenar el modelo K-NN, se mejora la capacidad del modelo para identificar los verdaderos vecinos más cercanos en un espacio de características equitativo. Esto es especialmente importante ya que se está desarrollado en basa a la ecuación de Richards lo que implica identificaciones más exactas y confiables que puede hacer predicciones basadas en patrones genuinos de similitud entre los puntos de datos.
- **Efectividad en la Predicción:** Cuando el modelo K-NN está bien entrenado con datos escalados, puede ser extremadamente efectivo en capturar relaciones no lineales y patrones complejos en los datos, esto es un indicador de que el código cumple con las condiciones de entorno validándose mutuamente con los coeficientes de estado.

El código utilizado para entrenar el modelo K-NN es el siguiente:

```
# Entrenamiento del modelo K-NN  
  
knn = KNeighborsRegressor(n_neighbors=5)  
knn.fit(X_train_scaled, y_train)
```

Este Código crea una instancia del modelo K-NN destinado para tareas de regresión. El modelo utiliza el algoritmo K-Nearest Neighbors, que predice el valor de una nueva observación basándose en las K observaciones más cercanas de los datos de entrenamiento. En este caso, se especifica que $K = 5$, lo que significa que el modelo buscará los 5 vecinos más cercanos para hacer sus predicciones. La elección de K es un hiperparámetro crítico que puede influir significativamente en el rendimiento del modelo.

Paso 7: Evaluación del modelo

Se evalúa el modelo utilizando el conjunto de prueba para determinar su precisión, que mide qué tan bien el modelo predice. A continuación, se muestra el código utilizado para evaluar la precisión del algoritmo de aprendizaje automático (K-NN).

```
# Evaluación del modelo

score = knn.score(X_test_scaled, y_test)
print(f"Precisión del modelo K-NN: {score}")
```

El código presentado se utiliza para evaluar el rendimiento de un modelo de regresión K-Nearest Neighbors (K-NN) ya entrenado, usando un conjunto de datos de prueba.

Figura 22

Precisión del modelo

```
# Evaluación del modelo
score = knn.score(X_test_scaled, y_test)
print(f"Precisión del modelo K-NN: {score}")
```

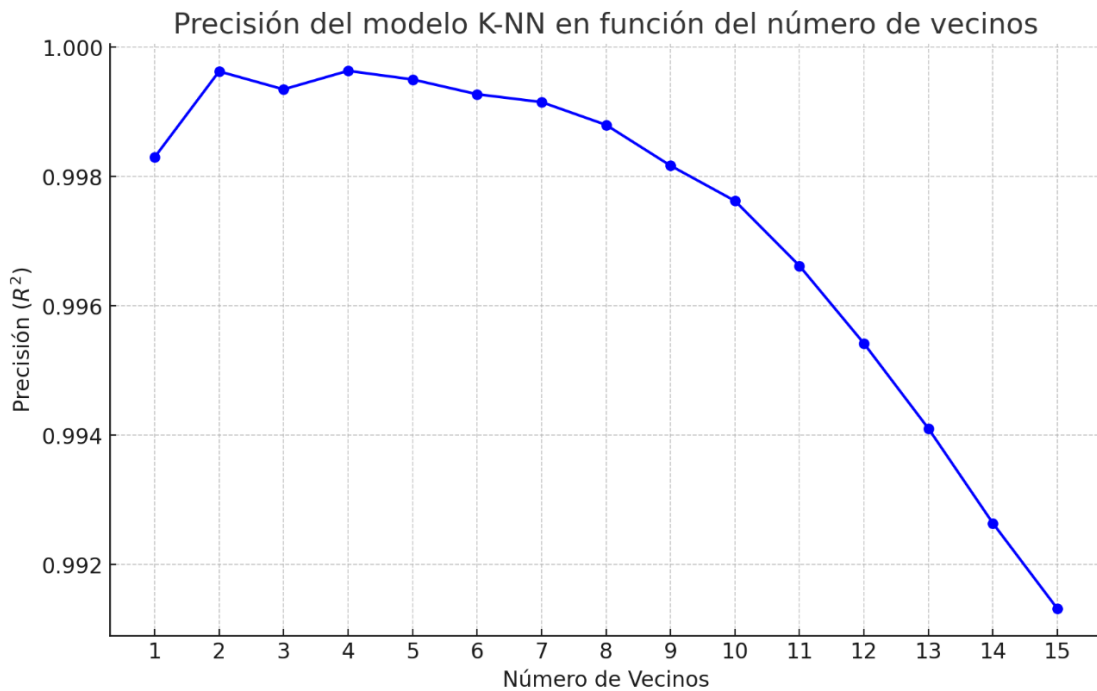
➡ Precisión del modelo K-NN: 0.999500571453694

Nota. Elaboración Propia

En el modelo de regresión como K-NN, el método `.score()` por defecto calcula el coeficiente de determinación, también conocido como R^2 , para las predicciones hechas en el conjunto de prueba. El R^2 es una medida estadística que representa la proporción de la varianza para una variable dependiente que es predecible a partir de las variables independientes. Si en los resultados del código el valor de la precisión arroja un R^2 de 1 indica una predicción perfecta, un R^2 de 0 indicaría que el modelo no es mejor que simplemente predecir el valor medio de la variable objetivo, y un R^2 negativo indica un rendimiento peor que las predicciones aleatorias.

Para el caso del código realizado en esta investigación la simulación arroja un valor de 0.999500571453694 o 99.95% (Ver figura 22), lo que refleja una gran aproximación a un $R^2 = 1$, esto indica una predicción perfecta lo que demuestra que el código realizado tiene una gran confiabilidad y validez.

Figura 23
Precisión del modelo K-NN



Nota. Elaboración Propia

La figura 23 muestra la precisión del modelo K-NN (medida a través del coeficiente de determinación, R^2 en función del número de vecinos considerados, desde 1 hasta 15. Se observa cómo varía la precisión con diferentes configuraciones de K , lo que permite seleccionar el número óptimo de vecinos para equilibrar entre el sobreajuste (cuando K es demasiado bajo y el modelo capta demasiado ruido de los datos de entrenamiento) y el subajuste (cuando K es demasiado alto, haciendo que el modelo sea demasiado general).

Paso 8: Predicción y visualización

La fase de predicción y visualización en el contexto de utilizar un modelo de aprendizaje automático, como K-Nearest Neighbors (K-NN), para predecir y entender comportamientos o relaciones en los datos se compone de la siguiente forma:

- **Predicción con el Modelo Entrenado:** Una vez que el modelo K-NN ha sido entrenado con un conjunto de datos relacionados con la conductividad hidráulica $K(\theta)$ en función del contenido de humedad del suelo θ , se utiliza para hacer predicciones sobre nuevos datos. Las predicciones resultantes, $K(\theta)$ predichas,

nos dan una estimación de la conductividad hidráulica basada en el aprendizaje del modelo a partir de los patrones identificados en los datos de entrenamiento.

El código utilizado para la predicción del modelo es el siguiente:

```
# Predicción con nuevos datos

new_theta = np.linspace(0, 1, 100).reshape(-1, 1)
new_theta_scaled = scaler.transform(new_theta)
predicted_K = knn.predict(new_theta_scaled)
```

`predicted_K = knn.predict(new_theta_scaled)` utiliza el modelo K-NN entrenado (`knn`) para predecir la conductividad hidráulica $K(\theta)$ basada en los valores escalados de θ . El método `.predict()` genera un conjunto de predicciones de $K(\theta)$ para cada uno de los nuevos valores de θ , basándose en la información aprendida del modelo durante su entrenamiento.

- **Visualización de los Resultados:** Este paso es fundamental ya que permite interpretar la eficacia del modelo y la naturaleza de la relación entre θ y $K(\theta)$, ya que al graficar tanto los valores reales de $K(\theta)$ obtenido del desarrollado realizado a partir de la ecuación de Richards se pueden comparar visualmente la precisión y la calidad de las predicciones del modelo.

A continuación, se muestra el código completo utilizado para el desarrollo del algoritmo de aprendizaje automático (K-NN).

```
import numpy as np
import matplotlib.pyplot as plt
from sklearn.neighbors import KNeighborsRegressor
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler

# Parámetros para la conductividad hidráulica relativa
alpha = 1.2 # Coeficiente de alpha
rho = 2 # Coeficiente rho
mu = 0.5 # Coeficiente mu
lambda = 0.5 # Coeficiente lambda
Ks = 0.0005152928571428572 # Valor de la conductividad hidráulica
saturada en cm/s
```

```

# Rango para theta desde 0 a 1
theta_values = np.linspace(0, 1, 100, endpoint=False)

# Calculo de K(theta)
K_theta = Ks * (((1 - np.abs(alpha * theta_values)) ** rho) ** (1 -
1/rho)) /
                ((1 + np.abs(alpha * theta_values)) ** rho) ** (mu *
lambda)) ** 2

# Eliminar cualquier NaN en K_theta y los correspondientes
theta_values
valid_indices = ~np.isnan(K_theta)
K_theta = K_theta[valid_indices]
theta_values_clean = theta_values[valid_indices]

# Dividir los datos en entrenamiento y prueba
X = theta_values_clean.reshape(-1, 1) # Convertimos a 2D array para
scikit-learn
X_train, X_test, y_train, y_test = train_test_split(X, K_theta,
test_size=0.2, random_state=42)

# Normalización de los datos
scaler = StandardScaler()
X_train_scaled = scaler.fit_transform(X_train)
X_test_scaled = scaler.transform(X_test)

# Entrenamiento del modelo K-NN
knn = KNeighborsRegressor(n_neighbors=5)
knn.fit(X_train_scaled, y_train)

# Evaluación del modelo
score = knn.score(X_test_scaled, y_test)
print(f"Precisión del modelo K-NN: {score}")

# Predicción con nuevos datos
new_theta = np.linspace(0, 1, 100).reshape(-1, 1)
new_theta_scaled = scaler.transform(new_theta)
predicted_K = knn.predict(new_theta_scaled)

# Graficar los resultados
plt.figure(figsize=(14, 7))

# Gráfico de la relación real entre theta y K(theta)
plt.subplot(1, 2, 1)
plt.scatter(theta_values_clean, K_theta, color='blue', label='Datos
reales')
plt.title('Relación real entre  $\theta$  y  $K(\theta)$ ')
plt.xlabel('θ (Contenido de humedad del suelo)')
plt.ylabel('K(θ) (Conductividad hidráulica)')
plt.legend()

# Gráfico de la predicción de K(theta) usando K-NN
plt.subplot(1, 2, 2)

```


```

plt.scatter(theta_values_clean, K_theta, color='blue', label='Datos
reales')
plt.plot(np.linspace(0, 1, 100), predicted_K, color='red',
label='Predicción K-NN')
plt.title('Predicción de  $K(\theta)$  usando K-NN')
plt.xlabel('θ (Contenido de humedad del suelo)')
plt.ylabel('K(θ) (Conductividad hidráulica)')
plt.legend()
plt.tight_layout()
plt.show()

```

Figura 24

Relación real vs la predicción de la conductividad hidráulica



Nota. Elaboración Propia

La similitud entre la distribución de los puntos azules en ambos gráficos es un indicador de que el modelo K-NN ha aprendido adecuadamente la tendencia de los datos. La línea roja en el gráfico de la derecha muestra cómo el modelo K-NN ha interpretado esta relación y cómo espera que $K(\theta)$ varíe con θ para valores dentro del rango observado. La línea roja se mantiene cerca de los puntos azules, sugiriendo que el modelo es capaz de capturar la variabilidad en la conductividad hidráulica con un grado de precisión razonable.

Además, la línea roja proporciona una representación visual de la variabilidad de la conductividad hidráulica según lo predicho por el modelo K-NN a lo largo del rango de valores de θ . El hecho de que la línea roja siga de cerca la tendencia de los puntos azules valida aún más la precisión del modelo: indica que el modelo puede predecir valores de $K(\theta)$ que están en consonancia con los cálculos o mediciones reales.


CAPÍTULO IV: RESULTADOS Y DISCUSIÓN

4.1. Análisis e Interpretación de los resultados

El modelo matemático desarrollado para el sistema de Riego Laguna Huanzo, se derivó de la aplicación de la ecuación de Richards, un enfoque diferencial avanzado para describir el movimiento del agua en medios porosos como el suelo. Este modelo incorpora de manera integral los parámetros físicos del suelo, tales como su capacidad de campo, parámetro de forma, permeabilidad y conductividad hidráulica saturada, así como variables climáticas que incluyen la humedad y la temperatura. Al correlacionar estas propiedades del suelo y condiciones climáticas, el modelo es capaz de predecir la dinámica del flujo de agua a través del perfil del suelo con una alta precisión.

Figura 25

Respuesta de la Conductividad Hidráulica

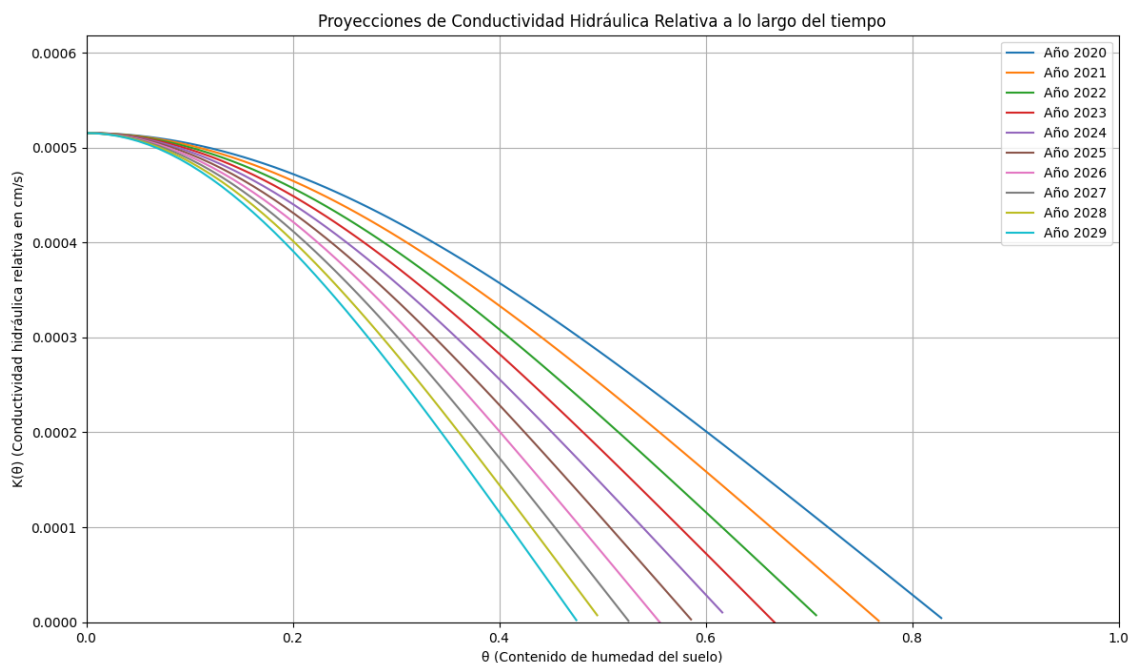


Nota. Elaboración Propia

Para validar la eficacia del modelo matemático basado en la ecuación de Richards, se empleó un enfoque de aprendizaje automático complementario utilizando el algoritmo K-Nearest Neighbors (K-NN). La figura 24 ilustra cómo este modelo de aprendizaje automático ha sido aplicado al sistema, y la figura 25 detalla la precisión alcanzada por el algoritmo, la cual asciende a un notable 99.95%. Esta alta tasa de precisión indica que el algoritmo K-NN ha sido excepcionalmente eficiente en aprender las complejidades y patrones del modelo de Richards, lo que sugiere una alineación significativa entre los datos observados y los resultados simulados por el modelo.

La precisión de 99.95% es un indicador robusto de la confiabilidad del modelo K-NN en su tarea de replicar los procesos hidrológicos que gobiernan el sistema de riego. Esto se logra mediante la capacidad del algoritmo para identificar patrones en los datos de entrada, que incluyen las variables de suelo y climáticas, y predecir con exactitud la respuesta del sistema en términos de humedad del suelo y tasas de infiltración. Como se ha demostrado una alta precisión del modelo desarrollado a continuación se evalúan los escenarios, y a partir de estas simulaciones por escenarios los gestores de recursos hídricos y los agricultores podrán evaluar el impacto de diversas estrategias de riego y tomar decisiones informadas que optimicen el uso del agua y mejoren la sostenibilidad de sus prácticas agrícolas.

Figura 26
Proyecciones futuras de la Conductividad Hidráulica



Nota. Elaboración Propia

La figura 26 muestra proyecciones futuras de la conductividad hidráulica relativa $K(\theta)$ en función del contenido de humedad del suelo θ a lo largo de varios años. Las líneas planas en la parte superior de la gráfica, cada una correspondiente a un año diferente desde 2020 hasta 2029, cada línea representa la conductividad para un año diferente, reflejando cómo el parámetro α se incrementa año tras año. A medida que α aumenta, la conductividad hidráulica $K(\theta)$ disminuye para un mismo contenido de humedad del suelo θ cuál es un indicativo de que el modelo anticipa una disminución en la capacidad del suelo para transmitir agua con el tiempo. Esto representa un suelo que se compacta o que pierde estructura porosa, lo cual es común con la erosión, el sobre pastoreo, o el uso intensivo de maquinaria agrícola. El código utilizado en el cálculo de proyección se encuentra en el Anexo 7.

4.1.1. Resultados de Proyección en 10 años futuros

- **Reducción de la Infiltración de Agua:** En la figura 26 se observa que la conductividad hidráulica del suelo disminuye, esto indica que con el tiempo el suelo podría volverse menos capaz de infiltrar y retener agua. Esto puede deberse a la compactación del suelo o la pérdida de materia orgánica, lo que resulta en una estructura de suelo más densa y menos porosa. Aunque la disminución es leve con una diferencia de rango en un 0.1 por año, esto es un indicador de que se debería comenzar a tomar medidas.
- **Riesgo de Escorrentía y Erosión:** El suelo al tener menor conductividad hidráulica puede tener un mayor riesgo de escorrentía superficial durante los eventos de lluvia. La escorrentía no solo lleva consigo agua, sino también nutrientes y suelo, lo que puede causar erosión y degradación de la tierra cultivable.
- **Efectos sobre los Cultivos:** Los cultivos pueden verse afectados negativamente si el suelo no puede suministrar suficiente agua a las raíces. Esto puede llevar a estrés hídrico en las plantas, lo que podría reducir el crecimiento y el rendimiento de los cultivos.
- **Impacto en la Gestión del Riego:** Como la figura 26, muestra una menor conductividad hidráulica por años, la gestión del riego puede necesitar adaptarse, posiblemente requiriendo un riego más frecuente, pero con menor

volumen de agua para evitar la saturación superficial y permitir que el agua se infiltre en el suelo.

Estas proyecciones pueden ser beneficiosas para la planificación a largo plazo del uso de la tierra y el manejo del agua. Al anticipar cómo la conductividad hidráulica podría cambiar con el tiempo, los agricultores y planificadores pueden desarrollar estrategias para mantener o mejorar la estructura del suelo.

Tabla 12
Coefficiente de Cultivo

COEFICIENTE DE USO CONSUNTIVO PARA LA CÉDULA DE CULTIVO (Kc)															
CULTIVOS DE BASE	ÁREA ha	Kc												CULTIVOS DE ROTACIÓN	ÁREA ha
		E	F	M	A	M	J	J	A	S	O	N	D		
Papa Amarga	110.00	0.90	1.07	0.90	0.65		0.36	0.67	1.05	0.95		0.45	0.75	HABAS VERDE	65.00
Papa nativa	225.00	0.95	1.10	0.85	0.65		0.40	0.71	1.05	0.85		0.50	0.70	ARVEJA GRANO	25.00
Papa común	20.00	0.87	1.10	1.04	0.80	0.65	0.85	1.12	1.00	0.75	0.40	0.40	0.57	TARWI	15.00
Maca	65.00	0.90	1.05	0.95	0.85	0.43	0.65	0.90	1.10	0.85	0.35	0.52	0.65	CEBADA FORRAJERA	55.00
Quinua	168.00	1.00	1.20	1.17	0.90	0.33	0.55	1.00	1.20	1.00	0.75	0.40	0.55	QUINUA	75.00
Maíz amiláceo	125.00	0.80	1.10	0.85	0.55		0.42	0.80	1.10	0.85	0.55		0.42	MAÍZ AMILÁCEO	85.00
Trigo	80.00	0.75	0.85	1.05	0.75	0.25	0.42	0.80	1.05	0.85			0.45	MAIZ CHOCCLO	55.00
Cebada	32.00	0.90	1.10	0.90	0.25	0.50	0.70	0.95	1.05	0.85	0.65	0.43	0.65	PAPA NATIVA	90.00
Alfalfa	10.00	0.85	0.85	0.85	0.90	0.90	0.90	0.90	0.90	0.80	0.80	0.80	0.80	ALFALFA	10.00
Rye Grass, Trébol	215.00	0.85	0.85	0.85	0.90	0.90	0.90	0.90	0.90	0.80	0.80	0.80	0.80	RAYGRAS+TREBOL	215.00
Avena forrajera	124.60	0.75	1.10	0.90		0.45	0.75	0.85	1.05	0.75	0.25		0.50	TRIGO	95.00
Kc ponderado		0.88	1.04	0.93	0.74	0.58	0.66	0.87	1.03	0.84	0.61	0.55	0.63		
	1774.6														785.00

Nota. Datos tomados del informe técnico N° 0015-2022-ANA-AAA.PA/HTP.

Los datos de la tabla 12, son datos obtenidos a partir del estudio realizado en los Anexos N°3,4 y 5, los cuales se tomó como año estándar la información recopilada por SENAHMI y la ANA para el año 2020, esto con el fin de mostrar de qué manera el modelo K-NN de aprendizaje automático, permite asumir hechos en base a como interviene la conductividad hidráulica en los cultivos.

Para esto primero aplicamos el promedio del Kc ponderado, para todos los valores de Kc, obteniendo el promedio 0.78, el cual se coloca en el código mostrado a continuación.

```

import numpy as np
import matplotlib.pyplot as plt
from sklearn.linear_model import LinearRegression
from sklearn.metrics import r2_score

# Parámetros para la conductividad hidráulica relativa
Ks = 0.0005152928571428572 # Valor de la conductividad hidráulica
saturada en cm/s
rho = 2 # Coeficiente rho
mu = 0.5 # Coeficiente mu
lambd = 0.5 # Coeficiente lambda

# Rango para theta desde 0 a 1
theta_values = np.linspace(0, 1, 100, endpoint=True)

alpha = 1.2
K_theta_values = Ks * (((1 - np.abs(alpha * theta_values) ** rho) **
(1 - 1/rho)) /
((1 + np.abs(alpha * theta_values) ** rho) **
(mu * lambd))) ** 2

mean_value = np.nanmean(K_theta_values)
K_theta_values = np.where(np.isnan(K_theta_values), mean_value,
K_theta_values)

Kc_values = 0.78 + 0.02 * theta_values

# Modelo de regresión lineal
model = LinearRegression()

# Ajustamos el modelo con los valores de K_theta y Kc
model.fit(K_theta_values.reshape(-1, 1), Kc_values)

# Realizamos predicciones con el modelo ajustado
Kc_predictions = model.predict(K_theta_values.reshape(-1, 1))

# Calculamos el R² para evaluar el rendimiento del modelo
r_squared = r2_score(Kc_values, Kc_predictions)

```

```

print(f'Coeficiente de Determinación (R2): {r_squared}')

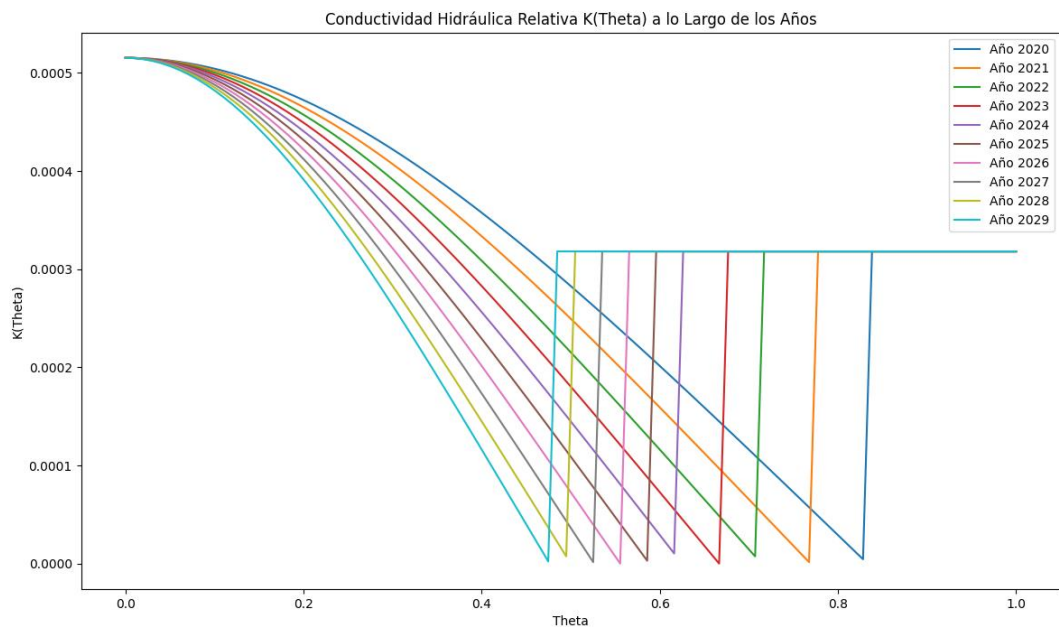
# Inicializar la gráfica para K(theta) a lo largo de los años
plt.figure(figsize=(14, 8))

# Generar y graficar K(theta)
for i in range(10):
    alpha = 1.2 + i * 0.1 # Aumentar alpha para cada año
    K_theta = Ks * (((1 - np.abs(alpha * theta_values)) ** rho) ** (1
- 1/rho)) /
                    ((1 + np.abs(alpha * theta_values)) ** rho) **
(mu * lambda)) ** 2
    # Imputación de NaNs para la visualización
    K_theta = np.where(np.isnan(K_theta), mean_value, K_theta)
    plt.plot(theta_values, K_theta, label=f'Año {2020 + i}')

plt.xlabel('Theta')
plt.ylabel('K(Theta)')
plt.title('Conductividad Hidráulica Relativa K(Theta) a lo Largo de
los Años')
plt.legend()
plt.show()

```

Figura 27
Conductividad Hidráulica en función a Kc



Nota. Elaboración Propia

Vemos en la figura 27 que la proyección futura se cruza con el valor R^2 a partir del modelo de regresión lineal para los valores de K_c , esto indica que existe un punto de inflexión en ambos parámetros, lo que demuestra que la conductividad hidráulica tiene implicaciones importantes para la gestión de recursos hídricos, especialmente si se relaciona con la capacidad del suelo para retener o transmitir agua. Al analizar más detenidamente la gráfica, se detecta que el punto de inflexión se presenta en un $K(\theta)$ de aproximadamente 0.0003. La consistencia de este punto a lo largo de los años sugiere que hay un patrón estable en la conductividad hidráulica que puede estar vinculado con prácticas de cultivo sostenibles. Aunque inicialmente parece que los datos del año 2020 son los únicos considerados, al expandir el análisis se aprecia que este patrón de inflexión varía en función de θ . Esto podría indicar que la estrategia de cultivo adoptada ha creado un entorno con poca variación en términos de conductividad hidráulica a lo largo de los años, posiblemente reflejando un manejo agronómico exitoso y consistente que mantiene las condiciones óptimas del suelo para el cultivo.

Este tipo de análisis es vital para anticipar las necesidades de riego y para optimizar el uso del agua en la agricultura, promoviendo la sostenibilidad y la resiliencia en los sistemas de cultivo. La conductividad hidráulica, al influir en la disponibilidad de agua para las plantas, juega un papel fundamental en la producción agrícola, y una comprensión clara de su comportamiento a través del tiempo es beneficioso para garantizar un rendimiento estable y sostenible.

CONCLUSIONES

La correlación detallada entre las propiedades del suelo y las condiciones climáticas, incluyendo precipitación y temperatura, con los patrones de conductividad hidráulica en Santiago de Lucanamarca, evidencia una relación significativa que permite utilizar estas variables como predictores confiables para el modelo de conductividad hidráulica. Este análisis se fundamenta en la recopilación y examen de datos históricos, aplicando técnicas estadísticas avanzadas para garantizar una predicción precisa y ajustada a la realidad del distrito, optimizando así la gestión de recursos hídricos en un contexto de cambio climático y demandas agrícolas crecientes.

La aplicación de la ecuación de Richards ha permitido desarrollar un modelo matemático robusto que describe con alta precisión el movimiento del agua en relación con la conductividad hidráulica del suelo en el distrito de Santiago. Este modelo, ajustado a través de una exhaustiva colección de datos sobre las características físicas y químicas del suelo, ha mejorado significativamente la capacidad de predecir la dinámica del agua, facilitando así la toma de decisiones estratégicas para la optimización del riego.

La integración del modelo matemático basado en la ecuación de Richards con el algoritmo de aprendizaje automático K-NN ha resultado en una optimización significativa de la predicción de conductividad hidráulica. Este enfoque híbrido ha demostrado ser efectivo al combinar la precisión del modelo matemático con la flexibilidad y capacidad de adaptación del K-NN mostrando una precisión del 99.95%, proporcionando así predicciones altamente precisas y confiables que son fundamentales para la planificación y gestión eficiente del riego.

La simulación de diversos escenarios, utilizando el modelo predictivo desarrollado, ha validado eficazmente sus predicciones de conductividad hidráulica bajo diferentes condiciones climáticas y de suelo. Esta fase de validación, crucial para el éxito del proyecto, ha confirmado la fiabilidad y precisión del modelo, demostrando su potencial para ser aplicado en la optimización del sistema de riego Laguna Huanzo y como interviene en su relación con los cultivos.

RECOMENDACIONES

Dada la importancia de las propiedades del suelo y las condiciones climáticas en la conductividad hidráulica, se recomienda establecer un sistema de monitoreo continuo. Este sistema debería emplear sensores IoT (Internet de las Cosas) para recoger datos en tiempo real sobre la humedad del suelo, temperatura, precipitación y otros factores relevantes. La recopilación de datos en tiempo real permitirá ajustes dinámicos en el modelo predictivo, mejorando la precisión de las predicciones de conductividad hidráulica y optimizando el uso del agua en respuesta a las condiciones cambiantes.

Para maximizar la utilidad del modelo predictivo desarrollado, se recomienda su integración con herramientas de agricultura de precisión, como sistemas de riego automatizados y drones para la monitorización de cultivos. La combinación del modelo predictivo con estas tecnologías permitirá no solo una planificación y ejecución más precisas del riego sino también una gestión agrícola más informada y eficaz. Esta integración hará posible aplicar de manera óptima el agua y otros insumos agrícolas, basándose en las necesidades específicas de los cultivos y las condiciones del suelo, mejorando así la productividad agrícola y la sostenibilidad ambiental.

Se recomienda fomentar programas de capacitación y desarrollo de capacidades para los agricultores y técnicos locales en el uso e interpretación del modelo predictivo de conductividad hidráulica. Estos programas deberían incluir formación sobre el manejo de tecnologías de monitoreo, interpretación de datos recogidos y toma de decisiones basadas en las predicciones del modelo. El empoderamiento de los agricultores y técnicos con este conocimiento y herramientas contribuirá a la adopción más amplia de prácticas de riego eficientes, promoviendo una gestión sostenible del agua y una mayor resiliencia frente a las variabilidades climáticas.

REFERENCIAS BIBLIOGRÁFICAS

- Agrawal, A., Gans, J. S., y Goldfarb, A. (2019). Artificial Intelligence: The Ambiguous Labor Market Impact of Automating Prediction. *The Journal of Economic Perspectives*, 33(2), 31–50. <https://www.jstor.org/stable/26621238>
- Ángel, L., y Pineda, D. (2019). Medición de la conductividad hidráulica y curvas de retención de humedad en suelos parcialmente saturados utilizando metodologías modernas. Obtenido de Universidad Católica de Colombia: <https://hdl.handle.net/10983/23891>
- AreaCiencias. (2021). *Difusividad Térmica - Areaciencias*. Areaciencias. <https://www.areaciencias.com/fisica/difusividad-termica/>
- Auccasi M. (2021). Provincia de Huancasancos. [Enfermeriaperu.com](https://www.hsancos.enfermeriaperu.com/provihuancapoli.htm). <https://www.hsancos.enfermeriaperu.com/provihuancapoli.htm>
- Blanco, M. (2015). *IDIS Aprendizaje automático*. [Proyectoidis.org](https://proyectoidis.org/aprendizaje-automatlico/). <https://proyectoidis.org/aprendizaje-automatlico/>
- Bonaccorso, G. (2018). *Machine Learning Algorithms* (2 ed.). Packt Publishing Ltd.
- Brady, N., y Weil, R. (2010). *The Nature and Properties of Soils*. 14th Edition. PrenticeHall, Inc. New Jersey. USA.
- Briaud, J. (2013). *Geotechnical Engineering*. Hoboken, New Jersey: John Wiley & Sons.
- Calvo, A. (2019.). *Riego inteligente: ¿La revolución del futuro?* Agroptima; Agroptima. <https://www.agroptima.com/es/blog/riego-inteligente/>
- Cortés C., F., y Rubalcava, R. Ma. (1983). NOTAS SOBRE COLINEALIDAD EN EL MODELO DE REGRESIÓN LINEAL DE TRES VARIABLES. *Demografía y Economía*, 17(2), 181–198. <http://www.jstor.org/stable/40602348>
- Dellot, B., y Balaram, B. (2018). MACHINE LEARNING. *RSA Journal*, 164(3 (5575)), 44–47. <https://www.jstor.org/stable/26798354>
- Guillén, J., Jorge Calle García, Gavidia, A., y Vélez, A. (2020). Desarrollo sostenible: desde la mirada de preservación del medio ambiente colombiano. *Revista de Ciencias Sociales*, 26(4), 293–307. <https://dialnet.unirioja.es/descarga/articulo/7687041.pdf>

- González-Barrios, José Luis, González-Cervantes, G., Sánchez-Cohen, I., López-Santos, A., Valenzuela-Núñez, L. M., González-Barrios, José Luis, González-Cervantes, G., Sánchez-Cohen, I., López-Santos, A., & Valenzuela-Núñez, L. M. (2011). Caracterización de la porosidad edáfica como indicador de la calidad física del suelo. *Terra Latinoamericana*, 29(4), 369–377. https://www.scielo.org.mx/scielo.php?pid=S0187-57792011000400369&script=sci_arttext
- Hernández, R., Fernández, C. y Baptista, P. (2014). Metodología de la Investigación. México: Mc Graw Hill
- Jordán, A. (2010). Edafología Departamento de Cristalografía, Mineralogía y Química Agrícola. Universidad de Sevilla. España.
- Lamz, A. y González, M. C. (2013). La salinidad como problema en la agricultura: la mejora vegetal una solución inmediata. Instituto Nacional de Ciencias Agrícolas. Cuba. *Cultivos Tropicales*, Vol. 34, No. 4, p 31-42. Recuperado de: <http://scielo.sld.cu/pdf/ctr/v34n4/ctr05413.pdf>
- Larose, D. T., y Larose, C. D. (2014). *Discovering knowledge in data: An Introduction to Data Mining*. (2 ed.). Wiley
- Leyva, M. (2017). Estimación de la conductividad hidráulica saturada en campo en la localidad de Tingua - 2017. *Unasam.edu.pe*. <http://repositorio.unasam.edu.pe/handle/UNASAM/3501>
- Liu, J., Song, X., Zhou, Y., Peng, X., Zhang, Y., Liu, P., Zhu, C. (2022). Deep anomaly detection in packet payload. *Neurocomputing*, 14. <https://doi.org/10.1016/j.neucom.2021.01.146>
- López, M., y Estrada, H. (2015). Propiedades físicas, químicas y biológicas del suelo. *Bioagrocencias*, 8(1), 3-11.
- Lu, N., y Likos, W. (2004). *Unsaturated Soil Mechanics*. Hoboken, New Jersey: John Wiley & Sons
- Macías, J., Vargas, A., & Arellano, F. (2018). Conductividad hidráulica en dos sitios del valle central de costa rica: análisis comparativo de tres metodologías de ensayo

- en la zona no saturada. *Revista Geológica de América Central*, 59(59), 71–96.
<https://doi.org/10.15517/rgac.v59i0.34160>
- Merino, J. (2022). Diseño e implementación de una estrategia de control para sistemas de riego utilizando aprendizaje reforzado. *Uchile.cl*.
<https://repositorio.uchile.cl/handle/2250/185787>
- Meza Ochoa, V. E., (2011). SUELOS PARCIALMENTE SATURADOS, DE LA INVESTIGACIÓN A LA CÁTEDRA UNIVERSITARIA. *Boletín de Ciencias de la Tierra*, (31), 23-38.
- Nazarathy, Y., y Klok, H. (2021). *Statistics with Julia: Fundamentals for Data Science, Machine Learning and Artificial Intelligence*. Springer Nature Switzerland.
doi:10.1007/978-3-030-70901-3
- Núñez, E., Steyerberg, E. W., y Núñez, J. (2011). Estrategias para la elaboración de modelos estadísticos de regresión. *Revista Española de Cardiología*, 64(6), 501–507. <https://doi.org/10.1016/j.recesp.2011.01.019>
- Parisi F., A., Parisi F., F., y Guerrero C., J. L. (2003). MODELOS PREDICTIVOS DE REDES NEURONALES EN ÍNDICES BURSÁTILES. *El Trimestre Económico*, 70(280(4)), 721–744. <http://www.jstor.org/stable/20856798>
- Pérez, L., y García, G. (2015). Evaluación de la conductividad hidráulica del suelo en un sistema agroforestal de café (*coffea arabica*) en CENECOOP, Masaya, Nicaragua, 2014. Obtenido de Universidad Nacional Agraria:
<https://repositorio.una.edu.ni/id/eprint/3195>
- PESCS y De La Cruz, J. (2022). Estudio hidrológico para la acreditación de la disponibilidad hídrica superficial del proyecto creación del servicio de agua del sistema de riego laguna huazo centro poblado de Santa Rosa de Ccocha - distrito de Santiago de Lucanamarca - provincia de Huanca Sancos - región Ayacucho, CUI N° 2318619 (formato anexo N°06). Ana.gob.pe.
<https://hdl.handle.net/20.500.12543/5337>
- Porta, C., López-Acevedo, M., y Roquero, C. (2003). *Edafología para la Agricultura y el Medio Ambiente*. Madrid, España: Mundi-Prensa.

- Portocarrero, C. (2020). Clasificación del territorio peruano de acuerdo con su potencial de agua subterránea utilizando algoritmos de aprendizaje automatizado. *Pucp.edu.pe*. <http://hdl.handle.net/20.500.12404/17705>
- Pousada, M. (2021). Aplicación de algoritmos predictivos para la eficiencia en la gestión del riego. *Uoc.edu*. <http://hdl.handle.net/10609/126626>
- Rosales, M. (2022). Modelo de estimación de la conductividad hidráulica saturada in situ en función de las propiedades físicas del suelo en la localidad de Marian - 2021. *Unasam.edu.pe*. <http://repositorio.unasam.edu.pe/handle/UNASAM/5260>
- Salazar, O., y Nájera, F. (2011). Contaminación de aguas por el uso de fertilizantes nitrogenados y enmiendas orgánicas. Chile: Simposio Nacional de la Ciencia del Suelo. Boletín de la Sociedad Chilena de la Ciencia del Suelo, Universidad de Chile., 147-154. Obtenido de Boletín de la Sociedad Chilena de la Ciencia del suelo, Universidad de Chile.: <http://www.agren.cl/schcs/boletines/24/files/assets/downloads/page0001.pdf>
- Salgado, S., Núñez, R., Palma, D. J., y Lagunés, L. (2010). Manejo de fertilizantes químicos y orgánicos. Colegio de Postgraduados. México D. F., México.
- Sánchez, J. (2008). Flujo en medios porosos: Ley de Darcy. Obtenido de Departamento de Geología de la Universidad de Salamanca.
- Srinivas, M., Sucharitha, G., y Matta, A. (2021). Machine Learning Algorithms and Applications. Scrivener Publishing LLC.
- Tamayo y Tamayo, M. (c. 2003). La investigación: serie aprender a investigación. Santa Fe de Bogotá: ARFO EDITORES LTDA.
- UNEP (2018). *Plan Operativo Sectorial Agropecuario 2018 | UNEP Law and Environment Assistance Platform*. (2018). Unep.org. <https://leap.unep.org/en/countries/do/national-legislation/plan-operativo-sectorial-agropecuario-2018>
- UNESCO (2020). Informe mundial de las Naciones Unidas sobre el desarrollo de los recursos hídricos 2020: agua y cambio climático, datos y cifras. Unesco.org. https://unesdoc.unesco.org/ark:/48223/pf0000372876_spa

Villón Béjar, M. (2005). DRENAJE (Segunda Ed). Editorial Villón.

ANEXOS

a) Matriz de consistencia

MATRIZ DE CONSISTENCIA								
TITULO: "DESARROLLO DE UN MODELO PREDICTIVO DE CONDUCTIVIDAD HIDRÁULICA PARA OPTIMIZAR EL SISTEMA DE RIEGO LAGUNA HUANZO, DISTRITO DE SANTIAGO - PROVINCIA DE HUANCA SANCOS - AYACUCHO"								
PROBLEMA	OBJETIVOS	HIPÓTESIS	VARIABLES	DIMENSIONES	INDICADORES	INSTRUMENTOS	METODOLOGIA	POBLACIÓN Y MUESTRA
Problema General	Objetivo General	Hipótesis General	Independiente: Características del sistema de riego	Condición climática	Precipitación Temperatura	Ficha de registro de recolección de datos.	La presente investigación presenta un enfoque cuantitativo. Este estudio se caracteriza por tener un alcance explicativo y aplicado. Esta investigación presenta un diseño de investigación no experimental.	Población: Todos los sistemas de riego ubicados dentro de la jurisdicción de la Autoridad Administrativa del Agua XI Pampas - Apurímac, específicamente bajo la Administración Local del Agua Bajo Apurímac - Pampas. Muestra: La muestra en esta investigación
¿Como desarrollar un modelo predictivo de conductividad hidráulica para optimizar la eficiencia del sistema de riego Laguna Huanzo en el distrito de Santiago, provincia de Huanca Sancos, Ayacucho?	Desarrollar un modelo predictivo de conductividad hidráulica para optimizar la eficiencia del sistema de riego Laguna Huanzo en el distrito de Santiago, provincia de Huanca Sancos, Ayacucho.	La aplicación de un modelo predictivo de conductividad hidráulica mejorará la eficiencia del sistema de riego Laguna Huanzo, optimizando el uso del agua en el distrito de Santiago, provincia de Huanca Sancos, Ayacucho.		Características físicas	Porosidad del suelo Estructura del suelo	Ficha de registro de recolección de datos.		
				Características químicas	Salinidad pH del suelo	Ficha de registro de recolección de datos.		
Problema específico	Objetivos específicos	Hipótesis específico			Ecuación de Richards			

<p>¿Cuál es la correlación de las propiedades del suelo y condiciones climáticas con los patrones de conductividad hidráulica en el distrito de Santiago, provincia de Huanca Sancos?</p>	<p>Analizar la correlación de las propiedades del suelo y condiciones climáticas con los patrones de conductividad hidráulica en el distrito de Santiago, provincia de Huanca Sancos.</p>	<p>Las propiedades del suelo y las condiciones climáticas en el distrito de Santiago, provincia de Huanca Sancos, tienen una correlación significativa con los patrones de conductividad hidráulica, lo que permite su utilización como predictores confiables en el modelo.</p>	<p>Dependiente: Conductividad hidráulica</p>	<p>Capacidad de simular y predecir el movimiento del agua en el suelo</p>			<p>es el sistema de riego Laguna Huanzo, ubicado en el Distrito de Santiago de Lucanamarca, entre las comunidades de Santa Rosa de Ccocha, Lucanamarca y Asunción de Erpa</p>
<p>¿Cómo se puede aplicar la ecuación de Richards para desarrollar un modelo matemático que describa el movimiento del agua en relación con la conductividad hidráulica?</p>	<p>Aplicar la ecuación de Richards para realizar un modelo matemático del movimiento del agua en la conductividad hidráulica.</p>	<p>La aplicación de la ecuación de Richards para modelar el movimiento del agua mejora significativamente la precisión de las estimaciones de conductividad hidráulica en comparación con modelos que no consideran la dinámica del movimiento del agua.</p>			<p>Algoritmo de aprendizaje K-NN</p>	<p>Software de Machine Learning (Python)</p>	
<p>¿De qué manera se puede integrar el modelo matemático con un algoritmo de aprendizaje automático (K-NN) para optimizar la precisión en la predicción de la conductividad hidráulica?</p>	<p>Combinar el modelo matemático con el algoritmo de aprendizaje automático (K-NN) para optimizar la predicción de conductividad hidráulica.</p>	<p>La integración del modelo matemático basado en la ecuación de Richards con el algoritmo de aprendizaje automático K-NN resulta en una optimización significativa de la predicción de la conductividad hidráulica.</p>			<p>Movimiento del agua</p>	<p>Software estadístico (R y Excel)</p>	

<p>¿Cómo se pueden simular diferentes escenarios utilizando el modelo matemático y el algoritmo de aprendizaje automático (K-NN)?</p>	<p>Simular escenarios para validar las predicciones del modelo desarrollado.</p>	<p>Las simulaciones de escenarios utilizando el modelo desarrollado confirman su validez, mostrando que las predicciones de conductividad hidráulica se alinean estrechamente con los datos observados en condiciones variadas.</p>							
---	--	---	--	--	--	--	--	--	--

Nota. Elaboración propia

ANEXO 2: Precipitación Mensual (mm)

PRECIPITACIÓN MENSUAL GENERADA (mm)														
Estación:	Zona de cultivos												F.R.:	1.2271
Altitud:	4050 msnm (promedio)													
AÑO	Ene.	Feb.	Mar.	Abr.	May.	Jun.	Jul.	Ago.	Sep.	Oct.	Nov.	Dic.	ANUAL	
2000	167.99	333.64	187.47	91.25	49.77	41.60	22.39	14.10	44.30	92.08	41.48	225.62	1311.7	
2001	304.93	183.33	288.01	40.64	92.90	7.46	15.76	21.57	21.57	23.23	110.00	171.67	1281.1	
2002	150.64	244.70	238.90	53.08	16.60	5.47	124.60	119.19	116.63	121.44	78.14	241.72	1511.1	
2003	211.43	173.63	176.33	66.14	20.25	0.00	1.60	36.69	28.96	55.71	68.35	157.80	996.9	
2004	62.34	181.36	165.29	36.57	6.38	24.54	15.71	19.88	66.75	34.60	60.25	183.08	856.7	
2005	158.42	94.73	172.28	49.33	0.00	0.00	15.95	15.46	63.32	79.17	29.82	158.91	837.4	
2006	256.71	197.44	241.98	74.36	5.15	10.06	4.91	59.15	13.01	102.93	153.75	156.33	1275.7	
2007	167.62	128.23	281.12	88.10	9.45	0.00	8.96	12.39	34.60	71.17	46.38	131.91	979.9	
2008	283.21	222.81	187.87	20.37	16.81	12.52	3.19	0.98	22.55	49.83	32.93	95.96	949.0	
2009	169.12	176.21	83.81	73.99	27.36	3.07	40.49	14.85	30.19	49.49	112.28	108.23	889.1	
2010	254.13	172.65	142.22	63.56	9.94	0.49	6.63	5.40	25.77	35.83	12.88	100.99	830.5	
2011	277.20	337.69	152.65	108.35	5.52	3.07	15.22	10.31	33.25	66.63	86.14	145.78	1241.8	
2012	149.58	257.81	151.54	129.21	6.14	5.64	1.47	0.37	9.20	42.10	62.34	0.00	815.4	
2013	179.25	235.71	151.73	94.93	76.41	19.36	9.10	12.57	33.40	41.21	27.94	17.36	899.0	
2014	151.40	235.80	232.70	44.98	44.76	17.11	11.28	15.55	44.36	50.90	88.39	72.05	1009.3	
2015	182.48	205.27	211.92	64.52	1.80	18.52	13.13	8.27	25.78	39.34	47.84	123.04	941.9	

2016	179.20	200.51	163.75	73.23	5.08	10.41	2.45	2.25	26.47	48.95	79.67	65.89	857.9
2017	187.03	185.50	202.73	85.91	19.15	3.82	5.98	1.75	37.94	76.07	50.27	112.35	968.5
2018	197.34	166.38	171.67	51.87	10.79	2.10	1.94	14.10	18.20	57.62	90.31	57.59	839.9
2019	143.88	190.65	163.91	67.44	22.08	2.11	5.30	9.69	20.11	65.17	86.82	99.15	876.3
2020	155.64	273.57	162.60	66.61	1.89	2.32	4.87	15.63	25.49	108.58	71.39	172.29	1060.3
PROM.	196.47	210.67	173.11	69.97	18.02	9.65	11.98	19.84	40.40	60.03	68.39	125.82	1004.4
Max.	343.44	337.69	288.01	129.21	92.90	50.96	124.60	119.19	434.14	159.34	197.72	241.72	
Min.	62.34	79.54	83.81	20.37	0.00	0.00	0.00	0.00	8.23	14.11	7.46	0.00	
Desv.	59.29	55.00	47.79	23.01	20.96	12.49	19.40	24.34	56.41	32.70	40.88	66.01	
P50%	188.19	208.85	164.64	68.04	10.36	5.03	5.93	10.84	30.27	54.69	66.51	135.56	
P75%	158.94	178.42	142.48	52.17	1.83	2.10	1.50	3.39	16.80	36.71	39.36	37.76	
P90%	142.86	154.67	114.11	40.46	0.33	0.34	0.34	0.42	12.98	21.45	23.86	17.30	
PE (mm)	100.70	101.67	97.37	43.71	0.00	0.00	0.00	0.00	11.21	29.79	32.17	71.61	

Nota. Datos tomados del informe técnico N° 0015-2022-ANA-AAA.PA/HTP. Fuente PESCS (Proyecto Especial Sierra Centro Sur) y De La Cruz (2022).

ANEXO 3: Demanda de Cultivo

Cuadro N°28: "Información base para cálculo de la demanda del Cultivo"

Proyecto: SISTEMA DE RIEGO
HUANZO

Ubicación

Departamento: AYACUCHO

Latitud: 14° 01' 00" 14.02

Provincia: HUANCASANCOS

Altitud: 4050.00 mnsn

Distrito: LUCANAMARCA

Eficiencia de Riego: 39%

Localidad: HUANZO

Información Referencial

Descripción	Unidad	E	F	M	A	M	J	J	A	S	O	N	D
<i>Precipitación Total Mensual</i>	mm	196.47	210.67	173.11	69.97	18.02	9.65	11.98	19.84	40.40	60.03	68.39	125.82
<i>Precipitación Efectiva Promedio Mensual</i>	mm	100.70	101.67	97.37	43.71	-	-	-	-	11.21	29.79	32.17	71.81
<i>Precipitación Total Mensual al 75%</i>	mm	158.94	178.42	142.48	52.17	1.83	2.1	1.50	3.39	16.80	36.71	39.36	87.78

Información Referencial

Descripción	Unidad	E	F	M	A	M	J	J	A	S	O	N	D
<i>Temperatura Media Mensual</i>	°C	9.84	9.59	9.82	9.57	8.65	7.87	7.62	8.61	9.20	10.11	10.04	10.24
<i>Precipitación Efectiva Mensual al 75%</i>	mm	158.94	178.42	142.48	52.17	1.83	2.10	1.50	3.39	16.80	36.71	39.36	87.78

ANEXO 4: Demanda Total de los Cultivos con Proyecto

		E	F	M	A	M	J	J	A	S	O	N	D		
Evapotranspiración Potencial		112.96	90.44	90.27	80.97	77.98	72.39	79	91.59	104.04	121.93	134.27	128.57	mm	
Precipitación Efectiva Mensual al 75%		158.94	178.42	142.48	52.17	1.83	2.1	1.5	3.39	16.8	36.71	39.36	87.78	mm	
Área Cultivada		1,174.60	1,174.60	1,174.60	1,050.00	635	785	785	785	785	650	845	1,174.60	ha	
CULTIVOS DE BASE	Papa Amarga	-	-	-	1.29		39.93	85.71	154.63	136.73		59.41	24.41	HABAS VERDE ARVEJA GRANO VERDE	CULTIVOS DE ROTACIÓN
	Papa nativa	-	-	-	2.64		17.22	34.99	59.47	45.92		160.26	12.83		
	Papa común	-	-	-	6.46	18.79	22.86	33.45	33.92	23.55	4.64	7.36	-		
	Maca	-	-	-	27.75	44.71	63.4	98.15	137.3	101.02	9.95	50.77	-	CEBADA FORRAJE	
	Quinua	-	-	-	89.17	45.98	72.53	149.03	204.84	167.77	105.27	61.82	-	QUINUA	
	Maíz amiláceo	-	-	-	-		61.69	134.47	212.19	156.13	66.16		-	MAÍZ AMILÁCEO	
	Trigo	-	-	-	17.55	36.25	39.92	87.01	130.84	101.02			-	MAÍZ CHOCLO	
	Cebada	-	-	-	-	85.77	112.09	169.72	214.1	165.31	98.19	15.08	-	PAPA NATIVA	
	Alfalfa	-	-	-	5.31	17.53	16.17	17.85	20.27	17.03	15.6	17.45	3.87	ALFALFA	
	Ray Grass, trebol	-	-	-	114.11	376.85	347.6	383.67	435.73	366.24	335.39	375.2	83.14	RAYGRAS+TREBOL	
Avena forrajera	-	-	-	-	81.03	127.14	159.91	226	149.15	-		-	TRIGO		
DMA - TOTAL		-	-	-	264.28	706.91	920.53	1,353.94	1,829.30	1,429.88	635.21	747.35	124.34	1000 m3	
Q 24 hrs		-	-	-	0.102	0.264	0.355	0.506	0.683	0.552	0.237	0.288	0.046	m3/seg	
Mr - Módulo de Riego		-	-	-	0.097	0.416	0.452	0.644	0.87	0.703	0.365	0.341	0.039	l/seg/ha	
Caudal de Diseño									0.683					m3/seg	
									682.98					l/seg/ha	

Nota. Datos tomados del informe técnico N° 0015-2022-ANA-AAA.PA/HTP. Fuente PESCS (Proyecto Especial Sierra Centro Sur) y De La Cruz (2022).

ANEXO 5: Balance Hídrico Anual

BALANCE HÍDRICO ANUAL														
														0.01 = Colmatación Anual
ITEM	AÑO	APORTES TOTALES EFECTIVO DEL RÍO HUACCRAHUAYCCO (MMC) INC Q "ECOLÓGICO"	APORTES TOTALES DEL RÍO YANACOLLPA (MMC) INC Q "ECOLÓGICO"	APORTES TOTALES DEL RÍO HUANZO (MMC) INC Q "ECOLÓGICO"	APORTES TOTALES (MMC)	*DEMANDAS ANUALES Totales (MMC)	Diferencia (MMC)	Vol. max. de almacenamiento (MMC)	VOLUMEN AL INICIO DEL AÑO (MMC)	EVAPORACIÓN (MMC)	INFILTRACIÓN (MMC)	VOLUMEN AL FIN DE AÑO (MMC)	DEFICIT (MMC)	EXCEDENCIA (MMC)
38	2000	3.965	7.657	9.004	20.667	8.023	12.643	12.630	12.630	0.844	0.047	12.620	0.000	12.643
39	2001	3.757	8.045	7.805	19.608	8.023	11.584	12.620	12.620	0.839	0.047	12.610	0.000	11.584
40	2002	4.501	8.407	10.966	23.874	8.023	15.851	12.610	12.610	0.857	0.047	12.600	0.000	15.851
41	2003	3.098	6.086	7.21	16.394	8.023	8.37	12.600	12.600	0.832	0.047	12.590	0.000	8.370
42	2004	2.645	4.728	5.625	12.998	8.023	4.974	12.590	12.590	0.827	0.047	12.580	0.000	4.974
43	2005	2.934	4.670	5.201	12.804	8.023	4.781	12.580	12.580	0.836	0.047	12.570	0.000	4.781
44	2006	3.418	6.211	7.909	17.538	8.023	9.515	12.570	12.570	0.845	0.047	12.560	0.000	9.515
45	2007	3.249	5.813	4.749	13.811	8.023	5.788	12.560	12.560	0.832	0.047	12.550	0.000	5.788
46	2008	2.451	4.491	4.692	11.634	8.023	3.61	12.550	12.550	0.819	0.047	12.540	0.000	3.610
47	2009	3.029	5.468	6.126	14.623	8.023	6.6	12.540	12.540	0.827	0.047	12.530	0.000	6.600
48	2010	1.676	2.603	3.193	7.471	8.023	-0.552	12.530	12.530	0.822	0.047	12.520	0.000	0.000
49	2011	3.370	7.051	7.068	17.489	8.023	9.466	12.520	12.520	0.817	0.047	12.510	0.000	8.045
50	2012	1.898	3.348	3.828	9.075	8.023	1.051	12.510	12.510	0.822	0.047	12.500	0.000	1.051
51	2013	3.035	5.300	6.118	14.453	8.023	6.43	12.500	12.500	0.819	0.047	12.490	0.000	6.430
52	2014	2.656	4.184	5.212	12.053	8.023	4.03	12.490	12.490	0.821	0.047	12.480	0.000	4.030

53	2015	2.900	5.330	6.287	14.517	8.023	6.494	12.480	12.480	0.823	0.047	12.470	0.000	6.494
54	2016	2.681	4.873	5.629	13.183	8.023	5.159	12.470	12.470	0.819	0.047	12.460	0.000	5.159
55	2017	3.257	6.219	7.282	16.757	8.023	8.734	12.460	12.460	0.824	0.047	12.450	0.000	8.734
56	2018	2.740	5.004	5.526	13.27	8.023	5.247	12.450	12.450	0.823	0.047	12.440	0.000	5.247
57	2019	2.950	4.948	5.75	13.648	8.023	5.624	12.440	12.440	0.820	0.047	12.430	0.000	5.624
58	2020	3.413	5.407	6.159	14.979	8.023	6.956	12.430	12.430	0.837	0.047	12.420	0.000	6.956

Nota. Datos tomados del informe técnico N° 0015-2022-ANA-AAA.PA/HTP. Fuente PESCS (Proyecto Especial Sierra Centro Sur) y De La Cruz (2022).

ANEXO6: Análisis por Laboratorio Físico y Químico

157

ESTUDIO HIDROLÓGICO PARA LA ACREDITACIÓN DE LA DISPONIBILIDAD HÍDRICA SUPERFICIAL DEL PROYECTO "CREACIÓN DEL SERVICIO DE AGUA DEL SISTEMA DE RIEGO LAGUNA HUANZO CENTRO POBLADO DE SANTA ROSA DE CCOCHA - DISTRITO DE SANTIAGO DE LUCANAMARCA - PROVINCIA DE HUANCASANCOS - REGIÓN AYACUCHO"



UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL DE HUAMANGA
FACULTAD DE CIENCIAS AGRARIAS
LABORATORIO DE SUELOS Y ANÁLISIS FOLIAR
Jr. Abraham Valdelomar N° 249 - Telf. 315936 966942996
Ayacucho - Perú

"Año del Bicentenario del Perú: 200 años de Independencia"

Región : Ayacucho HR. 00036
Provincia : Huancasancos
Distrito : Santiago de Lucanamarca
Localidad : CC. PP. Santa Rosa de Ccocha
Proyecto : Estudio Hidrológico para la Acreditación de la Disponibilidad Hídrica Superficial del Proyecto: "Creación del Servicio de Agua del Sistema de Riego Laguna Huanzo Centro Poblado Santa Rosa de Ccocha - Distrito de Santiago de Lucanamarca - Provincia de Huancasancos - Región Ayacucho".
Solicitante : Proyecto Especial Sierra Centro Sur (PESCS)

ANÁLISIS FÍSICO - QUÍMICO DE AGUA

DETERMINACIONES	FUENTE	
	Se Nahuimpampa	
CATIONES (meq./ Litro)		
CALCIO (Ca ⁺⁺)	10.70	
MAGNESIO (Mg ⁺⁺)	3.50	
POTASIO (K ⁺)	0.26	
SODIO (Na ⁺)	2.48	
AMONIO (NH ₄ ⁺)	0.00	
ANIONES (meq./ Litro)		
BICARBONATOS (HCO ₃ ⁻)	6.05	
CARBONATOS (CO ₃ ⁻)	0.00	
CLORUROS (Cl ⁻)	2.06	
FOSFATOS (PO ₄ ⁻³)	0.00	
NITRATOS (NO ₃ ⁻)	0.00	
SULFATOS (SO ₄ ⁻²)	8.79	
OTRAS DETERMINACIONES		
pH	7.28	
CE. (dS/m.)	1.630	
Sólidos en Suspensión (g/litro)	0.282	
Sales Solubles Totales (ppm)	1489.0	
Relación de Adsorción de Sodio	4.66	
Dureza Total (ppm CaCO ₃)	110.0	
CLASIFICACION	C3-S1	

OBSERVACIONES: Ver las indicaciones de la clasificación en el reverso.

Ayacucho, 04 de Junio del 2021

LABORATORIO DE ANÁLISIS DE SUELOS
PLANTA, AGUAS Y FERTILIZANTES
RESPONSABLES

Juan B. Girón Molina
C.I.P. 77120



José Luis De La Cruz Espinoza
REG. CIP N° 148904



Nota. Datos tomados de PESCS (Proyecto Especial Sierra Centro Sur) y De La Cruz (2022).

INTERPRETACIÓN DE LA CALIDAD DE AGUA DE RIEGO

La salinidad total es determinada por la medición de la conductividad del agua (CE.) Expresada en unidades de deci Siemens por metro (dSm^{-1}) o en milimhos por centímetro ($mmhos\ cm^{-1}$). También puede ser expresada como la cantidad total de sales disueltas (TDS), donde: TDS (en ppm o mgL^{-1}) = $640 \times CE$ (en de Sm^{-1} ó $mmhos\ cm^{-1}$).

Cuadro 1 Clasificación de las aguas de riego basada en su CE y TDS

Peligro de Salinidad	Características	CE dSm^{-1}	TDS ppm
Bajo (C_1)	- Bajo peligro de salinidad, no se espera efectos dañinos sobre las plantas y suelos.	< 0.25	< 160
Medio (C_2)	- Plantas sensibles pueden mostrar estrés a sales; moderada lixiviación previene la acumulación de sales en el suelo.	0.25 – 0.75	160 – 500
Alto (C_3)	- Salinidad afectará a muchas plantas. Requiere: selección de plantas tolerantes a salinidad, buen drenaje y lixiviación.	0.75 – 2.25	500 – 1500
Muy Alto (C_4)	- Generalmente no aceptable, excepto para plantas muy tolerantes a sales, se requiere excelente drenaje y lixiviación.	> 2.25	> 1500

* SAR (Relación de Absorción de Sodio): $SAR = Na^+ \text{ en meq } L^{-1} / ((Ca^{++} + Mg^{++}) \text{ en meq } L^{-1})^{1/2}$

Cuadro 2 Peligro de Sodio basado en el valor del SAR

Peligro de Na	SAR del agua	Comentarios sobre el peligro de Na
Bajo (S_1)	< 10	- Puede usarse para el riego de casi todos los suelos, sin peligro de destrucción de la estructura.
Medio (S_2)	10 – 18	- Puede desmejorarse la permeabilidad de suelos de textura fina con alta CIC. Puede usarse en suelos de texturas gruesa con buen drenaje.
Alto (S_3)	18 – 26	- Se producen, daños de los suelos, por acumulación de Na. Se requerirá intensivas prácticas de aplicación de enmiendas, drenaje y lixiviación.
Muy Alto (S_4)	> 26	- Generalmente no recomendable para el riego excepto en suelos de muy bajo contenido de sales. Se requerirá prácticas de manejo.

* Carbonato de sodio residual. (CSR) Tercer criterio que se usa para juzgar el peligro de sodio en las aguas de riego. Es definido como: $CSR = (CO_3^{2-} + HCO_3^-) - (Ca^{++} + Mg^{++})$.

Cuadro 3 Peligro de Sodio basado en el valor del CSR

Valor de CSR ($meq\ L^{-1}$)	Peligro de Na
< 0 (valores negativos)	- Ninguno. Ca y Mg del agua no participarán como carbonatos, ellos se mantienen Activos para prevenir la acumulación de Na en los sitios de cambio de la CIC.
0 – 1.25	- Bajo. Existe alguna remoción del Ca y Mg del agua de riego.
1.25 – 2.50	- Medio. Apreciable remoción de Ca y Mg del agua de riego.
> 2.50	- Alto. Todo o mayor parte del Ca y Mg del agua de riego es removido como carbonato precipitado produciendo acumulación de Na.



José Luis De La Cruz Espinoza
REG. CIP N° 148904

Nota. Datos tomados de PESCS (Proyecto Especial Sierra Centro Sur) y De La Cruz (2022).

ANEXO 7: Código de la Proyección Futura de la conductividad Hidráulica

```
import numpy as np
import matplotlib.pyplot as plt
from sklearn.neighbors import KNeighborsRegressor
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler

# Parámetros para la conductividad hidráulica relativa
alpha = 1.2 # Coeficiente de alpha
rho = 2     # Coeficiente rho
mu = 0.5   # Coeficiente mu
lambda = 0.5 # Coeficiente lambda
Ks = 0.0005152928571428572 # Valor de la conductividad hidráulica
saturada en cm/s

# Simulación de datos históricos con una dimensión de tiempo
years = np.arange(2000, 2020)
theta_values_time = np.linspace(0, 1.03, 100) # Rango para theta
desde 0 a 1

# K(theta) varía cada año basado en los parámetros dados
K_theta_time = []
for year in years:
    for t in theta_values_time:
        try:
            Kt = Ks * (((1 - np.abs(alpha * t) ** rho) ** (1 -
1/rho)) /
                    ((1 + np.abs(alpha * t) ** rho) ** (mu *
lambda))) ** 2
            if not np.isnan(Kt) and Kt >= 0:
                K_theta_time.append(Kt)
            else:
                K_theta_time.append(0)
        except ValueError:
            K_theta_time.append(0)

K_theta_time = np.array(K_theta_time).reshape(len(years), -1)

# Preparar los datos para el modelo
X_time = np.column_stack((np.repeat(years,
theta_values_time.shape[0]),
theta_values_time.repeat(years.shape[0])))
y_time = K_theta_time.flatten()

# Dividir los datos en entrenamiento y prueba
X_train_time, X_test_time, y_train_time, y_test_time =
train_test_split(X_time, y_time, test_size=0.2, random_state=42)
```

```

# Normalización de los datos
scaler_time = StandardScaler()
X_train_scaled_time = scaler_time.fit_transform(X_train_time)
X_test_scaled_time = scaler_time.transform(X_test_time)

# Entrenamiento del modelo K-NN con la dimensión de tiempo como
una característica
knn_time = KNeighborsRegressor(n_neighbors=5)
knn_time.fit(X_train_scaled_time, y_train_time)

# Evaluación del modelo con los datos de prueba
score_time = knn_time.score(X_test_scaled_time, y_test_time)
print(f"Precisión del modelo K-NN con tiempo: {score_time}")

# Predicción para un rango de años futuros
future_years = np.arange(2020, 2030)
new_theta_future = np.linspace(0, 1, 100) # Rango completo de
theta para cada año futuro
X_future = np.column_stack((np.repeat(future_years, 100),
np.tile(new_theta_future, future_years.size)))
X_future_scaled = scaler_time.transform(X_future)
predicted_K_future = knn_time.predict(X_future_scaled)

# Reestructurar los datos de salida para visualización
predicted_K_future_reshaped =
predicted_K_future.reshape(future_years.size, 100)


# Visualizar las predicciones para cada año futuro
plt.figure(figsize=(14, 7))
for idx, year in enumerate(future_years):
    plt.plot(new_theta_future, predicted_K_future_reshaped[idx,
:], label=f'Predicción para el año {year}')
plt.title('Proyecciones futuras de K( $\theta$ ) a lo largo del tiempo')
plt.xlabel('θ (Contenido de humedad del suelo)')
plt.ylabel('K(θ) (Conductividad hidráulica)')
plt.legend()
plt.show()

```

ANEXO 8: Panel Fotográfico en la Zona de Estudio













ACTA DE SUSTENTACIÓN DE TESIS N° 048-2024-FIMGC:

PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERA CIVIL

En la Universidad Nacional de San Cristóbal de Huamanga de la ciudad de Ayacucho, en cumplimiento a la **Resolución Decanal N° 512-2024-FIMGC-D**, a los dos días del mes de agosto de 2024, siendo las 10:00 a.m, reunidos en el Auditorio de la Escuela Profesional de Ingeniería Civil, bajo la presidencia del MSc. Ing. José Ernesto ESTRADA CÁRDENAS y los miembros; MSc. Ing. Edmundo CANCHARI GUTIERREZ y MSc. Ing. Jaime Leonardo BENDEZÚ PRADO, actuando como secretario docente el MSc. Ing. Kelvis BERROCAL ARGUMEDO, para proceder a la sustentación de tesis para optar el Título Profesional de Ingeniera Civil, del bachiller en Ciencias de la Ingeniería Civil:

LINYAN SHANNY SANTA ROSA MAÑUICO

Quien presentó la tesis denominada:

“DESARROLLO DE UN MODELO PREDICTIVO DE CONDUCTIVIDAD HIDRÁULICA PARA OPTIMIZAR EL SISTEMA DE RIEGO LAGUNA HUANZO, DISTRITO DE SANTIAGO - PROVINCIA DE HUANCA SANCOS - AYACUCHO”

Los señores miembros del jurado luego de expuesto la tesis y absueltas las preguntas, delibera y lo declaran:

APROBADO CON NOTA DIECISEIS (16)

Siendo las 12:20 p.m. del día 02 de agosto de 2024, culmina el acto de sustentación de tesis, y en conformidad a lo actuado los miembros del jurado firmamos al pie del presente.

MSc. Ing. José Ernesto ESTRADA CÁRDENAS
Presidente

MSc. Ing. Edmundo CANCHARI GUTIERREZ
Miembro

MSc. Ing. Jaime Leonardo BENDEZÚ PRADO
Miembro

MSc. Ing. Kelvis BERROCAL ARGUMEDO
Secretario docente de la FIMGC

cc:
Archivo



UNSCH

FACULTAD DE
INGENIERÍA
DE MINAS, GEOLOGÍA Y CIVIL



"Año del Bicentenario, de la consolidación de nuestra Independencia, y de la conmemoración de las heroicas batallas de Junín y Ayacucho"

CONSTANCIA DE ORIGINALIDAD DE TRABAJO DE INVESTIGACIÓN

CONSTANCIA N° 108-2024-FIMGC/ASIH

El que suscribe; responsable verificador de originalidad de trabajos de tesis de pregrado con el software Turnitin, de la Escuelas Profesional de **Ingeniería Civil** de la **Facultad de Ingeniería de Minas, Geología y Civil**; en cumplimiento a la **Resolución de Consejo Universitario N° 039-2021-UNSCH-CU**, Reglamento de Originalidad de Trabajos de Investigación de la Universidad Nacional San Cristóbal de Huamanga y **Resolución Decanal N° 476-2023-FIMGC-UNSCH-D**, deja constancia de originalidad de trabajo de investigación, que el/la Sr./Srta.

Apellidos y Nombres : LINYAN SHANNY SANTA ROSA MAÑUICO
Escuela Profesional : INGENIERÍA CIVIL
DE Título de la Tesis : "DESARROLLO DE UN MODELO PREDICTIVO CONDUCTIVIDAD HIDRÁULICA PARA OPTIMIZAR EL SISTEMA DE RIEGO LAGUNA HUANZO, DISTRITO DE SANTIAGO - PROVINCIA DE HUANCA SANCOS - AYACUCHO"
Evaluación de la Originalidad : 14 % Índice de Similitud
Identificador de la entrega : 2451086958

Por tanto, según los Artículos 12, 13 y 17 del Reglamento de Originalidad de Trabajos de Investigación, es **PROCEDENTE** otorgar la **Constancia de Originalidad** para los fines que crea conveniente.

En señal de conformidad y verificación se firma la presente constancia

Ayacucho, 11 de Setiembre 2024



UNIVERSIDAD NACIONAL DE
SAN CRISTÓBAL DE HUAMANGA
Facultad de Ingeniería de Minas, Geología y Civil

Msc. Ing. Alex Sander IRCAÑAUPA HUAMANI
Verificador de Originalidad de Trabajos de Tesis de Pregrado
Escuela de Formación Profesional de Ingeniería Civil

“DESARROLLO DE UN MODELO PREDICTIVO DE CONDUCTIVIDAD HIDRÁULICA PARA OPTIMIZAR EL SISTEMA DE RIEGO LAGUNA HUANZO, DISTRITO DE SANTIAGO - PROVINCIA DE HUANCA SANCOS - AYACUCHO”

por Linyan Shanny Santa Rosa Mañuico

Fecha de entrega: 11-sep-2024 10:23a.m. (UTC-0500)

Identificador de la entrega: 2451086958

Nombre del archivo: SANTA_ROSA_MA_UICO_LINYAN_SHANNY.pdf (4.54M)

Total de palabras: 27933

Total de caracteres: 148669

“DESARROLLO DE UN MODELO PREDICTIVO DE CONDUCTIVIDAD HIDRÁULICA PARA OPTIMIZAR EL SISTEMA DE RIEGO LAGUNA HUANZO, DISTRITO DE SANTIAGO - PROVINCIA DE HUANCA SANCOS - AYACUCHO”

INFORME DE ORIGINALIDAD

14%

INDICE DE SIMILITUD

13%

FUENTES DE INTERNET

3%

PUBLICACIONES

6%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1 Submitted to Universidad Nacional de San Cristóbal de Huamanga 3%
Trabajo del estudiante

2 repositoriotec.tec.ac.cr 2%
Fuente de Internet

3 repositorio.unap.edu.pe 1%
Fuente de Internet

4 hdl.handle.net 1%
Fuente de Internet

5 repositorio.unasam.edu.pe 1%
Fuente de Internet

6 qdoc.tips 1%
Fuente de Internet

7 repositorio.ucss.edu.pe 1%
Fuente de Internet

Submitted to Universidad de Cartagena

8

Trabajo del estudiante

<1 %

9

EUSEBIO CARMONA CHIARA. "Estudio del compost de corcho como sustrato hortícola y silvícola.", Universitat Politecnica de Valencia, 1999

Publicación

<1 %

10

www.dspace.espol.edu.ec

Fuente de Internet

<1 %

11

repository.eafit.edu.co

Fuente de Internet

<1 %

12

aneas.com.mx

Fuente de Internet

<1 %

13

juandomingofarnos.wordpress.com

Fuente de Internet

<1 %

14

repositorio.ana.gob.pe

Fuente de Internet

<1 %

15

zonasegura.seace.gob.pe

Fuente de Internet

<1 %

16

Submitted to Consorcio CIXUG

Trabajo del estudiante

<1 %

17

Submitted to Instituto Superior de Artes,
Ciencias y Comunicación IACC

Trabajo del estudiante

<1 %

repositorio.unsch.edu.pe

18	Fuente de Internet	<1 %
19	repositorio.unfv.edu.pe Fuente de Internet	<1 %
20	riunet.upv.es Fuente de Internet	<1 %
21	aphorticultura.pt Fuente de Internet	<1 %
22	repositorio.uchile.cl Fuente de Internet	<1 %
23	bibliotecadigital.ciren.cl Fuente de Internet	<1 %
24	www.scribd.com Fuente de Internet	<1 %
25	repositorio.ug.edu.ec Fuente de Internet	<1 %

Excluir citas

Activo

Excluir coincidencias < 30 words

Excluir bibliografía

Activo