

**UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL
DE HUAMANGA**

**FACULTAD DE INGENIERÍA DE MINAS, GEOLOGÍA Y
CIVIL**

ESCUELA PROFESIONAL DE INGENIERÍA CIVIL



TESIS:

**Desarrollo de un modelo predictivo de la disponibilidad hídrica
usando redes neuronales artificiales (ANN) en la cuenca del río
Chalcas, distrito San Pedro de Palco, Ayacucho**

Para optar el título profesional de:
INGENIERO CIVIL

PRESENTADO POR:
Bach. Jhac Harold TABOADA VALENZUELA

ASESOR:
Mg. Ing. Edward LEÓN PALACIOS

AYACUCHO - PERÚ

2025

A mis padres, Emilio y Enilda, por su amor incondicional, su apoyo incansable y su confianza inquebrantable en mí. Ustedes han sido mi mayor inspiración y mi principal motivación para seguir adelante. Este logro es tanto mío como suyo, fruto de su sacrificio, paciencia y enseñanzas.

AGRADECIMIENTOS

Agradecer a mi alma máter, la Universidad Nacional de San Cristóbal de Huamanga, por el conocimiento adquirido en sus aulas durante mi estadía universitaria.

Al Ing. Edward León Palacios, asesor de la presente tesis, por su dedicación y paciencia. Su dirección académica, llena de sabiduría, guía y estímulo, ha sido fundamental para dar forma y coherencia a esta investigación. Su compromiso con la excelencia ha sido una inspiración durante todo este proceso.

A los miembros del jurado, Ing. Jaime Leonardo Bendezú Prado e Ing. Hemerson Lizarbe Alarcón, por su valioso compromiso y sus críticas constructivas. Sus observaciones y sugerencias han sido determinantes para mejorar y perfeccionar este trabajo.

A mis profesores, quienes compartieron su conocimiento y guiaron mi aprendizaje.

Y a todos aquellos que, de alguna manera, contribuyeron a este logro, mi más sincero agradecimiento.

RESUMEN

El presente estudio tiene como objetivo desarrollar un modelo predictivo de la disponibilidad hídrica usando redes neuronales artificiales (ANN) en la cuenca del río Chalcas, distrito San Pedro de Palco, Ayacucho. El procedimiento metodológico adoptado fue de enfoque cuantitativo, alcance predictivo y diseño no experimental-longitudinal de tipo panel. La cuenca, de 164.41 km², enfrenta una marcada variabilidad hídrica estacional que limita la productividad agrícola al 65% de su capacidad. El modelo se implementó mediante un perceptrón multicapa con arquitectura 128-64-32-1, funciones de activación ReLU y 2000 épocas de entrenamiento. Para validar su desempeño, se realizaron 50 simulaciones consecutivas con inicializaciones aleatorias, manteniendo un promedio de precisión del 99.1 %, con valores individuales entre 97.6 % y 99.5 %. El análisis estadístico evidenció un coeficiente de determinación $R^2 = 1$, confirmando que la variabilidad observada fue explicada en su totalidad por el modelo, y un MSE de 1.96E-06, lo que refleja un margen de error mínimo. Las simulaciones para el periodo 2003-2030 arrojaron una media general de disponibilidad hídrica de 8.2 millones de m³, con máximos de aproximadamente 25 millones de m³ y mínimos cercanos a 1.3 millones de m³. Se identificó un patrón mensual marcado: los picos de disponibilidad ocurren entre enero y marzo, mientras que los valores más bajos se registran entre junio y julio. Por ejemplo, en 2024 la disponibilidad superó los 18.6 millones de m³ en enero, pero cayó a 1.9 millones en junio. Estos resultados confirman que el modelo ANN supera en precisión a métodos hidrológicos tradicionales, como el balance hídrico, al reproducir con alta exactitud los valores históricos y proyectar escenarios de gestión. Este enfoque puede replicarse en otras cuencas con desafíos similares.

Palabras Clave: Disponibilidad hídrica, Gestión hídrica, Modelo predictivo, Redes neuronales artificiales, Sistema de riego

ABSTRACT

The present study aims to develop a predictive model of water availability using Artificial Neural Networks (ANN) in the Chalcas River basin, San Pedro de Palco district, Ayacucho. The methodological procedure adopted followed a quantitative approach, with predictive scope and a non-experimental longitudinal panel design. The basin, covering 164.41 km², faces pronounced seasonal water variability that restricts agricultural productivity to 65% of its potential capacity. The model was implemented through a multilayer perceptron with a 128-64-32-1 architecture, ReLU activation functions, and 2000 training epochs. To validate its performance, 50 consecutive simulations were carried out with random initializations, maintaining an average accuracy of 99.1%, with individual values ranging from 97.6% to 99.5%. Statistical analysis showed a determination coefficient of $R^2 = 1$, confirming that the observed variability was fully explained by the model, and an MSE of 1.96E-06, reflecting a minimal error margin. Simulations for the 2003–2030 period yielded an overall average water availability of 8.2 million m³, with maximums of approximately 25 million m³ and minimums close to 1.3 million m³. A clear monthly pattern was identified: peaks in availability occur between January and March, while the lowest values are recorded between June and July. For example, in 2024, availability exceeded 18.6 million m³ in January but dropped to 1.9 million in June. These results confirm that the ANN model outperforms traditional hydrological methods, such as the water balance approach, by reproducing historical values with high accuracy and projecting management scenarios. This approach can be replicated in other basins facing similar challenges.

Keywords: Water availability, Water management, Predictive model, Artificial neural networks, Irrigation system.

ÍNDICE DE CONTENIDO

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

2.1.2.	Investigaciones nacionales	20
2.2.	Bases teóricas	21
2.2.1.	Disponibilidad hídrica	21
2.2.2.	Balance hídrico	21
2.2.3.	Oferta hídrica	23
2.2.4.	Demanda hídrica.....	23
2.2.5.	Precipitación	24
2.2.6.	Temperatura	26
2.2.7.	Caudal	26
2.2.8.	Hidrograma	27
2.2.9.	Evapotranspiración	28
2.2.10.	Cuenca Hidrográfica.....	28
2.2.11.	Tratamientos de Datos Hidrometeorológicos	36
2.2.12.	Sistema hidrológico	38
2.2.13.	Redes Neuronales.....	40
2.2.14.	Modelo Lutz Scholz	40
2.2.15.	Fundamentos Biológicos de las Redes Neuronales.....	44
2.2.16.	Redes Neuronales Artificiales.....	48
2.2.17.	Estructura de una Neurona Artificial	50
2.2.18.	Modelo de Red Neuronal Artificial (ANN).....	50
2.2.19.	Arquitectura de Red Neuronal	56
2.2.20.	Algoritmo de RetroPropagación.....	60
2.3.	Marco Conceptual	66
III.	MÉTODO DE LA INVESTIGACIÓN.....	69
3.1.	Enfoque	69
3.2.	Alcance	69
3.3.	Diseño de investigación	69
3.4.	Población y muestra.....	70
3.4.1.	Población	70

3.4.2. Muestra.....	70
3.5. Hipótesis	70
3.5.1. Hipótesis general	70
3.5.2. Hipótesis específicas	70
3.6. Operacionalización de variables.....	71
3.7. Técnicas e instrumentos	73
3.7.1. Técnicas	73
3.7.2. Instrumentos	73
3.8. Técnicas estadísticas para el procesamiento de la información	73
3.9. Análisis de validez, confiabilidad y objetividad	74
3.10. Desarrollo del trabajo de tesis	74
3.10.1. Ubicación y Límite de la Cuenca del Río Chalcas.....	74
3.10.2. Característica de la Cuenca del Río Chalcas.....	75
3.10.3. Metodología del Estudio realizado	76
3.10.4. Parámetros Geomorfológicos de la Cuenca	81
3.10.5. Determinación de la oferta hídrica mediante el modelo Lutz Scholz ...	82
3.10.6. Oferta Hídrica	83
3.10.7. Implementación del modelo de red neuronal artificial (ANN)	94
IV. RESULTADOS Y DISCUSIÓN.....	125
4.1. Impacto del modelo predictivo.....	125
4.2. Contrastación de Hipótesis	133
4.3. Discusión	134
CONCLUSIONES	137
RECOMENDACIONES	139
REFERENCIAS BIBLIOGRÁFICAS	140
ANEXOS	144

ÍNDICE DE TABLAS

Tabla 1	Clasificación de cuencas según la distancia (áreas)	29
Tabla 2	Cuadro de Operacionalización de variables	72
Tabla 3	Localización de la cuenca del río Chalcas.....	76
Tabla 4	Estaciones Meteorológicas	77
Tabla 5	Estaciones meteorológicas	78
Tabla 6	Características geomorfológicas de la cuenca del río Chalcas.....	82
Tabla 7	Precipitación mensual calculada en la cuenca del río Chalcas (mm).....	87
Tabla 8	Registro de Descarga Media Mensual de la Cuenca en Estudio	89
Tabla 9	Fase de Crecimiento Activo del Cultivo Principal.....	91
Tabla 10	Disponibilidad hídrica calculada en la cuenca del río Chalcas (l/s).....	92
Tabla 11	Arquitectura de la red neuronal artificial utilizada para estimar la disponibilidad hídrica	99
Tabla 12	Parámetros de compilación y entrenamiento del modelo ANN	106
Tabla 13	Resultados de las 50 simulaciones del modelo ANN.....	112
Tabla 14	Validación de la disponibilidad aplicando el modelo ANN.....	113
Tabla 15	Predicción anual-mensual de la disponibilidad hídrica en la cuenca del río Chalcas (2003–2030) (m ³).....	127

ÍNDICE DE FIGURAS

Figura 1 Tipos de Precipitaciones.....	25
Figura 2 Tipos de hidrogramas.....	27
Figura 3 Factor forma de la cuenca hidrográfica.....	31
Figura 4 Número de orden de un cauce por distribución	34
Figura 5 Sistema Hidrológico.....	39
Figura 6 Estructura del Modelo Lutz Scholz.....	42
Figura 7 Estructura de una neurona biológica	48
Figura 8 Modelo del Perceptron.....	51
Figura 9 Modelo del Perceptron de dos Capas.....	52
Figura 10 Modelo del Perceptron de tres Capas.....	53
Figura 11 Estructura de la Red Neuronal.....	100
Figura 12 Esquema de Red Neuronal Multicapa	101
Figura 13 Conexión de Capa de Entrada (128) hacia la capa Oculta 1 (64)	102
Figura 14 Conexión entre Capa Oculta 1 (64) y Capa Oculta 2 (32)	103
Figura 15 Conexión entre Capa Oculta 2 (32) y Capa de Salida (1)	104
Figura 16 Evolución del error de entrenamiento y validación.....	106
Figura 17 Comparación entre disponibilidad hídrica real y predicha por meses.....	109
Figura 18 Simulación de 50 ejecuciones	111
Figura 19 Proceso de entrenamiento del modelo ANN y generación de simulaciones 2003-2030.....	126
Figura 20 Disponibilidad hídrica predicha - 5 simulaciones.....	130
Figura 21 Promedio anual de disponibilidad hídrica predicha (m ³).....	130
Figura 22 Media general de disponibilidad hídrica por simulación	131
Figura 23 Promedio mensual de disponibilidad hídrica (2003–2030) (m ³)	132
Figura 24 Distribución de la disponibilidad hídrica por simulación	132

GLOSARIO

Caudal	:	Cantidad de agua que fluye a través de un punto específico en un río o canal en un tiempo determinado, generalmente medido en metros cúbicos por segundo (m^3/s).
Cuenca hidrográfica	:	Área de tierra donde toda el agua que cae, ya sea por precipitación o deshielo, converge hacia un río, lago o cuerpo de agua común.
Disponibilidad hídrica	:	Cantidad de agua disponible en una región o cuenca para ser utilizada en actividades humanas y ecosistemas.
Modelo predictivo	:	Herramienta matemática o estadística utilizada para prever resultados futuros basados en datos históricos.
Redes neuronales artificiales (ANN)	:	Algoritmos de aprendizaje automático que emula el funcionamiento de las neuronas humanas para identificar patrones y hacer predicciones.
Sistema de riego	:	Conjunto de infraestructuras y métodos utilizados para suministrar agua a cultivos de manera controlada y eficiente.

ACRÓNIMOS

ANA	: Autoridad Nacional del Agua
ANN	: Redes Neuronales Artificiales
Eto	: Evapotranspiración.
IDEAM	: Instituto de Hidrología, Meteorología y Estudios Ambientales
Kc	: Coeficiente de Cultivo.
MAE	: Error Medio Absoluto
MAPE	: Error Porcentual Absoluto Medio
MLP	: Perceptrón Multicapa
MSE	: Error Cuadrático Medio

INTRODUCCIÓN

La gestión sostenible del recurso hídrico es un desafío creciente, especialmente en regiones como la cuenca del río Chalcas, ubicada en el distrito de San Pedro de Palco, Ayacucho, donde las condiciones climáticas y geográficas generan variaciones significativas en la disponibilidad de agua. En este contexto, la predicción de la disponibilidad hídrica se convierte en una herramienta esencial para garantizar la eficiencia de los sistemas de riego, satisfacer las demandas agrícolas y minimizar los impactos de la escasez hídrica.

Este estudio se enfoca en el desarrollo de un modelo predictivo basado en redes neuronales artificiales (ANN), diseñado para estimar la disponibilidad hídrica en la cuenca. Las ANN fueron seleccionadas debido a su capacidad para identificar patrones complejos en grandes conjuntos de datos y realizar predicciones con alta precisión. Para ello, se recopilaron datos históricos y actuales relacionados con la precipitación, caudales, coeficientes de cultivo ponderado (K_c) y evapotranspiración mensual (E_{to}), entre otras variables relevantes.

El objetivo principal del estudio es proporcionar una herramienta que no solo permita anticipar la disponibilidad hídrica mensual en la cuenca, sino también evaluar su impacto en la gestión del agua y la eficiencia del sistema de riego. Los resultados obtenidos ofrecen información clave para la planificación y optimización de los recursos hídricos, identificando períodos críticos y proponiendo estrategias para mejorar la sostenibilidad hídrica en la región.

La introducción de técnicas predictivas avanzadas, como las ANN, en la gestión hídrica representa un paso importante hacia el fortalecimiento de la seguridad hídrica y la productividad agrícola, contribuyendo al desarrollo sostenible del distrito de San Pedro de Palco. Este enfoque puede ser replicado en otras cuencas con características similares, ampliando su impacto en la gestión integral del agua.

I. PLANTEAMIENTO DEL PROBLEMA

1.1. Descripción del problema

La cuenca del río Chalcas, ubicada en el distrito de San Pedro de Palco, provincia de Lucanas, Ayacucho, enfrenta desafíos significativos relacionados con la disponibilidad y gestión del recurso hídrico. Esta región, cuya economía depende en gran medida de la agricultura, sufre debido a la limitada disponibilidad de agua, afectando la productividad agrícola y, por ende, el desarrollo económico local.

La falta de un sistema eficiente para predecir y gestionar los flujos de agua ha resultado en una gestión subóptima del recurso hídrico. La disponibilidad de agua en la cuenca es variable y depende en gran medida de las condiciones meteorológicas, lo que genera incertidumbre y dificulta la planificación agrícola. En la actualidad, la agricultura en la región se desarrolla a solo un 65 % de su capacidad debido a la limitada disponibilidad de agua, exacerbada por la falta de datos precisos y actualizados sobre los flujos hídricos. Los agricultores se ven obligados a depender de las lluvias estacionales, restringiendo así la productividad durante las épocas de sequía y afectando negativamente sus ingresos económicos.

Ante esta situación, el objeto de estudio de la presente investigación es la disponibilidad hídrica en la cuenca del río Chalcas, considerada como variable dependiente, cuya estimación permitirá tomar decisiones oportunas en la gestión del recurso. Para ello, se plantea como solución el desarrollo de un modelo predictivo basado en redes neuronales artificiales (ANN), considerado como variable independiente, el cual permitirá anticipar con mayor precisión los patrones de comportamiento del agua en la zona de estudio.

El modelo ANN utilizará como variables de entrada los registros históricos y actuales de precipitación, temperatura, evapotranspiración, caudales medios y coeficientes de cultivo ponderado (K_c). Estos datos serán procesados empleando técnicas de aprendizaje automático y estadística aplicada, a través de herramientas como Python y MATLAB, que permitirán la creación, entrenamiento y validación del modelo predictivo. La disponibilidad hídrica será estimada mediante indicadores como el caudal medio mensual (m^3/s) y la disponibilidad volumétrica anual (m^3), utilizando escalas de medición físicas estandarizadas.

El desarrollo del modelo predictivo mediante ANN representará un avance en la gestión hídrica local, permitiendo una mejor planificación del riego agrícola, la identificación de períodos críticos y la optimización del uso del recurso disponible. Asimismo, facilitará una distribución más equitativa del agua y contribuirá a reducir los impactos negativos asociados a la escasez. De esta manera, se espera mejorar la productividad agrícola y la calidad de vida de los agricultores de la región. Finalmente, esta herramienta tecnológica podrá ser replicada en otras cuencas que enfrenten condiciones similares de variabilidad hídrica.

De esta manera, la presente investigación tiene como objeto de estudio la disponibilidad hídrica como variable dependiente, la cual será estimada mediante un modelo predictivo basado en redes neuronales artificiales (ANN), considerado como variable independiente, en coherencia con los objetivos, hipótesis y metodología del estudio.

1.2. Delimitación del problema

1.2.1. Espacial (geográfica)

La cuenca del río Chalcas se encuentra ubicada en el distrito de San Pedro de Palco, en la provincia de Lucanas, dentro del departamento de Ayacucho, Perú. Esta cuenca tiene una extensión de aproximadamente 164.41 km² y abarca diversas altitudes, desde los 2,641.1 msnm hasta los 4,400 msnm.

1.2.2. Temática y unidad de análisis

La temática central de esta investigación se enfoca en la disponibilidad hídrica y su gestión en la cuenca del río Chalcas. Se busca analizar cómo los patrones de precipitación y flujo de agua afectan la disponibilidad de agua para la agricultura a lo largo del año. La unidad de análisis incluye datos meteorológicos históricos, caudales de los ríos y precipitaciones, que serán utilizados para desarrollar un modelo predictivo mediante redes neuronales artificiales (ANN).

1.3. Formulación del problema

1.3.1. Problema general

¿Cómo desarrollar un modelo predictivo usando redes neuronales artificiales (ANN) para estimar la disponibilidad hídrica en la cuenca del río Chalcas, distrito San Pedro de Palco, Ayacucho?

1.3.2. Problemas específicos

- ¿Cómo recopilar y analizar de manera efectiva los datos históricos y actuales de precipitación, caudales y otras variables meteorológicas relevantes en la cuenca del río Chalcas?
- ¿Cómo desarrollar un modelo de redes neuronales artificiales (ANN) para predecir la disponibilidad hídrica y cómo validar su precisión mediante técnicas estadísticas?
- ¿Cómo evaluar el impacto del modelo predictivo en la gestión del recurso hídrico y en la eficiencia del sistema de riego en el distrito de San Pedro de Palco?

1.4. Justificación e importancia

1.4.1. Justificación

La gestión eficiente del recurso hídrico en la cuenca del río Chalcas es crucial para asegurar la sostenibilidad y el desarrollo económico de la región. La variabilidad en la disponibilidad de agua, junto con la dependencia de la agricultura local en las temporadas de lluvia, subraya la necesidad de un sistema predictivo que permita anticipar los flujos hídricos. La implementación de un modelo de predicción utilizando redes neuronales artificiales (ANN) ofrece una solución innovadora para mejorar la planificación y gestión del agua.

Este modelo permitirá a los agricultores y a los gestores de recursos hídricos anticipar con mayor precisión las variaciones en la disponibilidad de agua, optimizando así la planificación del riego y minimizando las interrupciones en el suministro. La justificación de esta investigación radica en la necesidad de abordar las deficiencias actuales en la gestión hídrica, que limitan la productividad agrícola y afectan negativamente los ingresos económicos de las familias de la región. Al proporcionar una herramienta predictiva confiable, se podrán tomar decisiones informadas que

contribuirán a una utilización más eficiente del recurso hídrico, beneficiando tanto a los agricultores como a la economía local.

1.4.2. Importancia

La importancia de desarrollar un modelo predictivo de la disponibilidad hídrica en la cuenca del río Chalcas radica en su potencial para transformar la gestión y uso del recurso hídrico en la región. Un modelo predictivo permitirá una gestión más eficiente del agua, ayudando a anticipar periodos de escasez y optimizando el uso del agua disponible. Esto es vital para mantener la productividad agrícola durante todo el año, incluso en las temporadas secas. Al poder planificar mejor el riego y asegurar un suministro constante de agua, los agricultores podrán incrementar su producción. Esto no solo mejora la seguridad alimentaria local, sino que también puede aumentar los ingresos económicos de las familias agrícolas, reduciendo la pobreza y mejorando la calidad de vida en la región. Una gestión hídrica eficiente contribuye al desarrollo económico sostenible de la región. La estabilidad en la producción agrícola permitirá a los agricultores invertir en mejoras y diversificar sus cultivos, fortaleciendo la economía local y creando oportunidades de empleo. Además, en un contexto de cambio climático, la capacidad de predecir y gestionar los recursos hídricos es esencial para mitigar sus efectos adversos. Un modelo predictivo basado en redes neuronales artificiales puede proporcionar información valiosa para adaptar las prácticas agrícolas a las nuevas condiciones climáticas, garantizando así la resiliencia de la comunidad.

1.5. Limitaciones de la investigación

- La precisión y efectividad del modelo ANN dependen en gran medida de la calidad y cantidad de datos históricos y actuales disponibles. La zona de estudio carece de estaciones pluviométricas e hidrométricas propias, lo que puede limitar la cantidad de datos precisos y actualizados sobre las condiciones meteorológicas y los caudales de agua.
- Las condiciones climáticas y geográficas de la zona de estudio son variables y pueden presentar desafíos adicionales en la recolección de datos y en la validación del modelo. Fenómenos climáticos extremos, como sequías o lluvias intensas, pueden afectar la precisión de las predicciones.
- La topografía accidentada de la zona de estudio puede dificultar el acceso a ciertos puntos de monitoreo, limitando la cobertura y representatividad de los datos recolectados.

1.6. Objetivos

1.6.1. Objetivo general

Desarrollar un modelo predictivo usando redes neuronales artificiales (ANN) para estimar la disponibilidad hídrica en la cuenca del río Chalcas, distrito San Pedro de Palco, Ayacucho.

1.6.2. Objetivos específicos

- Recopilar y analizar datos históricos y actuales de precipitación, caudales y otras variables meteorológicas relevantes en la cuenca del río Chalcas.
- Desarrollar un modelo de redes neuronales artificiales (ANN) para predecir la disponibilidad hídrica, validando su precisión mediante técnicas estadísticas.
- Evaluar el impacto del modelo predictivo en la gestión del recurso hídrico y la eficiencia del sistema de riego en el distrito de San Pedro de Palco

II. MARCO TEÓRICO

2.1. Antecedentes

2.1.1. Investigaciones internacionales

Montealegre y Javela (2021) en su tesis *“Predicción de caudales máximos diarios del Río Magdalena a la altura del municipio de Calamar (Bolívar), usando el método de redes neuronales artificiales (Rna)”*, tuvieron como objetivo implementar modelos de redes neuronales artificiales (RNA) para predecir caudales máximos diarios en el río Magdalena. La metodología incluyó la utilización de cinco modelos RNA desarrollados en Matlab®2020a, utilizando como atributos de entrada el día del año, el día pluviométrico y el nivel máximo diario. Los resultados se evaluaron mediante el índice de error cuadrático medio (MSE) y el coeficiente de correlación (R). El modelo RNA_4_1 demostró ser el más preciso, con un MSE de 3,882E-07 y un R de 1, indicando una excelente precisión y ajuste a los datos reales. El estudio abarcó una sección del río Magdalena entre las estaciones SAN PEDRITO ALERTA y CALAMAR, utilizando datos de enero de 2017 a diciembre de 2020 del IDEAM.

Villenas (2020) en su tesis *“Predicción de caudales en la cuenca del río Chalpi Norte mediante la aplicación de redes neuronales”*, tuvo como objetivo estimar los caudales diarios de la microcuenca de Chalpi Norte mediante la selección del modelo óptimo usando redes neuronales artificiales. Para ello, se utilizaron series de datos de precipitación y caudal de 4 estaciones pluviométricas y 1 estación hidrométrica proporcionadas por EPMAPS. Los modelos fueron desarrollados mediante aprendizaje supervisado en etapas de entrenamiento y validación. Se construyeron 24 modelos combinando diferentes parámetros, como algoritmos, funciones de salida y activación, y arquitectura de las redes neuronales. Los datos de entrada fueron normalizados y evaluados mediante el cálculo del coeficiente de error. Los resultados indicaron que uno de los modelos desarrollados es óptimo, logrando aproximar con precisión los caudales medidos en la microcuenca.

Castillo (2023) en su tesis *“Evaluación de modelos de pronóstico para estimar el ingreso de caudales al embalse Mazar: aplicación con redes neuronales”*, tuvo como objetivo desarrollar un modelo de red neuronal artificial (RNA) para pronosticar los niveles del río Paute, cuya cuenca es estratégicamente importante por sus hidroeléctricas. Se empleó una metodología que transformó los niveles del río a

caudales mediante la curva de descarga. La base de datos se dividió en 80% para entrenamiento y 20% para validación. La arquitectura de la RNA incluyó 7 entradas de niveles de agua de estaciones hidrológicas, 1 capa oculta con 50 neuronas y 1 capa de salida. Los errores entre los caudales observados y pronosticados se mantuvieron siempre por debajo del 10%, con un mínimo del 7.57%, reflejando la estabilidad y precisión del modelo desarrollado.

2.1.2. Investigaciones nacionales

Ramirez (2024) en su tesis de doctorado *“modelo predictivo basado en redes neuronales artificiales para pronosticar el consumo de agua potable en la ciudad de Iquitos”*, tuvo como objetivo desarrollar un modelo de predicción basado en redes neuronales artificiales para pronosticar con precisión el consumo de agua potable. La metodología fue de tipo aplicada, desarrollando una herramienta útil para empresas de saneamiento, mejorando la gestión del suministro de agua potable. Las variables de entrada identificadas fueron la temperatura máxima y mínima, la precipitación y la población de Iquitos. La variable de salida fue el consumo de agua potable. Utilizando un perceptrón multicapa con 4 neuronas en la capa de entrada, 2 capas ocultas con 10 neuronas cada una y 1 neurona en la capa de salida, y empleando el algoritmo de aprendizaje backpropagation, se logró un margen de error inferior al 5%. El modelo demostró una buena capacidad de rendimiento y efectividad, validado con métricas de evaluación como el coeficiente de regresión (r), el coeficiente de determinación (R^2) y el Error Porcentual Absoluto Medio (MAPE).

Vera y Vargas (2023) en su tesis *“Evaluación hidrológica con uso de redes neuronales artificiales para el cálculo de hidrogramas en la cuenca alta del Huallaga”*, tuvo como objetivo desarrollar un modelo de redes neuronales para predecir inundaciones en la cuenca alta del Huallaga. La metodología utilizada fue el modelado mediante un perceptrón multicapa (MLP), entrenado con un dataset que relacionaba hietogramas de entrada con hidrogramas de salida, generando un total de 250 simulaciones. Se entrenó el modelo durante 2000 iteraciones utilizando el optimizador Adam y la métrica de error MSE. Como resultado, el modelo logró un error de predicción del 8.17%, permitiendo una rápida estimación de inundaciones, mejorando así la capacidad de reacción ante emergencias en la población afectada. Esto proporciona una solución eficiente y rápida en comparación con los métodos hidrológicos convencionales.

Zárate (2020) en su tesis *“Modelamiento hidrológico de caudales medios mensuales en cuencas sin información hidrométrica aplicando el método Lutz Scholz y las redes neuronales artificiales, en la microcuenca Huajuiri - Oropesa - Antabamba – Apurímac”*, tuvo como objetivo calcular los caudales medios mensuales en la microcuenca Huajuiri, donde falta información hidrométrica. Se utilizó una metodología combinando el método Lutz Scholz y redes neuronales artificiales. Se emplearon datos hidrométricos de la cuenca La Angostura para modelar y validar los resultados. Los valores obtenidos fueron cercanos a los caudales medidos. En la cuenca Huajuiri, sin datos hidrométricos, el uso de redes neuronales mejoró significativamente la precisión de los caudales estimados en comparación con el método Lutz Scholz. Esto permite una mejor gestión del recurso hídrico, útil para las comunidades locales y el diseño de futuras obras hidráulicas.

2.2. Bases teóricas

2.2.1. Disponibilidad hídrica

La disponibilidad hídrica superficial se refiere al volumen total de agua precipitada sobre un área específica que, en un futuro cercano, estará disponible en volumen o caudal en un punto determinado de la cuenca hidrográfica para su uso. Este concepto es crucial para la gestión de los recursos hídricos, ya que permite planificar el uso eficiente y sostenible del agua en actividades como la agricultura, la industria y el consumo humano. Evaluar la disponibilidad hídrica superficial implica analizar las precipitaciones, la topografía y las características de la cuenca hidrográfica, así como considerar factores como la evaporación y la infiltración. La correcta estimación de esta disponibilidad es fundamental para garantizar que las necesidades de agua de las diferentes actividades y comunidades sean satisfechas sin comprometer el equilibrio ecológico ni la sostenibilidad a largo plazo de los recursos hídricos. Por lo tanto, la disponibilidad hídrica superficial es un indicador clave para la planificación y gestión del agua en cualquier región (Ordoñez, 2011, pp. 5-7).

2.2.2. Balance hídrico

El balance hídrico es uno de los principios fundamentales en hidrología. Aunque su formulación es bastante sencilla, la cuantificación de sus componentes suele ser compleja debido a la falta de mediciones directas en el campo. Este principio se basa

en la aplicación del principio de conservación de masas, también conocido como ecuación de la continuidad, que establece que, para cualquier volumen arbitrario y durante cualquier período de tiempo, la diferencia entre las entradas y salidas de agua está determinada por la variación del volumen de agua almacenada (Ordoñez, 2011, pp. 5-7).

2.2.2.1. Aplicaciones del balance hídrico

El balance hídrico es una herramienta esencial en diversos estudios hidrológicos, ya que permite determinar la disponibilidad de agua en una región específica. Este cálculo es crucial para la gestión y planificación de recursos hídricos, asegurando un uso eficiente y sostenible del agua en actividades como la agricultura, la industria y el abastecimiento de agua potable (Ordoñez, 2011, p. 7).

2.2.2.2. Estimación del balance hídrico

La estimación del balance hídrico implica medir tanto las entradas como las salidas de agua, así como los cambios en el almacenamiento de agua en un área determinada. La ecuación fundamental del balance hídrico es:

$$A = E - S$$

Donde:

- A representa el almacenamiento,
- E las entradas,
- S las salidas.

En la práctica, la técnica del balance hídrico requiere la medición precisa de los flujos de agua y el almacenamiento. Sin embargo, algunas mediciones pueden ser omitidas dependiendo del volumen y el período de tiempo considerados para el cálculo del balance (UNESCO, 1971). Esta metodología es fundamental para comprender y gestionar los recursos hídricos, especialmente en áreas con escasez de agua o con una alta demanda de este recurso.

2.2.3. Oferta hídrica

La cantidad de agua que, tras precipitarse sobre una cuenca y satisfacer las demandas de evapotranspiración e infiltración del sistema suelo-cobertura vegetal, fluye por los cauces principales de los ríos y otras corrientes superficiales, alimenta lagos, lagunas y reservorios, se une a otras corrientes y finalmente llega al mar, se conoce como escorrentía superficial. Los hidrólogos utilizan este término para referirse a esta porción de agua, y su cuantificación es el principal elemento de medición en las redes de seguimiento hidrológico de distintos países (IDEAM, 2004, p. 10).

La oferta hídrica de una cuenca se refiere al volumen de agua disponible para satisfacer la demanda generada por las actividades sociales y económicas humanas. Al cuantificar la escorrentía superficial, se está estimando la oferta de agua superficial de la cuenca. Variables como el caudal del río, la confiabilidad y la extensión de la serie de registros históricos pueden influir en la estimación de la oferta hídrica superficial. Cuando se dispone de información histórica confiable y series de datos extensas sobre los caudales, el caudal medio anual del río se considera como la oferta hídrica de esa cuenca (Corponariño, 2009, p. 22).

2.2.4. Demanda hídrica

La demanda de agua es un término fundamental en la planificación hidrológica. Se refiere a los caudales y volúmenes de agua necesarios para diversas actividades económicas. Esta demanda generalmente se divide en dos categorías: demanda hídrica poblacional y demanda hídrica productiva (Balairon, 2002, p. 23).

A. Demanda hídrica poblacional

La demanda hídrica poblacional es la cantidad de agua utilizada por una población específica para satisfacer sus necesidades básicas. Esta incluye el agua consumida para beber, cocinar, higiene personal y otras actividades domésticas. La cantidad de agua requerida varía según factores como el tamaño de la población, el nivel de desarrollo económico, las condiciones climáticas y las prácticas culturales. Asegurar una provisión adecuada de agua para la población es esencial para mantener la salud pública y el bienestar (Balairon, 2002, p. 24).

B. Demanda hídrica productiva

La demanda hídrica productiva se refiere a la cantidad de agua que necesitan las personas naturales o jurídicas para actividades productivas. Estas actividades pueden incluir la agricultura, la industria, la generación de energía y otros usos económicos. La cantidad de agua requerida para fines productivos depende del tipo de actividad, la eficiencia en el uso del agua y la disponibilidad de recursos hídricos en la región. La gestión eficiente de la demanda hídrica productiva es crucial para el desarrollo económico sostenible y la protección de los recursos hídricos (Balairon, 2002, pp. 24-25).


2.2.5. Precipitación

La precipitación es el fenómeno mediante el cual el agua proveniente de la atmósfera, ya sea en forma líquida o sólida, se deposita sobre la superficie terrestre. Su formación requiere que una masa de aire ascienda, se enfríe y condense parte de su contenido de vapor, dando lugar a la caída de agua en sus diversas formas. La intensidad y frecuencia de las precipitaciones presentan una notable variabilidad espacial y temporal; en determinadas zonas puede registrarse en un solo día una cantidad de lluvia superior a la que otras regiones reciben durante todo el año (Vásquez, 2000, pp. 45–47).

Las principales causas que influyen en la distribución de las precipitaciones incluyen la proximidad al mar, el incremento de la humedad del aire y las corrientes ascendentes de aire. Las cordilleras, por ejemplo, obligan al aire a ascender, causando precipitaciones más intensas y frecuentes en las laderas enfrentadas a los vientos predominantes, conocidas como barlovento. La variabilidad en la intensidad y distribución de las precipitaciones tiene un impacto directo en la disponibilidad de recursos hídricos. Regiones con alta variabilidad en las precipitaciones deben implementar estrategias de gestión del agua que consideren estos cambios para garantizar una provisión adecuada de agua durante todo el año. La planificación hidrológica efectiva debe tener en cuenta tanto la demanda de agua como la precipitación para desarrollar políticas y prácticas que aseguren la sostenibilidad de los recursos hídricos (Corponariño, 2009, pp. 21–22).

Figura 1

Tipos de Precipitaciones



Nota. Tomado de (Díaz, 2017).

Existen diversos tipos de precipitación, incluyendo la precipitación convectiva, orográfica y frontal, como se puede observar en la Figura 1. La precipitación puede clasificarse en tres tipos principales: orográfica, convectiva y frontal. La precipitación orográfica se produce cuando el aire es forzado a ascender por barreras geográficas, lo que resulta en condensación y lluvia constante en las mismas áreas. La precipitación convectiva ocurre cuando el aire caliente y húmedo asciende debido a su menor densidad, enfriándose y condensándose en el proceso. Este tipo de precipitación es común en zonas tropicales y costeras. Por último, la precipitación frontal o ciclónica se origina en ciclones, donde las diferencias de temperatura y presión atmosférica generan la ascensión y enfriamiento del aire, provocando la condensación y precipitación. Cada tipo de precipitación tiene características y procesos distintos, influenciados por factores geográficos y climáticos específicos. Comprender estos procesos es crucial para la planificación hidrológica y la gestión de recursos hídricos, ya que permite predecir y manejar la distribución de agua en diferentes regiones.

2.2.5.1. Precipitación Orográfica

Las montañas y cordilleras actúan como barreras que obligan a los vientos a ascender. Este ascenso forzado provoca un enfriamiento adiabático del aire, lo que lleva a la condensación y posterior precipitación. Debido a que estos obstáculos geográficos son permanentes, la precipitación ocurre consistentemente en las mismas áreas. Este tipo de precipitación es predominante en la sierra peruana (Vásquez, 2000, p. 46).

2.2.5.2. Precipitación Convectiva

La precipitación convectiva ocurre cuando una masa de aire caliente asciende debido a su menor densidad en comparación con el aire circundante. Este calentamiento suele ser resultado del calentamiento del suelo, el agua y el aire en contacto con ellos. Al ascender, el aire caliente y húmedo se enfría adiabáticamente, provocando la condensación y la lluvia. Este proceso se repite cuando el aire frío desciende para ocupar el lugar del aire ascendente y se calienta a su vez. Este fenómeno es común en zonas planas y boscosas de los trópicos, como los llanos amazónicos y los mares. En Perú, ocurre principalmente en la parte norte de la faja costera, en regiones como Piura y Tumbes, influenciado por los anticiclones del Atlántico norte y sur (Vásquez, 2000, p. 47).

2.2.5.3. Precipitación Frontal o Ciclónica

Un ciclón es una gran masa de aire que gira a alta velocidad alrededor de un vórtice, formado por fuertes diferencias de temperatura entre las capas atmosféricas. En el vórtice, la presión atmosférica es muy baja, lo que permite que las masas de aire caliente y húmedo asciendan rápidamente. Al expandirse en altitudes mayores, este aire sufre un enfriamiento adiabático, provocando la condensación del vapor de agua y la precipitación (Vásquez, 2000, p.45).

2.2.6. Temperatura

La temperatura se refiere a la cantidad de energía solar retenida por el aire en un momento dado. Principalmente, la temperatura depende de la radiación solar. La medición de esta energía se realiza con un termómetro, que debe ubicarse a 1,5 metros del suelo en un lugar ventilado y protegido de la influencia directa de los rayos del sol para obtener una lectura precisa. Los resultados se expresan en la escala Celsius o Fahrenheit (Ordoñez, 2001, pp. 5–7).

2.2.7. Caudal

El caudal es el volumen de agua que fluye a través de una sección transversal de un río o canal en un tiempo determinado. Se puede calcular utilizando la ecuación:

$$Q = \frac{V}{t}$$


donde Q representa el caudal, V el volumen y t el tiempo.

2.2.8. Hidrograma

Un hidrograma es una representación gráfica de la variación del caudal a lo largo del tiempo (Ordoñez, 2011, pp. 5–7). La forma del hidrograma depende de las precipitaciones en la cuenca y sus características físicas. Por ejemplo, en cuencas con mayor pendiente, la respuesta del hidrograma es más rápida y directa, como se observa en la Figura 2, donde se comparan hidrogramas de diferentes cuencas.

Figura 2

Tipos de hidrogramas



Nota. Tomado de (Díaz, 2017).

La figura ilustra cómo la forma geomorfológica de una cuenca influye en su respuesta hidrológica frente a un evento de precipitación. En la parte superior se observa una cuenca con forma redondeada, donde la mayoría de los flujos de agua recorren distancias similares hasta llegar al punto de salida. Esto provoca que el escurrimiento superficial se concentre rápidamente, generando un hidrograma con un pico más alto y un tiempo al pico más corto, representado como t_{c1} .

En contraste, la parte inferior muestra una cuenca alargada, donde las distancias hacia la salida varían considerablemente. Como resultado, el flujo de agua tarda más

tiempo en concentrarse, lo que produce un hidrograma más aplanado, con un caudal pico menor y un tiempo al pico mayor, denotado como t_{c2} , siendo $t_{c2} > t_{c1}$.

Esta representación evidencia que la morfología de una cuenca tiene un papel fundamental en la dinámica del escurrimiento, ya que determina la rapidez con la que el caudal aumenta y decrece, afectando directamente la gestión del recurso hídrico y el diseño de infraestructuras hidráulicas.

2.2.9. Evapotranspiración

La evapotranspiración es la combinación de dos procesos: la evaporación desde la superficie del suelo y la transpiración de las plantas. Dado que medir estos procesos por separado es complicado, se utiliza el término evapotranspiración para describir la pérdida conjunta de agua de un sistema determinado (Ordoñez, 2011, p.6).

2.2.10. Cuenca Hidrográfica

Una cuenca hidrográfica es una unidad geográfica delimitada por divisorias de aguas, en la que se desarrolla el ciclo hidrológico y confluyen factores naturales, sociales, económicos, políticos e institucionales que influyen en su dinámica (Vásquez, 2000, p. 46). Se trata de un espacio en el que los aportes hídricos provienen exclusivamente de las precipitaciones, y cuyos excedentes de agua o sedimentos fluyen hacia un único punto de salida. Por esta razón, es considerada la unidad territorial más adecuada para la gestión integrada de los recursos hídricos (Llamas, 1993, p. 63).

2.2.10.1. Características Morfométricas de una Cuenca

Las características de una cuenca y sus corrientes pueden cuantificarse mediante índices de forma, relieve y conexión con la red fluvial. Estos índices son matemáticos y permiten comparar cuencas de diferentes tamaños. Según Maidment (1992), el análisis de las características morfométricas es crucial para evaluar el funcionamiento del sistema hidrológico de una región (p. 23).

A. Divisorias de Aguas o Parteaguas

Las divisorias de aguas son los límites naturales entre cuencas, generalmente ubicados en las cumbres de las montañas. Son fáciles de identificar y actúan como límites naturales para el agua, dirigiendo el flujo hacia arroyos, ríos, lagos y eventualmente el océano. Las divisorias pueden variar en tamaño, desde pequeñas hectáreas hasta áreas que abarcan varios estados (Trujillo, 2010, pp. 17–21).

B. Superficie o Área

El área de una cuenca es una de sus características morfométricas e hidrológicas más importantes. Se define como la proyección ortogonal de toda el área de drenaje que contribuye a un sistema de escurrimiento. El tamaño de estas áreas hidrológicas determina su denominación como microcuenca, subcuenca, cuenca o sector (Trujillo, 2010, p.18).

Tabla 1

Clasificación de cuencas según la distancia (áreas)

ÁREA (Km ²)	NOMBRE
< 5	Unidad
5-20	Sector
20 – 100	Microcuenca
100-300	Subcuenca
> 300	Cuenca

Nota. Tomado de (Díaz, 2017).

C. Perímetro

El perímetro de una cuenca, también conocido como la longitud del parteaguas, es un parámetro fundamental que, en combinación con el área de la cuenca, nos permite inferir sobre su forma (Trujillo, 2010, pp. 20–21). Tradicionalmente, herramientas como el planímetro y el curvímetro se han utilizado para medir el área y el perímetro, respectivamente. Sin embargo, con los avances en herramientas computacionales como CAD y SIG, estos cálculos se pueden realizar de manera rápida y precisa, siempre y cuando la cuenca haya sido digitalizada utilizando un sistema georreferenciado adecuado.

D. Forma de la Cuenca

Índice de Compacidad o Índice de Gravelius

El índice de compacidad es un indicador adimensional que describe la forma de una cuenca, comparando su perímetro con el área de un círculo de tamaño equivalente. Cuanto mayor es el coeficiente, más alejada es la forma de la cuenca respecto a un círculo (Trujillo, 2010, p.20).

Este índice se define mediante la ecuación:

$$K_c = 0.28 \times \left(\frac{P}{\sqrt{A}} \right)$$

donde:

- K_c es el índice de compacidad o índice de Gravelius (adimensional),
- P es el perímetro de la cuenca,
- A es el área de la cuenca.

Los valores de K_c pueden clasificarse en los siguientes rangos:


- K_{c1} : 1 a 1.25 (forma redonda a oval redonda),
- K_{c2} : 1.25 a 1.5 (forma oval redonda a oval oblonga),
- K_{c3} : 1.5 a 1.75 (forma oval oblonga a rectangular oblonga).

Factor Forma

El índice de Gravelius, un parámetro adimensional introducido por Horton, refleja el efecto combinado de la forma de la cuenca y la configuración de su red de drenaje. Valores del índice cercanos a la unidad indican una cuenca de forma redondeada, lo que resulta en tiempos de concentración más cortos. Esto provoca ondas de crecidas súbitas más frecuentes e intensas, aumentando significativamente la vulnerabilidad a las inundaciones (López, 1998, pp. 22–24).

Figura 3

Factor forma de la cuenca hidrográfica



Nota. Tomado de (Villón, 2002).

El factor de forma es la relación entre el área de la cuenca (A) y el cuadrado de su longitud máxima (L_m). Este parámetro mide la propensión de la cuenca a tener crecidas rápidas e intensas o lentas y sostenidas, dependiendo de su valor. Un valor alto indica una cuenca más redondeada con un río principal corto, tendiendo a concentrar el escurrimiento rápidamente. La ecuación del factor de forma es:

$$F = \frac{A}{L_m^2}$$

donde:

- F es el factor de forma (adimensional),
- A es el área de la cuenca (km^2),
- L_m es la longitud máxima del recorrido (km).

Índice de Alargamiento

El índice de alargamiento es otro parámetro que describe la forma de una cuenca, indicando su tendencia a ser alargada en relación con su longitud axial y ancho

máximo. Las cuencas con un valor del índice mayor a uno presentan una forma más alargada. Este índice también permite predecir la dinámica del movimiento del agua en los drenajes y su potencial erosivo. La ecuación del índice de alargamiento es:

$$la = \frac{Lm}{l}$$

Donde:

- la es el índice de alargamiento (adimensional),
- Lm es la longitud máxima (km),
- l es el ancho máximo (km).

E. Tiempo de Concentración

El tiempo de concentración es el tiempo necesario para que toda la cuenca contribuya eficazmente al flujo en el punto de salida del desagüe. Comúnmente, se define como el tiempo que tarda una partícula de agua desde el punto más alejado de la cuenca hasta la salida del desagüe. Este tiempo no es constante; aunque depende ligeramente de la intensidad y duración de la precipitación. Dado que el tiempo de concentración tiene una base física, muchos autores han desarrollado fórmulas empíricas para calcularlo a partir de características morfológicas y geométricas de la cuenca (Cahuana, 2009, pp. 10–11). A continuación, se presentan algunas de estas fórmulas:

- Kirpich: $Tc = 0.06626 \times \left(\frac{L_p^2}{S}\right)^{0.385}$
- Temez: $Tc = 0.126 \times \left(\frac{L_p}{S_p^{0.35}}\right)^{0.75}$
- Pasini: $Tc = 0.126 \times \left(\frac{A \times L_p}{S_p}\right)^{0.5}$
- Pizarro: $Tc = 13.548 \times \left(\frac{L^2}{H}\right)^{0.77}$

Donde:

- Tc = Tiempo de concentración (hr)
- L_p = Longitud del curso principal (Km)

- S_p = Pendiente del curso principal
- H = Diferencia de cotas entre el punto más alto y el de estudio (m)
- A = Área de drenaje (Km²)

F. Altura Promedio de la Cuenca:

La altura promedio de una cuenca es la altitud media correspondiente a la media de la abscisa del histograma de frecuencia de altitudes. Gráficamente, se obtiene entrando con el 50% del área en el eje X, trazando una perpendicular hasta interceptar la curva hipsométrica, y desde ese punto trazando una horizontal hasta cortar el eje Y (Cahuana, 2009, p. 11).


2.2.10.2. Parámetros de la Red Hidrográfica

A. Número de Orden de un Cauce

Las corrientes fluviales se clasifican jerárquicamente para entender mejor su estructura y conexión dentro de una cuenca. Las corrientes que forman las cabeceras, sin afluentes tributarios, se clasifican como de primer orden. Cuando dos corrientes de primer orden se unen, forman una corriente de segundo orden. Este proceso continúa: dos corrientes de segundo orden que se encuentran forman una de tercer orden, y así sucesivamente. Este sistema de clasificación, conocido como la jerarquía de Horton (1945), ilustra cómo cada corriente se integra en la red fluvial y cómo se interconecta toda la red, como se muestra en la figura 4.

Figura 4

Número de orden de un cauce por distribución



Nota. Tomado de (Horton, 1945).

La corriente principal de una cuenca tendrá un orden específico que refleja la extensión y complejidad de la red de corrientes dentro de la cuenca. Este sistema de ordenación es esencial para comprender la dinámica del flujo de agua, la distribución de sedimentos y la gestión de recursos hídricos en la cuenca. Conocer el orden de un cauce permite a los hidrólogos y gestores de recursos hídricos planificar de manera más efectiva la conservación, el manejo y la utilización sostenible de los recursos fluviales.

B. Longitud de la Red Principal

Este parámetro puede interpretarse de dos maneras distintas: como la distancia máxima recorrida por la escorrentía dentro de la cuenca o como la distancia entre la fuente más lejana y el punto de confluencia.

C. Pendiente del Cauce Principal (S_m)

Existen varias formas de definir la pendiente del cauce principal, incluyendo la pendiente media, la pendiente media ponderada y la pendiente equivalente. La pendiente media (S_m) se calcula como la relación entre la diferencia de altura total del cauce principal (cota máxima, H_{max} , menos cota mínima, H_{min}) y su longitud.

$$S_m = \frac{H_{max} - H_{min}}{L}$$

Donde:

- S_m : Pendiente Media
- H_{max} : Cota Máxima
- H_{min} : Cota Mínima
- L : Longitud del cauce principal

D. Densidad del Drenaje

La densidad de drenaje se define como el cociente entre la longitud total de los cauces presentes en una cuenca hidrográfica y el área total de dicha cuenca (Cahuana, 2009, p. 15). De forma similar, Horton (1945, p. 84) plantea que la densidad de drenaje es la relación entre la longitud acumulada de la red de drenaje y la superficie de la cuenca. A continuación, se presenta la fórmula correspondiente:

$$Dd = \frac{L}{A}$$

Donde:

- Dd : Densidad de drenaje (Km/Km²)
- L : Longitud total de corrientes (Km)
- A : Área de la cuenca (Km²)

E. Altura del Cauce Principal

Se refiere a la altitud máxima alcanzada por el cauce de mayor orden dentro de la cuenca (Cahuana, 2009, pp. 10–12).

F. Pendiente del Cauce Principal

La pendiente del cauce principal se relaciona directamente con las características hidráulicas del escurrimiento, incluyendo la velocidad de propagación de las ondas de avenida y la capacidad de transporte de sedimentos. Una mayor pendiente suele indicar una mayor velocidad del flujo y una mayor capacidad para transportar sedimentos (Cahuana, 2009, p. 11).

2.2.11. Tratamientos de Datos Hidrometeorológicos

Una de las áreas más desatendidas en el análisis de series hidrológicas es el tratamiento de los datos históricos obtenidos mediante medición directa, lectura o conteo. El tratamiento de datos implica ajustar los datos históricos a una condición homogénea, corrigiendo posibles errores sistemáticos, completando y extendiendo los registros, y reduciendo los datos a condiciones naturales (Tarazona, 2005, p. 51).

A. Análisis de Consistencia

La inconsistencia y no-homogeneidad en las series hidrológicas son aspectos críticos en los estudios hidrológicos modernos. Si no se identifican y corrigen, estos problemas pueden introducir errores significativos en los análisis futuros, resultando en resultados sesgados. Los datos medidos en una estación pueden contener errores aleatorios y sistemáticos. Los errores aleatorios, causados por inexactitudes en las mediciones y observaciones, son difíciles de evaluar con el tiempo y pueden originarse por errores de lectura, equipos defectuosos, mal uso de los equipos y transcripciones incorrectas. Los errores sistemáticos son más importantes, ya que pueden aumentar o reducir sistemáticamente los datos, desviando los resultados finales y causando errores significativos en los estudios basados en esos datos. La inconsistencia y no-homogeneidad se manifiestan en forma de saltos y/o tendencias en las series hidrológicas, afectando sus características estadísticas, como la media y la desviación estándar. El análisis de consistencia de la información implica identificar, describir y eliminar la no-homogeneidad e inconsistencia de una serie temporal hidrológica (Tarazona, 2005, p.71).

B. Análisis Gráficos

Tarazona (2005) señala que esta fase complementaria consiste en analizar visualmente la distribución temporal de la información hidrometeorológica disponible. Se grafica la información en coordenadas cartesianas, con el valor de la información (precipitación, descargas, etc.) en el eje de las ordenadas y el tiempo cronológico en el eje de las abscisas. El gráfico resultante, conocido como hidrograma, permite evaluar si la información es aceptable o dudosa. La información que muestra valores constantes en periodos donde físicamente no es posible se considera dudosa. Para identificar

periodos con información dudosa, se pueden usar criterios como comparar los gráficos de series históricas de estaciones vecinas o dividir una estación en varios periodos y compararla con la información de campo obtenida (p.38).

C. Análisis de Doble Masa Acumulada

Los errores se pueden detectar mediante la recta de doble masa, observando los quiebres o cambios de pendiente. Un cambio significativo indica errores sistemáticos naturales o artificiales. Se deben realizar análisis entre datos de la misma causa o efecto (precipitación vs. precipitación o descargas vs. descargas) y comparar con estaciones vecinas o cuencas con comportamiento hidrológico similar para corregir los errores (Tarazona, 2005, p. 70).

D. Análisis Estadísticos de Saltos

Para evaluar y cuantificar los errores detectados como saltos, se usa un análisis estadístico, que implica un proceso de inferencia para las medias y desviaciones estándar de ambos periodos separados, utilizando pruebas de T de Student y F de Fisher, respectivamente (Tarazona, 2005, p. 75).

E. Complemento y Extensión de Datos

El objetivo es aumentar la información de registros cortos y obtener series completas y confiables. Los métodos varían desde el relleno con promedios hasta técnicas estadísticas y matemáticas avanzadas (Tarazona, 2005, p. 77).

F. Análisis de Regresión Lineal Simple

Este método es común para la estimación de datos mensuales y anuales, estableciendo una regresión lineal con una estación patrón. La ecuación es:

$$y = a + bx$$

donde y es la precipitación estimada, x la precipitación de la estación patrón, y a y b las constantes de la regresión (Tarazona, 2005, p. 78).

G. Promedios Vecinales

Se usa para completar datos menores de un año en zonas planas. Se considera la distribución espacial de tres estaciones completas alrededor de la estación con datos faltantes, usando la ecuación:

$$Px = \frac{\sum Pi}{n}$$

Donde Pi es la precipitación de las estaciones A, B, C, y n el número de estaciones (Tarazona, 2005, p. 79).

H. Razones Promedio

Este método complementa el anterior en zonas montañosas, donde las precipitaciones difieren más del 10%. La ecuación es:

$$Px = \frac{\overline{Px}}{N} \times \left(\frac{PA}{\overline{PA}} + \frac{PB}{\overline{PB}} + \dots + \frac{PN}{\overline{PN}} \right)$$

donde Px es la precipitación estimada y $\overline{PA}, \overline{PB}, \overline{PN}$ son los promedios de las precipitaciones anuales (Tarazona, 2005, p. 79).

I. Análisis de Regresión Múltiple

Este método extiende la regresión simple y estima la precipitación mediante la ecuación:

$$Y = a + bX_1 + cX_2 + \dots + nX_n$$


donde Y es la precipitación estimada, X_1 la precipitación de estaciones completas, y a, b, c y n las constantes de la regresión (Luna y Lavado, 2015, p. 42).

2.2.12. Sistema hidrológico

Según Tarazona (2005), los fenómenos hidrológicos son extremadamente complejos y nunca pueden ser comprendidos en su totalidad. Sin embargo, a pesar de

esta complejidad, pueden representarse de manera simplificada mediante el concepto de sistema. Un sistema se define como un conjunto de partes que interactúan entre sí como un todo cohesivo. El ciclo hidrológico puede considerarse un sistema cuyos componentes incluyen la precipitación, evaporación, escorrentía y otras fases del ciclo. Estos componentes pueden agruparse en subsistemas individuales y combinarse según sus interacciones (p. 64).

Figura 5
Sistema Hidrológico



Nota. Tomado de (Olano y Solano, 2019).

La figura 5, representa el ciclo hidrológico, mostrando el movimiento del agua entre la atmósfera, la superficie y el subsuelo. Incluye procesos como la precipitación, evaporación, transpiración, infiltración, escorrentía y recarga de aguas subterráneas, evidenciando cómo el agua circula continuamente a través de estos compartimentos.

2.2.13. Redes Neuronales

En los últimos años, la computación paralela y las redes neuronales han generado un gran interés en los campos de la computación y la inteligencia artificial. Anteriormente, los métodos tradicionales de procesamiento de información utilizaban representaciones explícitas del conocimiento mediante reglas, redes semánticas y modelos probabilísticos. Estos métodos se enfocaban en las causas y sus relaciones, procesando la información de manera secuencial. Sin embargo, se presentaron muchos problemas complejos donde una representación explícita del conocimiento no era adecuada y no existía un procedimiento lógico para resolverlos. Así, surgieron las redes neuronales artificiales como una alternativa, inspiradas en las funciones del cerebro humano. Este nuevo paradigma computacional consiste en una gran cantidad de pequeños elementos procesadores interconectados que trabajan en paralelo, permitiendo realizar múltiples operaciones simultáneamente, a diferencia del procesamiento secuencial tradicional (Martí, 2009, p. 58).

Inicialmente, el desarrollo de las redes neuronales se vio limitado por la falta de tecnología adecuada y la desconexión con otras áreas de la inteligencia artificial. No obstante, el rápido avance de los recursos computacionales y el desarrollo de técnicas eficientes de computación paralela han renovado el interés en este campo. Hoy en día, las redes neuronales son eficaces en la resolución de problemas complejos como el reconocimiento de patrones, imágenes y voz, la predicción de series temporales, el control de procesos y el procesamiento de señales. Aunque las redes neuronales no buscan replicar los procesos biológicos, sino resolver tareas específicas de manera similar a los procesos inteligentes humanos, se basan en una simplificación del sistema nervioso humano. Los avances en neurología y los modelos de funcionamiento del cerebro han inspirado el diseño de estas estructuras computacionales. En esencia, las redes neuronales están formadas por numerosas neuronas procesadoras dispuestas en capas e interconectadas mediante conexiones con pesos ajustables. Estas neuronas realizan cálculos simples basados en la información recibida de las neuronas vecinas, utilizando un proceso de aprendizaje por analogía en lugar de reglas programadas rígidamente (Martí, 2009, p. 60).

2.2.14. Modelo Lutz Scholz

El modelo hidrológico Lutz Scholz es una herramienta combinada que integra un enfoque determinístico y otro estocástico para el análisis y generación de series de

caudales. Fue desarrollado entre 1979 y 1980 como parte de la Cooperación Técnica Alemana dentro del Plan Meris II (Tarazona, 2005, p. 72). Su finalidad es estimar caudales mensuales promedio y generar series sintéticas de caudales que representen adecuadamente el comportamiento hidrológico de una cuenca durante períodos prolongados.

Este modelo se basa en dos componentes principales:

- **Modelo determinístico:** Calcula los caudales mensuales promedio a partir de un balance hídrico simplificado, que incorpora variables como la precipitación, la evapotranspiración potencial, la capacidad de almacenamiento del suelo y el escurrimiento superficial. Este módulo permite establecer una base física confiable del comportamiento hidrológico a corto plazo.
- **Modelo estocástico:** Utiliza procesos de tipo markoviano para simular series de caudales a largo plazo, considerando la variabilidad aleatoria e histórica del recurso hídrico. Esta etapa permite extender las series de datos existentes y realizar análisis de frecuencia, confiabilidad y disponibilidad del caudal (Tarazona, 2005, p. 73).

La aplicación del modelo Lutz Scholz se estructura en tres fases secuenciales:

- **Etapla 1: Análisis cartográfico y estadístico de la información.** Se recopilan y procesan datos hidroclimáticos (precipitación, temperatura, evaporación, caudales) y se realizan análisis morfométricos de la cuenca mediante herramientas cartográficas. Esta fase garantiza la calidad y representatividad de los datos de entrada del modelo.
- **Etapla 2: Aplicación de los modelos determinísticos parciales.** Se emplean ecuaciones del balance hídrico mensual para obtener los caudales promedio en función de las condiciones climáticas y características de la cuenca. Esta parte permite identificar patrones mensuales y estacionales del comportamiento hidrológico.


- **Etapas 3: Generación de caudales para un período extendido.** A partir del modelo estocástico, se generan series sintéticas de caudales que reproducen estadísticamente las características observadas. Esto permite proyectar escenarios de oferta hídrica, útiles en la planificación a largo plazo y en estudios de seguridad hídrica (Tarazona, 2005, p. 77).

Este modelo se destaca por su flexibilidad y adaptabilidad a cuencas con información limitada, siendo una herramienta robusta en la evaluación de la disponibilidad hídrica y en el diseño de estrategias de gestión sostenible del recurso agua (Tarazona, 2005, p. 78).

La Figura 6, presenta la estructura del modelo Lutz Scholz, el cual integra componentes determinísticos y estocásticos para la estimación y proyección de caudales en una cuenca hidrográfica.

Figura 6

Estructura del Modelo Lutz Scholz



Nota. Tomado de (Tarazona, 2005).

La figura 6, ilustra la estructura operativa del modelo Lutz Scholz, conformada por tres fases principales. En primer lugar, se realiza un análisis cartográfico y estadístico de la información, que incluye el procesamiento de datos climáticos, hidrológicos y morfométricos de la cuenca. A continuación, se aplica el modelo determinístico parcial para calcular los caudales mensuales promedio, utilizando ecuaciones de balance hídrico. Finalmente, se procede a la generación de caudales para un período extendido mediante técnicas estocásticas, lo que permite obtener series sintéticas de caudal que reflejan el comportamiento hidrológico a largo plazo. Esta

estructura combinada proporciona una herramienta eficaz para la gestión y planificación de recursos hídricos, especialmente en contextos con información limitada.

2.2.14.1. Fundamento matemático básico

El fundamento técnico del modelo Lutz Scholz se basa en la combinación de herramientas analíticas deterministas y métodos probabilísticos. Su componente determinista se construye a partir del balance hídrico mensual, que establece que el caudal puede ser estimado como el resultado neto entre las entradas y salidas de agua dentro de la cuenca durante un periodo determinado.

La fórmula principal utilizada es:

$$Q = P - ET - \Delta S$$

Donde:

- Q : Caudal mensual promedio (en milímetros o metros cúbicos por segundo)
- P : Precipitación mensual registrada.
- ET : Evapotranspiración potencial.
- ΔS : Variación del almacenamiento de humedad en el suelo.

(Montealegre y Javela, 2021, p. 44).

El aprendizaje del modelo ANN se basa en el algoritmo de retropropagación del error, utilizando una función de activación sigmoideal/ReLU y optimización mediante descenso del gradiente. La función de pérdida empleada fue el error cuadrático medio (MSE), expresado como:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Este modelo también incorpora parámetros complementarios, como el coeficiente de escorrentía, la capacidad de infiltración del terreno y los factores de recarga subterránea. Dichos valores son ajustados con base en las características específicas de la cuenca analizada y validados con datos empíricos. El componente aleatorio del modelo se basa en cadenas de Markov de primer orden, lo que implica que la predicción del valor siguiente depende exclusivamente del valor actual y no de estados previos. Para aplicar este enfoque, se construye una matriz de probabilidades de transición a partir de los caudales históricos, la cual sirve como base para simular

nuevas series con propiedades similares a las originales. En conjunto, esta estructura matemática le permite al modelo Lutz Scholz replicar fielmente el comportamiento hidrológico observado y generar escenarios futuros de manera confiable. Esta capacidad lo hace idóneo para realizar evaluaciones de oferta hídrica en el tiempo, incluso en condiciones de incertidumbre o con información limitada (Montealegre y Javela, 2021, p. 45).

2.2.14.2. Aplicaciones, ventajas y utilidad del modelo Lutz Scholz

El modelo Lutz Scholz presenta múltiples aplicaciones dentro del ámbito de la ingeniería y la gestión de recursos hídricos, destacando por su versatilidad y simplicidad operativa. Una de sus funciones principales es la proyección de caudales sintéticos para horizontes temporales prolongados, lo que permite planificar el uso del agua en actividades agrícolas, urbanas, industriales y ambientales. Una de sus fortalezas más notables es que puede ser utilizado en cuencas con escasa información hidrométrica, ya que requiere un volumen moderado de datos para calibrarse. Asimismo, su estructura puede implementarse en herramientas accesibles como hojas de cálculo o entornos de programación básicos, lo que facilita su uso por parte de investigadores, técnicos y estudiantes. Este modelo también es valioso para el diseño de infraestructuras hidráulicas como represas, canales de riego o estaciones de bombeo, ya que permite conocer la variabilidad mensual de los caudales con base en registros históricos y datos estimados. Además, su componente estocástico contribuye al análisis de riesgos y a la identificación de periodos secos o húmedos, aportando información útil para estrategias de adaptación al cambio climático (Montealegre y Javela, 2021, p. 53).

En el ámbito institucional, el modelo apoya la formulación de planes de ordenamiento de recursos hídricos, ya que permite evaluar la disponibilidad y fiabilidad del agua a lo largo del tiempo. De esta manera, el modelo Lutz Scholz se posiciona como una herramienta eficaz, de bajo costo y alto valor técnico, que facilita la toma de decisiones en contextos donde el manejo del agua es crítico para el desarrollo sostenible de una región (Montealegre y Javela, 2021, p. 54).

2.2.15. Fundamentos Biológicos de las Redes Neuronales

La neurona es el elemento esencial del sistema de comunicación neuronal. La información se transmite entre neuronas a través de prolongaciones, formando redes

donde se elabora y almacena. Una de las prolongaciones, el axón, conduce los impulsos eléctricos y se ramifica en botones terminales que contactan con células efectoras a través de sinapsis. Las dendritas, otras prolongaciones, reciben señales y las propagan hacia el interior de la neurona. Las sinapsis, espacios líquidos con concentraciones de iones, facilitan o inhiben la transmisión de impulsos eléctricos, actuando como moduladores de las señales neuronales. El cerebro humano cuenta con alrededor de 100 mil millones de neuronas, cada una con miles de conexiones, creando una red enormemente conectada con una capacidad de procesamiento excepcional (Martí, 2009, p. 61).

A. Definición y Propiedades

Las redes neuronales artificiales son sistemas de procesamiento distribuidos en paralelo, conformados por unidades interconectadas de manera masiva, con la capacidad de almacenar conocimiento derivado de la experiencia. Su funcionamiento se asemeja al del cerebro humano, ya que adquieren conocimiento a través del aprendizaje y lo codifican mediante el ajuste de la intensidad de las conexiones entre las neuronas. Una vez definida la arquitectura adecuada para un problema específico, los pesos sinápticos se modifican progresivamente durante el entrenamiento con el fin de representar la información contenida en los datos. Estas redes destacan por su capacidad para modelar procesos no lineales, generalizar resultados, adaptarse a entornos cambiantes, tolerar errores, integrarse fácilmente a tecnologías existentes y ofrecer respuestas confiables (Haykin, 1999, pp. 43–48).

B. Aplicaciones

Las redes neuronales se utilizan en una variedad de campos debido a su capacidad para reconocer patrones, clasificar datos y realizar predicciones. En finanzas, se emplean para predecir índices y detectar fraudes. En medicina, ayudan en el diagnóstico y análisis de imágenes. En transporte, optimizan rutas y horarios. También se aplican en energía, biología, manufactura, y más. Desde 1990, las redes neuronales han sido ampliamente aplicadas en ingeniería hidráulica y medioambiental, demostrando su versatilidad y efectividad en numerosos ámbitos (Haykin, 1999, p. 49).

Las propiedades particulares de los sistemas de computación basados en redes neuronales permiten aplicar esta novedosa técnica de procesamiento a una gran

diversidad de áreas. La computación neuronal ofrece una aproximación más cercana a la percepción y el reconocimiento humano en comparación con los métodos de cálculo tradicionales. Las redes neuronales artificiales (RNA) logran resultados satisfactorios incluso en situaciones donde los datos de entrada están incompletos o contienen ruido. Entre sus principales ámbitos de aplicación se incluyen:

- a) **Conversión de texto a voz:** Esta aplicación consiste en transformar texto escrito en lenguaje hablado. Uno de los pioneros en este campo fue Terrence Sejnowski, quien junto a Rosenberg desarrolló el sistema *NetTalk*, capaz de convertir texto en fonemas y generar voz mediante un sintetizador (Dectalk). A diferencia de los enfoques clásicos que requieren programar complejas reglas fonéticas, las RNA simplifican el proceso, abriendo posibilidades para futuras investigaciones y desarrollos comerciales (Olabe, 1998).
- b) **Procesamiento del lenguaje natural:** Esta rama estudia la formación y estructura de las reglas lingüísticas. Investigadores como Rumelhart y McClelland construyeron una red neuronal capaz de aprender la conjugación en pasado de los verbos en inglés. Gracias a su capacidad de generalización con datos incompletos y de abstracción, el sistema puede prever adecuadamente la forma verbal de palabras no vistas previamente (Olabe, 1998).
- c) **Compresión de imágenes:** Implica reducir la cantidad de datos que conforman una imagen sin perder calidad visual significativa. Investigadores de las universidades de San Diego y Pittsburgh crearon un sistema que comprime imágenes en una proporción de 8:1 utilizando RNA (Olabe, 1998).
- d) **Reconocimiento de caracteres:** Consiste en identificar y clasificar símbolos escritos. La empresa Nestor, Inc. diseñó un sistema neuronal que, tras ser entrenado con diversas fuentes tipográficas, logra reconocer caracteres nuevos no incluidos en el conjunto de entrenamiento (Olabe, 1998).
- e) **Identificación de patrones en imágenes:** Se aplica, por ejemplo, a la clasificación de objetos detectados por sonar. Algunas redes basadas en el algoritmo de *Backpropagation* presentan un rendimiento comparable al de

operadores humanos. También es común su uso en procesos de inspección automatizada en industrias (Olabe, 1998).

- f) **Problemas combinatorios:** Estas situaciones suelen requerir un tiempo de cálculo elevado con métodos tradicionales. Un caso clásico es el del “viajero”, cuyo objetivo es hallar la ruta más corta entre varias ciudades. Hopfield desarrolló una red neuronal capaz de resolver eficientemente este tipo de problemas (Olabe, 1998).

- g) **Procesamiento de señales:** Las RNA se han usado en tres campos principales: predicción, modelado de sistemas y eliminación de ruido (Olabe, 1998).
 - **Predicción:** Para series de datos caóticos, Lapedes y Farber demostraron que la red *Backpropagation* supera en precisión a métodos lineales o polinómicos tradicionales.
 - **Modelado de sistemas:** Las RNA pueden aprender funciones de transferencia y simular el comportamiento de sistemas lineales.
 - **Filtrado de ruido:** Estas redes son eficaces eliminando ruido sin alterar significativamente la señal original.

- h) **Aplicaciones económicas y financieras:** Las RNA se emplean con éxito en proyecciones como precios bursátiles, producción agrícola, tasas de interés y niveles de ventas, superando con frecuencia a los métodos convencionales en exactitud y adaptabilidad (Olabe, 1998).


- i) **Control de servomecanismos:** En sistemas de control complejo, las RNA ayudan a compensar variaciones físicas que afectan la precisión del sistema. Se entrenan para predecir errores de posicionamiento en brazos robóticos y corregirlos en tiempo real, mejorando así la exactitud de las tareas realizadas (Olabe, 1998).

2.2.16. Redes Neuronales Artificiales

Las redes neuronales artificiales (ANN) están inspiradas en las redes neuronales biológicas del cerebro humano, constituidas por elementos que emulan las funciones básicas de una neurona biológica. Estos elementos se organizan de manera similar a la estructura del cerebro humano (Olabe, 1998, p. 44).

Figura 7

Estructura de una neurona biológica



Nota. Tomado de (Bustamante y Quizhpilema, 2020).

Según Olabe (1998), las partes de una neurona biológica son:

- **Célula nerviosa (soma):** Donde se combinan las señales (cuerpo celular).
- **Dendrita:** Recibe entradas de muchas otras células nerviosas (entradas).
- **Sinapsis:** La interfaz entre dos neuronas (conexiones).
- **Axón:** Transporta la señal de activación a otras células nerviosas en distintas partes (salida).

El cerebro humano es el sistema de cálculo más complejo conocido. Tanto los ordenadores como los humanos realizan tareas de manera eficiente, pero en diferentes contextos. Por ejemplo, el reconocimiento facial es una tarea sencilla para los humanos, pero compleja para los ordenadores, mientras que la contabilidad es una tarea ardua para un contable experto pero una rutina simple para un ordenador básico (Olabe, 1998, p. 47).

2.2.16.1. Redes neuronales artificiales de una capa

La capacidad de procesamiento y el rendimiento de las redes neuronales artificiales (ANN) se fundamentan en la amplia interconexión entre las neuronas artificiales que las componen. Estas conexiones permiten transmitir y transformar la información de manera eficiente, facilitando el aprendizaje y la generalización a partir de los datos.

En su forma más simple, una red neuronal consiste en un conjunto de neuronas dispuestas en una única capa. Cada entrada está conectada a todas las neuronas mediante pesos específicos que determinan el grado de influencia de cada señal en la activación de las neuronas. Aunque en aplicaciones prácticas algunas conexiones pueden ser omitidas o incluir retroalimentaciones internas, el principio general se basa en una arquitectura totalmente conectada que asegura una adecuada propagación de la información para fines de entrenamiento y predicción (Olabe, 1998).

2.2.16.2. Redes neuronales artificiales multicapa

Por lo general, las redes neuronales de mayor complejidad y tamaño tienden a ofrecer un mejor rendimiento en tareas de procesamiento de información que aquellas de arquitectura simple. Aunque las configuraciones pueden variar considerablemente, todas comparten una característica fundamental: la organización de las neuronas en capas o niveles, una estructura que se asemeja a ciertas regiones del cerebro humano (Olabe, 1998).

Las redes multicapa están compuestas por múltiples capas conectadas en secuencia, donde la salida generada por una capa actúa como la entrada para la siguiente. Este diseño en cascada permite que la red aprenda representaciones más abstractas y complejas de los datos. Es importante resaltar que el principal valor añadido de las redes multicapa radica en la incorporación de funciones de activación no lineales entre sus capas. Estas funciones permiten que la red represente relaciones no lineales en los datos. En ausencia de esta no linealidad, incluso una red multicapa se comportaría de manera equivalente a una red de una sola capa, perdiendo gran parte de su capacidad para resolver problemas complejos (Olabe, 1998, p. 42).

2.2.17. Estructura de una Neurona Artificial

Las neuronas en una red neuronal artificial están organizadas en niveles o capas con un número determinado de neuronas en cada una. Se pueden distinguir tres tipos de capas:

- **Capa de entrada:** Recibe la información directamente de las fuentes externas a la red.
- **Capas ocultas:** Son internas a la red y no tienen contacto directo con el entorno exterior. Estas capas pueden estar interconectadas de diversas formas, determinando junto con su número las diferentes tipologías de redes.
- **Capa de salida:** Transfiere la información procesada desde la red hacia el exterior (Olabe, 1998, p. 50).

A. Funciones de Activación

La función de activación se selecciona según la tarea que debe realizar la neurona. En el Perceptrón Multicapa, la función de activación comúnmente utilizada es la sigmoideal. Para su correcto funcionamiento, los valores de los atributos deben escalarse a un rango entre -1 y +1. El aprendizaje en estas redes es supervisado, donde el usuario determina la salida deseada, diferenciándose en dos etapas: entrenamiento y funcionamiento.

B. Modelo Estándar de Neurona Artificial

Según Rumelhart y McClelland (1986), la neurona artificial estándar consiste en:

- Un conjunto de entradas (x_i) y pesos sinápticos (w_{ji})
- Una regla de propagación, generalmente aditiva, basada en la sumatoria de los productos de las entradas y sus pesos.
- Una función de activación (ϕ) que determina la salida de la neurona y su estado de activación.

2.2.18. Modelo de Red Neuronal Artificial (ANN)

Las redes neuronales artificiales (ANN) son modelos computacionales inspirados en el funcionamiento del cerebro humano, útiles para resolver problemas de

predicción en sistemas complejos. En el ámbito hidrológico, se han aplicado con éxito para estimar caudales en cuencas, incluso en condiciones de datos limitados (Montealegre y Javela, 2021, p. 44).


2.2.18.1. Red Neuronal Perceptron Multicapa (MLP)

La estructura del Perceptron, conocida también como asignación de patrones (pattern-mapping), tiene la capacidad de aprender a reconocer y clasificar configuraciones a través de un proceso de aprendizaje supervisado. Los elementos que clasifica comúnmente son vectores compuestos por valores binarios (0 y 1), y las clases resultantes también se representan mediante vectores binarios. Este modelo está conformado por dos niveles de unidades de procesamiento (PE), pero únicamente una de estas capas posee la habilidad de ajustar los pesos de sus conexiones. Aunque la arquitectura del Perceptrón puede incorporar capas adicionales, estas no tienen la facultad de modificar sus enlaces sin intervención externa (Olabe, 1998).

Las señales de entrada, representadas como x_j , se introducen desde el lado izquierdo, y cada conexión dirigida hacia la neurona i está asociada a un peso específico, denotado como w_{ij} .

Figura 8

Modelo del Perceptron



Nota. Tomado de (Olabe, 1998).

La unidad de procesamiento del Perceptrón lleva a cabo una suma ponderada de las señales de entrada, de acuerdo con la expresión:

$$S_j = \sum a_i \cdot w_{ji}$$

En muchas redes neuronales artificiales (ANN) es común incorporar una entrada adicional denominada *bias* (sesgo), representada convencionalmente como a_0 . Esta entrada tiene un valor constante de +1 y actúa como un punto de referencia fijo, similar a una fuente de potencial constante en un circuito eléctrico. El Perceptrón evalúa si el valor total de las entradas ponderadas supera o no un umbral predefinido y genera la salida x_j conforme a la siguiente regla:


Si $S_j > 0$, entonces $x_j = 1$

Si $S_j \leq 0$, entonces $x_j = 0$

La salida x_j se transmite a través del canal correspondiente y forma parte del vector de salida general de la red neuronal. Las redes Perceptrón con dos capas están conformadas por una capa de entrada y una capa de procesamiento, que actúa como la capa de salida del sistema.

Figura 9

Modelo del Perceptron de dos Capas




Nota. Tomado de (Olabe, 1998).

Durante las décadas de 1950 y 1960 se propusieron diversas configuraciones de redes neuronales inspiradas en la estructura del Perceptrón. Las arquitecturas que incluyen tres o más niveles se distinguen porque la regla de aprendizaje del Perceptrón únicamente ajusta los pesos o coeficientes de conexión en una sola capa. Un ejemplo común del uso de una red con tres capas es aquel en el que se toma como entrada una imagen correspondiente a la letra “E” y como resultado se obtiene su clasificación en dos categorías distintas.

Figura 10

Modelo del Perceptron de tres Capas



Nota. Tomado de (Olabe, 1998).

El proceso de entrenamiento del Perceptrón consiste en presentar a la red, de manera secuencial, todos los ejemplos del conjunto de aprendizaje, los cuales están formados por pares de vectores que representan la entrada y la salida esperada. El propósito de este entrenamiento es encontrar un conjunto adecuado de pesos que permita a la red generar respuestas correctas para todos los casos del conjunto de entrenamiento. Una vez finalizado este proceso, los pesos se mantienen fijos y la red queda lista para operar, respondiendo adecuadamente a nuevas entradas.

La actualización de los pesos puede realizarse utilizando diversas reglas de aprendizaje. Una de las más básicas se expresa mediante la siguiente fórmula:

$$W_{jinuevo} = W_{jiviejo} + C(t_j \cdot x_j)a_i$$

donde t_j representa la salida esperada, x_j es la salida generada por la neurona, a_i corresponde a la entrada i y C es el coeficiente de aprendizaje. Durante el entrenamiento, el desempeño de la red suele mejorar progresivamente hasta alcanzar un punto en el que se estabiliza, lo que indica que ha alcanzado la convergencia. Esta convergencia puede darse en dos escenarios: o bien la red ha aprendido correctamente todos los patrones del conjunto de entrenamiento, o no ha logrado ajustarse a todas las respuestas esperadas.

2.2.18.2. Estructura de la red y función de activación

Una ANN está compuesta por nodos interconectados, organizados en capas: una capa de entrada, una o más capas ocultas y una capa de salida. Cada nodo procesa la información recibida, aplica una combinación lineal ponderada de sus entradas y luego transforma ese valor mediante una función de activación no lineal (Haykin, 2004, pp. 133–134). Matemáticamente, la salida de una neurona se expresa como:

$$y = f\left(\sum (w_{ij} * x_i) + b_j\right)$$

Donde:

- y : Salida de la neurona.
- x_i : Representa las entradas.
- w_{ij} : Son los pesos asociados.
- b_j : Es el sesgo.
- f : Es la función de activación, como la logística, ReLU o tangente hiperbólica

Las funciones más empleadas son la logística, la tangente hiperbólica y ReLU. Estas funciones permiten modelar relaciones no lineales complejas Haykin, 2004, p. 34).

Por otra parte, una arquitectura de red con cuatro entradas, dos capas ocultas de diez nodos y una salida, logrando buena precisión en la predicción del consumo de agua” (Ramirez, 2024, p. 21).

2.2.18.3. Función de error (función de costo)

Durante el entrenamiento de la red, es fundamental cuantificar la diferencia entre la salida estimada por la ANN y el valor real. Para ello, se emplea la función de error o función de costo. En tareas de regresión, como la estimación de caudales, es habitual utilizar el error cuadrático medio (ECM), que se define como:

$$ECM = \left(\frac{1}{n}\right) * \sum (y_i - t_i)^2$$

Donde:

- n : Número total de muestras.
- y_i : Salida estimada por la red.
- t_i : Valor real (Maidment, 1992).

Esta función penaliza los errores grandes y favorece modelos más estables. Es comúnmente utilizada en ANN por su facilidad de diferenciación (Maidment, 1992, p. 21).

2.2.18.4. Entrenamiento: algoritmo de retropropagación

El proceso de aprendizaje de una ANN implica ajustar los pesos sinápticos para minimizar el error. El método más común para ello es el algoritmo de retropropagación del error, propuesto por (Rumelhart, Hinton y Williams, 1986, pp. 533–535). Este algoritmo calcula el gradiente de la función de error respecto a cada peso y realiza la actualización correspondiente.

Durante el entrenamiento, los pesos se ajustan iterativamente para representar la relación entre variables. Existen mejoras como el término de momento y optimizadores como Adam o RMSprop, que permiten un aprendizaje más estable y rápido (Vera y Vargas, 2023, p. 47). Estas técnicas adaptan la magnitud de los cambios en los pesos según la evolución del gradiente. Una red neuronal entrenada con datos de una cuenca vecina es más precisa que métodos empíricos, validando el uso de ANN en contextos con limitación de datos (Zarate, 2020, p. 39).

La regla básica de ajuste de pesos se define como:

$$\Delta W_{ij} = -n * \left(\frac{\partial E}{\partial W_{ij}} \right)$$

Donde:

- ΔW_{ij} : Cambio en el peso.
- n : Tasa de aprendizaje.
- $\frac{\partial E}{\partial W_{ij}}$: Derivada parcial del error respecto al peso.

Este proceso se repite por múltiples iteraciones hasta lograr una mínima diferencia entre el valor predicho y el real. Este método es la base del aprendizaje supervisado en redes multicapa (Haykin, 2004, pp. 160–162).

2.2.19. Arquitectura de Red Neuronal

La arquitectura de una red neuronal artificial (ANN) describe la organización estructural del modelo, es decir, la forma en la que están distribuidas las neuronas y cómo estas se interconectan entre capas. Una ANN está compuesta por una capa de entrada, una o varias capas ocultas y una capa de salida. La capa de entrada recibe las variables independientes (por ejemplo, precipitación, caudal, temperatura, etc.), las capas ocultas realizan el procesamiento no lineal de los datos mediante funciones de activación, y la capa de salida genera el resultado final, que en este estudio corresponde a la predicción de la disponibilidad hídrica (Montealegre y Javela, 2021, p. 52).

Cada neurona en la red realiza una transformación matemática de sus entradas, y el resultado se transmite a las siguientes capas. El número de capas ocultas y de neuronas por capa depende del nivel de complejidad del problema. En modelos hidrológicos, se suele utilizar una arquitectura de tipo perceptrón multicapa (MLP), que ha demostrado ser eficaz para modelar sistemas no lineales y multivariantes como los relacionados con el ciclo del agua (Montealegre y Javela, 2021, p. 53).

2.2.19.1. Algoritmo de entrenamiento: backpropagation

El algoritmo de retropropagación (backpropagation) es el método más comúnmente empleado para entrenar redes neuronales. Su objetivo es minimizar el

error entre los valores reales y los valores predichos por el modelo, ajustando los pesos de las conexiones sinápticas. Este proceso se lleva a cabo en dos fases: la propagación hacia adelante, donde se calcula la salida del modelo, y la propagación hacia atrás, en la cual el error se distribuye desde la capa de salida hacia las capas anteriores (Haykin, 2004, pp. 166).

Durante la retropropagación, se calcula el gradiente del error con respecto a cada peso, y se actualizan los valores utilizando un algoritmo de optimización, generalmente el descenso del gradiente o sus variantes. La fórmula de actualización de pesos es:

$$w_{ij}^{(t+1)} = w_{ij}^{(t)} - \eta \cdot \frac{\partial E}{\partial w_{ij}}$$

Donde:

w_{ij} es el peso entre la neurona i y j .

η es la tasa de aprendizaje.

$\frac{\partial E}{\partial w_{ij}}$ es la derivada del error respecto al peso.

2.2.19.2. Función de activación ReLU (Rectified Linear Unit)

La función de activación ReLU, acrónimo de Rectified Linear Unit, es una de las funciones más empleadas en el entrenamiento de redes neuronales profundas debido a su sencillez, eficacia computacional y capacidad para introducir no linealidades esenciales en el modelo. Matemáticamente, se define como:

$$f(x) = \max(0, x)$$

Esto implica que la función devuelve cero para cualquier valor de entrada negativo y el mismo valor de entrada si este es positivo. A diferencia de funciones sigmoideas o tangenciales, ReLU no satura en rangos positivos, lo cual permite mantener gradientes más estables durante el aprendizaje (Haykin, 2004, pp. 172). El principal aporte de la ReLU radica en su capacidad para acelerar el proceso de entrenamiento, ya que evita el problema del desvanecimiento del gradiente (vanishing gradient), que puede afectar a otras funciones de activación. Además, su forma simple reduce el costo computacional de cada iteración, permitiendo trabajar con redes más profundas sin incurrir en tiempos excesivos de procesamiento (Olabe, 1998).

2.2.19.3. Función de error y evaluación

La función de error mide qué tan buena es la predicción del modelo respecto a los valores reales. En redes neuronales para predicción hidrológica, una de las métricas más utilizadas es el error cuadrático medio (Mean Squared Error – MSE), el cual penaliza fuertemente los errores grandes. Su fórmula es:

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

Donde:

y_i es el valor real.

$\hat{y}_i$ es el valor predicho.

n es el número de observaciones.

Además del MSE, también pueden emplearse otras métricas como el error absoluto medio (MAE), el coeficiente de determinación (R^2) y el Error Porcentual Absoluto Medio (MAPE), que permiten evaluar la precisión, la capacidad explicativa y la estabilidad del modelo.

2.2.19.4. Proceso de entrenamiento y validación

El proceso de entrenamiento en una red neuronal artificial (ANN) consiste en permitir que el modelo adquiera la capacidad de realizar predicciones precisas, ajustando sus parámetros internos, conocidos como pesos, según los datos que recibe como entrada. Este aprendizaje se realiza a través del algoritmo de retropropagación, que modifica los pesos para minimizar la diferencia entre el valor predicho por el modelo y el valor real observado (Zarate, 2020, p. 59).

Para lograr que el modelo aprenda de forma adecuada y sea capaz de adaptarse a nuevas situaciones sin limitarse solo a memorizar los datos proporcionados, se suele dividir el conjunto total de datos en tres subconjuntos:

- **Datos de entrenamiento (Training set):** incluye la mayor parte de los registros y se usa para que la red ajuste sus pesos. En esta etapa, el modelo identifica las relaciones entre variables como la precipitación, el caudal o la temperatura, y la variable objetivo, que es la disponibilidad hídrica (Zarate, 2020).

- **Datos de validación (Validation set):** se utilizan durante el aprendizaje para evaluar cómo generaliza el modelo. Este conjunto permite ajustar ciertos parámetros del modelo, como la cantidad de capas ocultas, la velocidad de aprendizaje o el tipo de función de activación. También ayuda a detectar el sobreajuste (overfitting), una situación en la que el modelo aprende en exceso los datos de entrenamiento, perdiendo precisión con nuevos datos (Zarate, 2020).
- **Datos de prueba (Test set):** se aplican al finalizar el entrenamiento para comprobar el rendimiento del modelo con información completamente nueva. Esto permite verificar su capacidad real para hacer predicciones confiables (Zarate, 2020).

El proceso se repite durante varias épocas, que son ciclos en los que la red analiza por completo todos los datos de entrenamiento. En cada iteración se evalúa el error en los datos de validación, y el entrenamiento suele detenerse si dicho error deja de mejorar, lo que previene que el modelo se sobreentrene. Para aumentar la eficacia del aprendizaje, se aplican técnicas como la normalización, que ajusta los valores de entrada a un rango común (como entre 0 y 1), facilitando el cálculo interno. También se utilizan funciones de activación como ReLU o sigmoide, que permiten representar relaciones complejas entre los datos de entrada y la salida del modelo.

2.2.19.5. Estructura matemática general del modelo ANN

Matemáticamente, una red neuronal multicapa puede representarse como una composición de funciones. Para una red con una capa oculta, el modelo se expresa como:

$$\hat{y} = f^{(2)}(W^{(2)} \cdot f^{(1)}(W^{(1)} \cdot x + b^{(1)}) + b^{(2)})$$

Donde:

x es el vector de entrada (variables climáticas/hidrológicas).

$W^{(1)}$, $W^{(2)}$ son los pesos de las capas.

$b^{(1)}$, $b^{(2)}$ son los sesgos (bias).

$f^{(1)}$, $f^{(2)}$ son funciones de activación (ReLU, sigmoide).

$\hat{y}$ es la salida estimada (disponibilidad hídrica).

Cada capa aplica una transformación lineal seguida de una función no lineal. Esta estructura permite a la red neuronal capturar relaciones complejas entre las variables de entrada y la variable objetivo, que en este estudio es la disponibilidad hídrica mensual.

2.2.20. Algoritmo de RetroPropagación

El algoritmo de retropropagación es una forma de aprendizaje para redes neuronales, especialmente para redes con varias capas (como el perceptrón multicapa). Su objetivo es que la salida de la red sea lo más parecida posible a la salida que se espera. Para lograr esto, se ajustan los valores internos de la red (como los pesos) usando un proceso que reduce el error entre lo que la red predice y lo que debería predecir. Este error se mide con una fórmula matemática que compara las salidas reales con las deseadas. La red aprende buscando minimizar ese error. Como el comportamiento de la red no siempre es lineal, se usan métodos especiales para encontrar la mejor solución. El más común es el descenso del gradiente, que cambia los pesos de la red en la dirección que hace que el error disminuya (Isasi y Galván, 2004).

En la práctica, no se espera a tener todos los errores para hacer el ajuste. En su lugar, se corrige el error paso a paso con cada dato que entra, lo que se llama gradiente estocástico. Cada peso se actualiza con esta fórmula:

$$w(n) = w(n - 1) - \alpha \cdot \frac{\partial e(n)}{\partial w}$$

Donde:

w : peso que se está ajustando,

α : velocidad de aprendizaje (qué tanto se corrige),

$e(n)$: error para el patrón de entrada actual.

2.2.20.1. Obtención de la regla delta generalizada

Se va a desarrollar una versión más general de la regla delta, útil para entrenar redes neuronales con múltiples capas (perceptrón multicapa). Esta regla es simplemente una manera eficiente de aplicar el descenso del gradiente a los parámetros de la red, como los pesos y umbrales.

Para ello, se deben distinguir dos casos:

1. Los pesos entre la última capa oculta y la capa de salida (y los umbrales de la salida).
2. Los pesos y umbrales del resto de la red.

a) Pesos desde la última capa oculta a la capa de salida

Supongamos que w_{ji}^{C-1} es el peso que conecta la neurona j de la capa $C - 1$ con la neurona i de la capa de salida. Usando el descenso del gradiente, este peso se ajusta así:

$$w_{ji}^{C-1}(n) = w_{ji}^{C-1}(n-1) - \alpha \cdot \frac{\partial e(n)}{\partial w_{ji}^{C-1}}$$

Donde:

- α : tasa de aprendizaje,
- $\partial e(n)$: error en la salida.

El error se calcula como la diferencia entre la salida deseada $S_i(n)$ y la salida real de la red $y_i(n)$. Al derivarlo, obtenemos:

$$\frac{\partial e(n)}{\partial w_{ji}^{C-1}} = -(s_i(n) - y_i(n)) \cdot \frac{\partial y_i(n)}{\partial w_{ji}^{C-1}}$$

Y la derivada de la salida $y_i(n)$ se expresa usando la función de activación f , como:

$$\frac{\partial y_i(n)}{\partial w_{ji}^{C-1}} = f' \left(\sum w_{ji}^{C-1} a_j^{C-1} + u_i^C \right) \cdot a_j^{C-1}(n)$$

Esto nos lleva a definir el término delta:

$$\delta_i^C(n) = -(s_i(n) - y_i(n)) \cdot f' \left(\sum w_{ji}^{C-1} a_j^{C-1} + u_i^C \right)$$

Reemplazando en la ecuación de derivada:

$$\frac{\partial e(n)}{\partial w_{ji}^{C-1}} = \delta_i^C(n) \cdot a_j^{C-1}(n)$$

Finalmente, la fórmula para actualizar el peso se convierte en:

$$w_{ji}^{C-1}(n) = w_{ji}^{C-1}(n-1) + \alpha \cdot \delta_i^C(n) \cdot a_j^{C-1}(n)$$

Los umbrales se tratan como si fueran pesos conectados a una entrada fija de valor 1. Por tanto, su actualización sigue:

$$u_i^C(n) = u_i^C(n-1) + \alpha \cdot \delta_i^C(n)$$

b) Pesos entre capas ocultas anteriores

Si tomamos un peso w_{ji}^{C-2} que conecta la neurona k de la capa $C-2$ con la neurona j de la capa $C-1$, la fórmula es:

$$w_{kj}^{C-2}(n) = w_{kj}^{C-2}(n-1) + \alpha \cdot \frac{\partial e(n)}{\partial w_{kj}^{C-2}}$$

A diferencia del caso anterior, ahora este peso influye en todas las salidas de la red, por lo que el error total es una suma de errores parciales:

$$\frac{\partial e(n)}{\partial w_{kj}^{C-2}} = \sum_{i=1}^{n_C} (s_i(n) - y_i(n)) \cdot \frac{\partial y_i(n)}{\partial w_{kj}^{C-2}}$$

La derivada de cada salida se propaga usando la regla de la cadena, considerando las activaciones y pesos involucrados:

$$\frac{\partial y_i(n)}{\partial w_{kj}^{C-2}} = f'(\dots) \cdot w_{ji}^{C-1} \cdot \frac{\partial a_j^{C-1}}{\partial w_{kj}^{C-2}}$$

Con más sustituciones y simplificación, se llega a:

$$\frac{\partial e(n)}{\partial w_{kj}^{C-2}} = \delta_j^{C-1}(n) \cdot a_k^{C-2}(n)$$

Y por tanto:

$$w_{kj}^{C-2}(n) = w_{kj}^{C-2}(n-1) + \alpha \cdot \delta_j^{C-1}(n) \cdot a_k^{C-2}(n)$$

c) Generalización para cualquier capa intermedia

Para cualquier peso w_{kj}^c que conecte la capa c con la capa $c+1$:

$$w_{kj}^c(n) = w_{kj}^c(n-1) + \alpha \cdot \delta_j^{c+1}(n) \cdot a_k^c(n)$$

Y el valor de δ para la neurona j de la capa $c+1$ se define como:

$$\delta_j^{c+1}(n) = f' \left(\sum w_{kj}^c a_k^c + u_j^{c+1} \right) \cdot \sum_{i=1}^{n_{c+2}} \delta_i^{c+2}(n) \cdot w_{ji}^{c+1}$$

d) Actualización de umbrales intermedios

Como los umbrales también se consideran como pesos, su fórmula de actualización es:

$$u_j^{c+1}(n) = u_j^{c+1}(n-1) + \alpha \cdot \delta_j^{c+1}(n)$$

2.2.20.2. Derivada de la función de activación

Para calcular los valores de δ (delta) en una red neuronal multicapa, es necesario derivar la función de activación utilizada en las neuronas.

El perceptrón multicapa normalmente trabaja con dos tipos de funciones de activación:

1. Función sigmoideal
2. Función tangente hiperbólica

La forma de calcular δ depende del tipo de función que se haya elegido.

a) Derivada de la función sigmoideal

La derivada de la función sigmoideal se obtiene aplicando la regla de derivación a su fórmula:

$$f_1(x) = \frac{1}{1 + e^{-x}}$$

Derivando esta expresión, se obtiene:

$$f_1'(x) = \frac{e^{-x}}{(1 + e^{-x})^2} = f_1(x)(1 - f_1(x))$$

Esto significa que la derivada de la función sigmoideal depende del mismo valor de activación. Es una ventaja porque hace más simple el cálculo del ajuste.

b) Aplicación de δ con función sigmoideal

Cuando usamos esta función, el cálculo del error δ en las neuronas de la capa de salida se da por:

$$\delta_i^C(n) = -(s_i(n) - y_i(n)) \cdot y_i(n) \cdot (1 - y_i(n))$$

Y para las neuronas ocultas de otras capas, el valor de δ es:

$$\delta_j^{c+1}(n) = a_j^c(n)(1 - a_j^c(n)) \cdot \sum_{i=1}^{n_{c+2}} \delta_i^{c+2}(n) \cdot w_{ji}^{c+1}$$

c) Derivada de la función tangente hiperbólica

Si se usa la función tangente hiperbólica como activación, esta se puede expresar en términos de la sigmoideal:

$$f_2(x) = 2f_1(x) - 1$$

Entonces, su derivada se convierte en:

$$f_2'(x) = 2f_1(x)(1 - f_1(x))$$

Esto implica que, si usamos la tangente hiperbólica, los valores δ calculados serán similares a los obtenidos con la función sigmoideal, pero multiplicados por 2.

2.2.20.3. Regla delta generalizada para un perceptrón multicapa con 2 entradas, 2 ocultas y 1 salida

Para este tipo de red neuronal, el error en la salida se calcula con la siguiente fórmula:

$$e(n) = \frac{1}{2}(s(n) - y(n))^2$$

donde:

- $s(n)$: valor deseado (objetivo),
- $y(n)$: salida generada por la red.

Se encarga de actualizar los pesos (conexiones) de la red para reducir ese error. Esto se hace derivando el error respecto a cada peso, y luego aplicando el método del descenso del gradiente.

a) Ajuste de pesos entre la capa oculta y la salida

Supón que v_1 conecta la neurona oculta 1 con la de salida. La derivada del error respecto a ese peso es:

$$\frac{\partial e(n)}{\partial v_1} = -(s(n) - y(n)) \cdot \frac{\partial y(n)}{\partial v_1}$$

Dado que:

$$y = f(v_1 a_1^2 + v_2 a_2^2 + u^3)$$

Entonces, usando la regla de la cadena:

$$\frac{\partial y(n)}{\partial v_1} = f'(\text{suma de entradas}) \cdot a_1^2(n)$$

Definimos el término delta como:

$$\delta^3(n) = -(s(n) - y(n)) \cdot f'(\cdot)$$

La fórmula final para actualizar v_1 es:

$$v_1(n) = v_1(n-1) + \alpha \cdot \delta^3(n) \cdot a_1^2(n)$$

De forma similar, se ajustan:

$$v_2(n) = v_2(n-1) + \alpha \cdot \delta^3(n) \cdot a_2^2(n)$$

$$u^3(n) = u^3(n-1) + \alpha \cdot \delta^3(n)$$

b) Ajuste de pesos desde la capa de entrada a la capa oculta

Ejemplo: el peso w_{12} conecta la neurona de entrada 1 con la segunda neurona oculta.

$$\frac{\partial e(n)}{\partial w_{12}} = -(s(n) - y(n)) \cdot \frac{\partial y(n)}{\partial w_{12}}$$

Para calcularlo, se aplica nuevamente la regla de la cadena, y se tiene:

$$\frac{\partial y(n)}{\partial w_{12}} = f'(\cdot) \cdot v_2 \cdot \frac{\partial a_2^2(n)}{\partial w_{12}}$$

Dado que:

$$a_2^2(n) = f(w_{12} a_1^1 + w_{22} a_2^1 + u_2^2)$$

Entonces:

$$\frac{\partial a_2^2(n)}{\partial w_{12}} = f'(\cdot) \cdot a_1^1(n)$$

Definimos:

$$\delta_2^2(n) = f'(\cdot) \cdot v_2 \cdot \delta^3(n)$$

Y la regla de actualización para w_{12} es:

$$w_{12}(n) = w_{12}(n-1) + \alpha \cdot \delta_2^2(n) \cdot a_1^1(n)$$

c) Reglas generales de ajuste para otros pesos

El resto de pesos y umbrales se actualizan de forma similar:

$$w_{11}(n) = w_{11}(n-1) + \alpha \cdot \delta_1^2(n) \cdot a_1^1(n)$$

$$w_{21}(n) = w_{21}(n-1) + \alpha \cdot \delta_1^2(n) \cdot a_2^1(n)$$

$$w_{22}(n) = w_{22}(n-1) + \alpha \cdot \delta_2^2(n) \cdot a_2^1(n)$$

$$u_1^2(n) = u_1^2(n-1) + \alpha \cdot \delta_1^2(n)$$

$$u_2^2(n) = u_2^2(n-1) + \alpha \cdot \delta_2^2(n)$$

2.3. Marco Conceptual

A. Disponibilidad Hídrica: Se define como el volumen total de agua que ha precipitado en un área específica y que está disponible para ser utilizada. Esto incluye usos como el riego agrícola, la generación de energía eléctrica y el abastecimiento de agua potable. La disponibilidad hídrica es crucial para la gestión de recursos hídricos, ya que determina la cantidad de agua accesible para satisfacer las necesidades humanas y ambientales de una región determinada (Ordoñez, 2011, p. 7).

B. Balance Hídrico: Se refiere al equilibrio entre los recursos hídricos que ingresan y salen de un sistema en un periodo de tiempo determinado. Basado en el principio del balance de materia, este concepto permite entender la dinámica del agua dentro de una cuenca hidrográfica. Involucra la medición y análisis de la precipitación, evapotranspiración, infiltración y escorrentía, facilitando una gestión adecuada y sostenible de los recursos hídricos (Ordoñez, 2011, p.7).

C. Parámetros Geométricos: Son las mediciones específicas de una zona en estudio, esenciales para caracterizar su forma y estructura. Estos parámetros incluyen el área, perímetro, forma, pendiente, longitud del cauce, longitud de la pendiente y altitudes. Los parámetros geométricos son fundamentales para el

análisis geomorfológico e hidrológico, proporcionando información vital para la planificación, gestión y conservación de recursos naturales y para el diseño de infraestructuras hidráulicas (Díaz, 2017, p. 30).

- D. Precipitación:** Se define como toda agua meteórica que cae sobre la superficie terrestre, tanto en forma líquida (llovizna, lluvia) como sólida (nieve, granizo) y precipitaciones ocultas (rocío, helada blanca). Provocada por cambios de temperatura o presión, la precipitación es la principal fuente de agua en el sistema hidrológico continental. Su medición y análisis son esenciales para comprender y gestionar los recursos hídricos y los patrones climáticos regionales (Tarazona, 2005, p. 70).
- E. Caudal:** Es el volumen de agua que fluye a través de una sección transversal de un río o canal en una unidad de tiempo. Este parámetro es crucial para la gestión de recursos hídricos, permitiendo evaluar la disponibilidad de agua para diferentes usos, como el abastecimiento de agua potable, riego, generación de energía y control de inundaciones. La medición del caudal se realiza mediante instrumentos hidrométricos en estaciones de aforo (Díaz, 2017, p. 15).
- F. Hidrograma:** Es una representación gráfica que muestra la variación del caudal de un río o corriente a lo largo del tiempo en un punto específico. Un hidrograma integra información sobre las características fisiográficas y climáticas de una cuenca de drenaje, reflejando cómo la lluvia y la escorrentía afectan el flujo de agua. Es una herramienta esencial en la hidrología para el análisis y gestión de eventos de inundación y sequía (Díaz, 2017, p. 64).
- G. Cuenca Hidrográfica:** Se define como una unidad territorial donde el agua de precipitación se reúne y fluye hacia un punto común, como un río, lago o mar. Esta área incluye hábitats de seres humanos, animales y plantas, todos interrelacionados. La cuenca hidrográfica es fundamental para la gestión integrada de los recursos hídricos, permitiendo el manejo sostenible y coordinado de las actividades humanas y ambientales que afectan el ciclo del agua (Díaz, 2017, p. 34).
- H. Temperatura:** Es la cantidad de energía solar retenida por el aire en un momento dado, dependiente principalmente de la radiación solar. Se mide con un termómetro a 1.5 metros del suelo, en un lugar ventilado y protegido de la radiación solar directa. Los resultados se expresan en grados Celsius o

Fahrenheit. La temperatura es un factor clave en los procesos climáticos y meteorológicos, influenciando la evapotranspiración y el ciclo del agua (Suarez, 2001, p. 32)

- I. **Evapotranspiración:** Se refiere al total de agua convertido en vapor por una cobertura vegetal, incluyendo la evaporación desde el suelo, la evaporación del agua interceptada y la transpiración por las estomas de las hojas. Este proceso es esencial para el ciclo hidrológico, afectando la disponibilidad de agua en una cuenca. La medición de la evapotranspiración es crucial para la planificación y gestión de recursos hídricos, especialmente en regiones agrícolas y naturales (Tarazona, 2005, p. 50).

III. MÉTODO DE LA INVESTIGACIÓN

3.1. Enfoque

El enfoque de esta investigación es cuantitativo, ya que se basa en la recopilación y análisis de datos numéricos para desarrollar y validar un modelo de predicción de la disponibilidad hídrica utilizando redes neuronales artificiales (ANN). Este enfoque permite una evaluación objetiva y sistemática de las variables meteorológicas y de caudales de agua, proporcionando resultados precisos y replicables. Según Hernández et al. (2014, p. 7), el enfoque cuantitativo se caracteriza por su objetividad y precisión en la medición de los fenómenos estudiados, lo que es esencial para el desarrollo de modelos predictivos fiables.

3.2. Alcance

El alcance de esta investigación es predictivo, ya que se orienta al desarrollo de un modelo basado en redes neuronales artificiales (ANN) que permita anticipar la disponibilidad hídrica en la cuenca del río Chalcas, en el distrito de San Pedro de Palco. Esta predicción contribuirá a mejorar la toma de decisiones en la planificación y gestión del recurso hídrico en la zona de estudio. Según Hernández et al. (2014, p. 381), una investigación predictiva no solo permite identificar relaciones entre variables, sino también proyectar el comportamiento futuro de un fenómeno a partir del análisis de datos históricos y el uso de modelos estadísticos o computacionales.

3.3. Diseño de investigación

El diseño de investigación es no experimental, cuantitativo y longitudinal tipo panel. Es no experimental porque no se manipularán deliberadamente las variables de estudio, sino que se observarán tal como ocurren en su entorno natural. Es cuantitativo porque se utilizarán datos numéricos para analizar patrones y comportamientos hidrológicos. Es longitudinal tipo panel porque se analizarán registros históricos de variables meteorológicas e hidrológicas correspondientes a los mismos puntos de observación en distintos momentos del tiempo, lo cual permite identificar tendencias y proyectar la disponibilidad hídrica a futuro mediante el modelo predictivo basado en redes neuronales artificiales (ANN). De acuerdo con Hernández et al. (2014, p. 212), los diseños longitudinales permiten estudiar los cambios o evolución de fenómenos a lo largo del tiempo, mientras que el diseño tipo panel es adecuado cuando se utilizan las mismas unidades de análisis en distintos periodos.

3.4. Población y muestra

3.4.1. Población

La población está conformada por los registros históricos de precipitación, temperatura y caudal correspondientes a la cuenca del río Chalcas, distrito de San Pedro de Palco, obtenidos de las estaciones meteorológicas Lucanas y Puquio, y la estación hidrológica Chalcas, registradas por el SENAMHI.

3.4.2. Muestra

La muestra comprende datos mensuales del periodo 1980-2002, seleccionados mediante muestreo no probabilístico por conveniencia. Se priorizó la disponibilidad y continuidad de los registros. Para uniformizar la amplitud temporal, se consolidaron las series a una frecuencia mensual, interpolando datos faltantes y asegurando la consistencia entre estaciones.

3.5. Hipótesis

3.5.1. Hipótesis general

El modelo predictivo usando redes neuronales artificiales (ANN) permite estimar con alta precisión la disponibilidad hídrica en la cuenca del río Chalcas, distrito San Pedro de Palco, Ayacucho.

3.5.2. Hipótesis específicas

- La recopilación y análisis de datos históricos y actuales de precipitación, caudales y otras variables meteorológicas relevantes en la cuenca del río Chalcas proporcionará una base de datos confiable y detallada que es esencial para el desarrollo de un modelo preciso de predicción de la disponibilidad hídrica.
- El desarrollo de un modelo de redes neuronales artificiales (ANN) para predecir la disponibilidad hídrica validado mediante técnicas estadísticas, permitirá obtener predicciones precisas y fiables sobre los patrones de flujo de agua, superando en precisión a los métodos tradicionales de predicción.
- El modelo predictivo mejorará la gestión del recurso hídrico y la eficiencia del sistema de riego en el distrito de San Pedro de Palco, permitiendo una distribución más efectiva del agua y aumentando la productividad agrícola.

3.6. Operacionalización de variables

A. Variable Independiente: Modelo predictivo usando redes neuronales artificiales (ANN).

Indicadores:

- Arquitectura ANN
- Cantidad de capas
- Cantidad de neuronas
- Precisión del modelo
- MAPE (Error Porcentual Absoluto Medio)

B. Variable Dependiente: Disponibilidad hídrica

Indicadores:

- Caudal promedio mensual
- Volumen proyectado
- Precipitación
- Porcentaje de uso eficiente del recurso hídrico disponible
- Distribución del recurso

Tabla 2

Cuadro de Operacionalización de variables

VARIABLES	DEFINICIÓN CONCEPTUAL	DEFINICIÓN OPERACIONAL	TIPO	MEDICIÓN	DIMENSIÓN	INDICADORES	UNIDAD DE MEDIDA
Modelo predictivo usando redes neuronales artificiales (ANN)	Es un sistema computacional que emplea algoritmos de aprendizaje profundo para predecir resultados basados en patrones complejos de datos históricos.	Es el desarrollo de una red neuronal artificial entrenada con datos climáticos históricos para predecir la disponibilidad hídrica en la cuenca del río Chalcas.	Independiente	Razón	Desarrollo del modelo	Arquitectura ANN	-----
						Cantidad de capas	N°
						Cantidad de neuronas	N°
					Validación del modelo	Precisión del modelo	(%)
						Error Porcentual Absoluto Medio (MAPE)	(%)
Disponibilidad hídrica	Es la cantidad y regularidad del agua disponible para riego y uso agrícola en dicha infraestructura.	Es el volumen de agua disponible en la cuenca del río Chalcas según la predicción del modelo ANN con datos meteorológicos.	Dependiente	Razón	Estimación de disponibilidad	Caudal promedio mensual	(m³)
						Volumen proyectado	(m³)
						Precipitación	(mm)
					Eficiencia del sistema de riego	Porcentaje de uso eficiente del recurso hídrico disponible	(%)
					Gestión del recurso hídrico	Distribución del recurso	(%)

Nota. Elaboración propia

3.7. Técnicas e instrumentos

3.7.1. Técnicas

- **Revisión bibliográfica:** Se empleará para recopilar y analizar antecedentes científicos sobre el uso de redes neuronales artificiales (ANN) en predicción hidrológica, validando su aplicabilidad en contextos similares al de la cuenca del río Chalcas.
- **Recolección de datos secundarios:** Consiste en la recopilación de registros históricos y actuales de precipitación, caudal, temperatura y evapotranspiración, extraídos de estaciones meteorológicas (Lucanas, Puquio) e hidrológicas (Chalcas) proporcionadas por el SENAMHI.

3.7.2. Instrumentos

- **Fichas de registros:** Instrumentos para almacenar información.
- **Software Estadístico:** Programa Python (con bibliotecas como Keras, TensorFlow, Pandas, NumPy, y SciPy) para realizar análisis descriptivos y de series temporales.

3.8. Técnicas estadísticas para el procesamiento de la información

El procesamiento de la información recolectada en esta investigación se realizará mediante diversas técnicas estadísticas que permitirán analizar y validar los datos, así como optimizar el modelo predictivo desarrollado utilizando redes neuronales artificiales (ANN). Las principales técnicas estadísticas incluyen:

- **Descomposición de Series Temporales:** Descomposición de los datos en componentes de tendencia, estacionalidad y ruido para identificar patrones subyacentes.
- **Análisis de Correlación:** Cálculo de coeficientes de correlación para determinar las relaciones entre diferentes variables meteorológicas y de caudales.
- **Regresión Lineal Múltiple:** Aplicación de modelos de regresión lineal para identificar relaciones entre variables independientes (meteorológicas) y la variable dependiente (caudal de agua).
- **Regresión No Lineal:** Aplicación de modelos de regresión no lineal para capturar relaciones más complejas entre las variables.

- **Error Cuadrático Medio (MSE):** Medición de la diferencia promedio al cuadrado entre los valores predichos y los valores observados.
- **Raíz del Error Cuadrático Medio (RMSE):** Interpretación de la magnitud del error en las mismas unidades de la variable dependiente.
- **Coeficiente de Determinación (R^2):** Evaluación de la proporción de la varianza en la variable dependiente que es predecible a partir de las variables independientes.

3.9. Análisis de validez, confiabilidad y objetividad

- **Validez:** Se respalda mediante el uso de fuentes oficiales y literatura científica reconocida. Las variables seleccionadas han sido validadas en investigaciones previas sobre predicción hidrológica.
- **Confiabilidad:** Garantizada mediante la selección de datos continuos, completos y verificados. Se emplea interpolación para datos faltantes y análisis de consistencia entre estaciones cercanas.
- **Objetividad:** Asegurada por el uso de instrumentos automáticos con criterios reproducibles. La estructura del modelo ANN minimiza la intervención subjetiva del investigador.

3.10. Desarrollo del trabajo de tesis

3.10.1. Ubicación y Límite de la Cuenca del Río Chalcas

El diseño hidráulico enfocado en el uso eficiente del agua proveniente de las precipitaciones en la microcuenca se desarrolla con el objetivo de optimizar al máximo este recurso natural. Este enfoque prioriza la gestión adecuada del agua disponible, considerando tanto su captación como su utilización, para garantizar un uso sostenible y eficiente. La estrategia implementada busca maximizar el beneficio del recurso hídrico, adaptándose a las características específicas de la microcuenca. Con ello, se pretende fomentar un manejo responsable que contribuya al equilibrio entre la disponibilidad del agua y las necesidades de las actividades que dependen de este recurso (Municipalidad Distrital de San Pedro de Palco, 2020).

3.10.1.1. Ubicación Geográfica

La cuenca que alimenta la quebrada donde está prevista la construcción de la bocatoma se encuentra a una altitud de 3,738.55 msnm. Su ubicación geográfica se especifica mediante las siguientes coordenadas UTM: 535,900 E y 8'409,506 N, con una cota establecida en 3,738.55 msnm. (Municipalidad Distrital de San Pedro de Palco, 2020).

3.10.1.2. Ubicación Política

La ubicación política y geográfica del proyecto se detalla de la siguiente forma:

- **Anexo:** San José de Chalcas
- **Distrito:** San Pedro de Palco
- **Provincia:** Lucanas
- **Región:** Ayacucho

(Municipalidad Distrital de San Pedro de Palco, 2020).

3.10.1.3. Límite

La microcuenca limita con los siguientes:

- Por el Norte con la Provincia de Huancasancos.
- Por el Sur con el distrito de Otona.
- Por el Este con el distrito de Aucara y el distrito de Lucanas.
- Por el Oeste con el distrito de Ocaña.

(Municipalidad Distrital de San Pedro de Palco, 2020).

3.10.2. Característica de la Cuenca del Río Chalcas

La zona de estudio se encuentra localizado desde un enfoque político y geográfico de la siguiente manera:

A. Localización:

La posición de la cuenca del río Chalcas, objeto del estudio, es la siguiente:

Tabla 3*Localización de la cuenca del río Chalcas*

Nombre de la cuenca	Ubicación Punto de Captación Norte (m)	Ubicación Punto de Captación Este (m)	Cota (msnm)	Área de la cuenca (km²)	Perímetro de la cuenca (km)
Río Chalcas	8,409,506.00	535,900.00	2,641.10	164.41	67.73

Nota. Elaboración propia.**B. Cobertura Vegetal:**

La vegetación principal está formada por el ichu, que, junto con otras especies, cubre el 80% del área, mientras que el 20% corresponde a afloramientos rocosos. Estas rocas, caracterizadas por fisuras y grietas, almacenan humedad que, combinada con la capacidad del suelo para retener agua, asegura la permanencia de manantiales durante largos periodos y permite una descarga continua incluso en temporadas de sequía (Municipalidad Distrital de San Pedro de Palco, 2020).

3.10.3. Metodología del Estudio realizado**3.10.3.1. Información y Datos Utilizados**

Para el análisis hidrológico de la presente investigación, se empleó la siguiente información:

A. Hidrometeorología

La información recopilada sobre condiciones meteorológicas se basa principalmente en registros históricos de precipitaciones, utilizando como referencia estaciones meteorológicas ubicadas en la parte alta de la cuenca del proyecto especial Río Cachi. Estas estaciones fueron seleccionadas debido a su similitud en altitud y características hidrometeorológicas con la zona del proyecto (Municipalidad Distrital de San Pedro de Palco, 2020). En este contexto, se consideraron las siguientes estaciones meteorológicas:

Tabla 4*Estaciones Meteorológicas*

Estación Meteorológica	1980-1984	1985-1989	1990-1994	1995-1999	2000-2002
Lucanas	Incompleto	Incompleto	Incompleto	Incompleto	Incompleto
Puquio	Incompleto	Incompleto	Incompleto	Completo	Completo
Paucocorral	Completo	Incompleto	Incompleto	Incompleto	Incompleto
Huancasancos	Completo	Completo	Completo	Incompleto	Incompleto
Quiroramba	Completo	Completo	Completo	Completo	Completo
Paico	Completo	Completo	Completo	Completo	Completo

Nota. Elaboración propia.

Para el estudio relacionado con la generación de caudales, se han tomado en cuenta las siguientes estaciones meteorológicas, además el desglose de estas estaciones se puede visualizar en el Anexo N° 9.

Tabla 5*Estaciones meteorológicas*

Estación Meteorológica	Tipo	Latitud (° ' ")	Longitud (° ' ")	Altitud Media (msnm)	Región	Provincia	Distrito
Lucanas	Convencional, Meteorológica	14° 37' 00.00"	74° 13' 00.00"	3,354.00	Ayacucho	Lucanas	Lucanas
Puquio	Convencional, Meteorológica	14° 41' 00.00"	74° 07' 00.00"	3,168.00	Ayacucho	Lucanas	Puquio
Paucocorral	Convencional, Meteorológica	14° 40' 00.00"	74° 06' 00.00"	4,060.00	Ayacucho	Lucanas	Puquio
Huancasancos	Convencional, Meteorológica	13° 55' 00.00"	74° 20' 00.00"	3,553.00	Ayacucho	Huancasancos	Sancos
Querobamba	Convencional, Meteorológica	14° 01' 00.00"	73° 50' 00.00"	3,502.00	Ayacucho	Sucre	Querobamba
Paico	Convencional, Meteorológica	14° 02' 00.00"	73° 40' 00.00"	3,589.00	Ayacucho	Sucre	Paico

Nota. Elaboración propia.

Las estaciones meteorológicas consideradas presentan registros variables de precipitación, temperatura y evaporación en diferentes periodos. De acuerdo con el Informe Técnico N.º 002-2020 ANA-AAA-CH.CH-ALA GRANDE, las series temporales abarcan intervalos comprendidos entre 1980 y 2002, con algunas estaciones como Lucanas y Huanca Sancos mostrando datos completos, y otras como Paco con registros incompletos. El detalle del periodo de registro de cada estación se presenta en el Anexo 7, donde se incluyen los datos obtenidos de las estaciones analizadas. Además, para estimar la demanda hídrica agrícola, se consideró la estación ubicada en la parte inferior de la cuenca del río Chalcas, a una altitud de 3738.55 msnm, según información proporcionada por la Municipalidad Distrital de San Pedro de Palco (2019).

3.10.3.2. Análisis de Consistencia

Este estudio tiene como objetivo identificar, medir y ajustar posibles variaciones o patrones anómalos presentes en los registros históricos, ocasionados por errores sistemáticos durante los procesos de medición. El procedimiento de consistencia se llevará a cabo a través de tres análisis específicos que se detallan a continuación (Municipalidad Distrital de San Pedro de Palco, 2020).

A. Análisis gráfico

El análisis gráfico inicial es un paso para la construcción de un modelo predictivo basado en redes neuronales artificiales (ANN). Mediante estas representaciones visuales, se busca identificar patrones, rupturas o irregularidades en los datos, permitiendo una comprensión preliminar de su comportamiento. Este proceso permite orientar las etapas posteriores del análisis, como la normalización de los datos y la selección de variables clave, asegurando una mejor preparación para el modelo. Además, el análisis gráfico facilita la detección de tendencias y comportamientos que el modelo ANN debe captar para hacer predicciones precisas.

B. Análisis de doble masa

El análisis de doble masa complementa el proceso de construcción del modelo predictivo basado en redes neuronales artificiales (ANN), al ofrecer una herramienta para validar y ajustar la consistencia de los registros históricos. Este método permite identificar cambios abruptos en los datos, ya sea por errores sistemáticos en la medición o por fenómenos naturales significativos.

C. Análisis Estadístico

Para determinar la homogeneidad de los principales parámetros estadísticos en los períodos marcados por los quiebres del diagrama de doble masa, se realizaron las pruebas estadísticas T y F, considerando un nivel de significancia de 0.05.

- **Análisis de Consistencia de la Media (Prueba t de Student)**

Los parámetros estadísticos se determinan utilizando las ecuaciones que se presentan a continuación:

$$S_p = \sqrt{\frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2}}$$

$$S_d = S_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$$

$$T_c = \frac{(\bar{x}_1 - \bar{x}_2) - (u_1 - u_2)}{S_d}$$

- **Análisis de Consistencia de la Desviación (Prueba F de Fisher)**

$$F_c = \frac{\text{Variancia} >}{\text{Variancia} <}$$

$$F_1 = \frac{G.L (Var >)}{G.L (Var <)}$$

Se incluyen los parámetros correspondientes a los períodos determinados por los quiebres, junto con los resultados obtenidos del análisis estadístico realizado.

3.10.3.3. Corrección de la Información

Para ajustar los períodos que no presentan homogeneidad, se empleó la siguiente ecuación:

$$x = \left(\frac{x - x_2}{S_2} \right) * S_1 + x_1$$

Donde:

x_1 = valor corregido

x = valor a ser corregido

(Municipalidad Distrital de San Pedro de Palco, 2020).

3.10.4. Parámetros Geomorfológicos de la Cuenca

El análisis del comportamiento hídrico de las cuencas se realiza identificando características y variables fundamentales que permitan establecer coeficientes capaces de describir los procesos naturales. Para ello, se consideran los siguientes factores en el estudio de su comportamiento físico:

- Relación de forma de la microcuenca, definida como:
 $K = \text{Perímetro de la microcuenca} / \text{Perímetro del círculo de área equivalente}$
- Duración del tiempo de concentración.
- Índice de densidad de drenaje.
- Relación del factor de forma.
- Coeficiente asociado a la escorrentía.

Además, se toman en cuenta parámetros esenciales de las cuencas, tales como:

- Perímetro.
- Superficie
- Longitud.
- Grado de inclinación.
- Diferencia de altura (m.s.n.m.).

Estos factores se establecen luego de evaluar las dinámicas físicas de la cuenca y determinar el potencial de escurrimiento para incluirlo en el aporte hídrico de la cuenca del río Chalcas.

Tabla 6*Características geomorfológicas de la cuenca del río Chalcas*

DESCRIPCIÓN	UND	VALOR
Área y Perímetro de la Cuenca		
Área	km ²	164.41
Perímetro	km	67.73
Cotas		
Cota máxima	msnm	4,400.00
Cota mínima	msnm	2,641.10
Centroide PSC (WGS: 1984 UTM ZONE 18S)		
X centroide	km	537.52
Y centroide	km	8,417.94
Z centroide	msnm	3,738.55
Altitud		
Altitud media	msnm	3,738.55
Altitud más frecuente	msnm	4,211.00
Altitud de frecuencia media	msnm	4,193.00
Pendiente		
De la Red Hídrica		
Longitud del curso principal	km	23.39
Orden de la red hídrica	und	7.00
Longitud de la red hídrica	km	955.03
Pendiente promedio de la red hídrica	%	1.52
Parámetros calculados		
Factor de forma de Horton (Kf)		0.30
Índice de Compacidad o de Gravelius (Kc)		1.48
Coeficiente de Circularidad de Miller (Cc)		0.45
Densidad de Drenaje (D)	km/km ²	5.81
Tiempo de concentración	horas	1.77

Nota. Elaboración propia.**3.10.5. Determinación de la oferta hídrica mediante el modelo Lutz Scholz**

A través del modelo Lutz Scholz, se estimaron caudales mensuales promedio a partir del balance hídrico. Como resultado del proceso, se obtuvieron caudales en el orden de 250 m³/s en meses húmedos y 30 m³/s en meses secos. Estos valores fueron utilizados en la siguiente etapa para la comparación con la demanda hídrica. El detalle del cálculo se presenta en el Anexo 8.

El procedimiento consistió en aplicar el balance hídrico mensual bajo la forma:

$$Q = P - ETP \pm \Delta S$$

Donde:

- Q : Caudal medio mensual estimado (m^3/s).
- P : Precipitación mensual (mm).
- ETP : Evapotranspiración potencial (mm).
- ΔS : Variación del almacenamiento del suelo.

Se calibraron los parámetros del modelo en función del coeficiente de escorrentía y características del suelo. A partir de estos cálculos, se generó una serie mensual de caudales promedio que permitió representar la oferta hídrica disponible en la cuenca. Los resultados obtenidos mostraron una mayor disponibilidad en los meses de enero a marzo, superando los $250 \text{ m}^3/\text{s}$, mientras que en los meses secos (junio a agosto) los caudales se redujeron a valores cercanos a $30 \text{ m}^3/\text{s}$.

3.10.6. Oferta Hídrica

3.10.6.1. Disponibilidad del Recurso Hídrico para el proyecto

Para este proyecto, los recursos hídricos disponibles provienen del escurrimiento generado por las precipitaciones en la cuenca del río Chalcas. Con el propósito de calcular el caudal promedio mensual de escurrimiento.

El recurso hídrico considerado para esta investigación fue determinado mediante los registros de precipitación obtenidos de estaciones ubicadas en Lucanas, Huancasancos y Sucre, seleccionadas por sus características similares al área de estudio. Dado que la cuenca en análisis no cuenta con estaciones hidrométricas que registren descargas naturales, fue necesario estimar la disponibilidad hídrica a través de un modelo que permitiera generar caudales mensuales promedio. Para este fin, se empleó el modelo hidrológico Lutz Scholz, que se ajusta a las condiciones específicas de la zona.

El modelo Lutz Scholz realiza una simulación del ciclo hidrológico, incorporando simplificaciones. Las variables de entrada están basadas en los datos mensuales de precipitación de las estaciones seleccionadas y en parámetros clave de la cuenca, tales

como área, coeficiente de uniformidad, coeficiente de escorrentía, umbral de escorrentía, tiempo de concentración, intensidad de tormentas y precipitación con un 75% de persistencia. Estos valores se calculan según el siguiente procedimiento:

A. Área de la Cuenca (A)

A partir del análisis del plano y las curvas de nivel correspondientes a la cuenca del río Chalcas y sus áreas cercanas de interés, se ha determinado una superficie total de 164.41 km².

B. Pendiente de la Microcuenca (J)

El cálculo se realiza utilizando la fórmula siguiente:

$$J = \frac{H}{L \times 1000}$$

Donde:

- L representa la longitud del cauce principal en kilómetros (Km).

C. Coeficiente de Uniformidad (k)

Este valor se calculó aplicando la siguiente fórmula aproximada:

$$K = 1 + \frac{Tc^{1.25}}{Tc^{1.32} + 14}$$

Donde:

- Tc es el tiempo de concentración, que se define como el intervalo necesario para que el agua de la precipitación registrada en la zona más lejana de la microcuenca llegue al punto de interés. Este tiempo se mide en horas.

D. Coeficiente de Escorrentía (C)

$$C = \frac{(Pd - Po) * (Pd + 23Po)}{(Pd - 11Po)^2}$$

Donde:

Pd = Precipitación media mensual al 75% de persistencia (mm).

Po = Umbral de escorrentía, que es el parámetro de modelo de infiltración (mm).

E. Tiempo de Concentración (Tc)

La ecuación utilizada para calcular el tiempo de concentración sugerido es una adaptación de la fórmula del US Army Corps of Engineers:

$$Tc = 0.3 * \left(\frac{L}{J^{1/4}} \right)^{0.76}$$

Donde:

- J corresponde a la pendiente del cauce principal de la microcuenca expresada en porcentaje (%).

F. Umbral Escorrentía (Po)

El enfoque se basa en que las primeras gotas de lluvia de una precipitación son absorbidas y retenidas por el suelo hasta alcanzar un punto crítico (P0), donde comienza a generarse escorrentía. A medida que el terreno se satura con agua, el porcentaje de escorrentía incrementa progresivamente hasta alcanzar el 100%. Este comportamiento se representa mediante dos parámetros principales que describen el modelo:

- **La pérdida inicial** (también conocida como umbral de escorrentía, P0, expresada en milímetros).
- **El número de curva (CN)**, un valor adimensional que caracteriza las propiedades de la cuenca. Este número varía de 0 a 100, donde valores menores indican mayor permeabilidad del suelo y valores mayores, menor capacidad de absorción.

Donde:

- CN = Número de Curva (adimensional).

G. Intensidad de Tormenta (It)

El cálculo se realiza mediante las siguientes expresiones empíricas:

$$P0 = \frac{5080}{CN} - 50.80$$

$$It = Id * \left(\frac{It}{Id} \right)^{\frac{28t-1}{28t-1}}$$

Donde:

- ***It*** = Intensidad promedio de la tormenta de diseño en mm/h.
- ***Id*** = Intensidad media diaria, expresada en mm/h.
- ***I1*** = Intensidad promedio de la tormenta con duración de 1 hora.
- ***t*** = Duración de la tormenta de diseño, igual al tiempo de concentración.

La relación entre la intensidad de una tormenta horaria y la intensidad diaria (conocida como factor de torrencialidad) se obtiene a partir de un análisis regional.

H. Persistencia de la Precipitación al 75% (PP 75%)

La probabilidad de ocurrencia de la precipitación con un 75% de constancia es considerada adecuada para proyectos de irrigación, ya que los cultivos pueden tolerar hasta un 25% de déficit hídrico sin afectar significativamente su rendimiento.

El cálculo se llevó a cabo utilizando la función estadística de percentil aplicada a la serie de datos mensuales. Con los valores obtenidos de las variables de entrada para el modelo de balance hídrico, se procede a generar las descargas promedio mensuales correspondientes al período evaluado en la cuenca.

La Tabla 7 muestra el registro completo de la precipitación mensual en la cuenca del río Chalcas, correspondiente al período enero de 1980 a diciembre de 2002, con un total de 276 registros. Estos datos fueron obtenidos a partir de las estaciones meteorológicas de Lucanas, Sucre y Huancasancos, y se utilizaron como variable de entrada para la construcción del modelo predictivo con redes neuronales artificiales.

Tabla 7*Precipitación mensual calculada en la cuenca del río Chalcas (mm)*

Año	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Total
1960	77.42	53.73	124.58	4.41	2.63	0.39	8.07	1.07	12.36	36.63	16.21	28.75	77.42
1981	93.32	207.52	135.6	46.74	5.69	1.3	1.29	24.38	8	7.72	23.42	94.74	93.32
1982	113.33	115.82	108.86	40.98	4.52	0.92	2.31	5.8	19.55	34.22	44.6	31.86	113.33
1983	75.09	80.2	98.73	33.55	3.08	1.32	1.98	2.19	13.78	17.91	15.8	53.43	75.09
1984	132.19	149.93	142.07	37.92	7.07	10.9	2.74	5.36	12.94	23.8	42.53	67.02	132.19
1985	88.25	166.44	292.17	88.57	24.06	11.19	1.71	4.26	6.06	14.21	24.47	77.18	88.25
1986	189.56	186.17	214.35	43.22	7.18	1.42	2.78	7.1	8.98	6.14	10.1	77.62	189.56
1987	149.04	81.27	93.94	25.4	5.85	3.78	0.91	4.6	11.96	19.4	25.82	44.74	149.04
1988	115.52	130.58	112.63	39.69	17.63	0.61	2.27	1.76	5.78	14.04	12.6	79.13	115.52
1989	240.09	185.16	186.39	37.08	8.39	2.29	1.89	6.04	3.07	14.81	20.15	41.09	240.09
1990	108.29	71.95	103.45	33.59	38	28.89	1.25	11.97	19.91	38.38	60.48	78.95	108.29
1991	85.87	66.19	165.25	32.55	9.34	3.28	1.27	1.96	5.56	14.25	18.67	22.1	85.87
1992	34.19	65.63	61.45	14.03	1.51	1.92	2.96	3	3.11	19.32	18.29	29.97	34.19
1993	115.58	123.83	109.05	47.28	10.14	0.82	2.34	7.73	12.67	24.55	36.57	65.12	115.58
1994	167.91	197.8	163.77	55.16	17.05	15.41	4.08	16.42	12.92	12.08	28.17	35.51	167.91
1995	109.95	89.83	168.61	25.13	1.55	0.71	1.04	1.46	11.94	19.03	57.02	59.9	109.95
1996	145.96	214.41	124.23	82.89	6.1	0.32	1.41	9.03	11.46	14.35	23.76	64.6	145.96
1997	125.23	140.59	87.69	35.99	8.24	0.31	2.05	20.66	18.87	16.91	37.21	98.33	125.23
1998	178.05	115.25	121.48	22.91	0.93	9.67	0.64	2.43	3.06	19.68	41.88	82.47	178.05
1999	122.33	202.2	133.23	44.31	10.57	1.12	4.5	0.77	20.94	45.33	20.88	75.51	122.33
2000	189.93	183.99	149.28	25.38	10.18	4.85	5.23	11.35	9.51	56.05	24.87	99.58	189.93
2001	160.37	138.36	182.82	52.5	18.89	2.3	7.01	10.08	11.32	17.37	34.91	42.31	160.37

2002	123.4	149.53	157.39	36.3	15.36	5.28	19.24	8.46	17.96	22.12	50.34	84.35	123.4
N° Datos	23	23	23	23	23	23	23	23	23	23	23	23	23
Media	127.86	135.49	140.74	39.37	10.17	4.74	3.43	7.30	11.38	22.10	29.95	62.36	127.86
Desv. Estándar	45.79	51.34	48.95	18.79	8.60	6.72	3.94	6.29	5.50	12.22	14.14	23.87	45.79
Coef. Variación	0.36	37.89	34.78	47.72	84.59	141.78	114.71	86.21	48.32	55.29	47.22	38.28	35.81
Precip. Máx.	240.09	214.41	292.17	88.57	38	28.89	19.24	24.38	20.94	56.05	60.48	99.58	240.09
Precip. Mín.	34.19	53.73	61.45	4.41	0.93	0.31	0.64	0.77	3.06	6.14	10.1	22.1	34.19
Precip. 75%	95.90	101.62	105.56	29.53	7.63	3.56	2.57	5.48	8.54	16.58	22.46	46.77	95.90

Nota. Información tomada del Informe Técnico N°002-2020 ANA-AAA-CH.CH-ALA GRANDE. Fuente (Municipalidad Distrital de San Pedro de Palco, 2020). La precipitación mensual en la cuenca del río Chalcas fue calculada aplicando el método de isoyetas con base en los registros históricos de las estaciones meteorológicas de Lucanas, Huancasancos y Sucre proporcionados por el SENAMHI. El procedimiento incluyó la delimitación de áreas de influencia y el uso de mapas topográficos para interpolar valores promedio mensuales representativos para la cuenca.

3.10.6.2. Generación de Descargas Medias Mensuales

El enfoque racional, utilizado en el modelo de Lutz Scholz, supone que el caudal máximo ocurre durante una precipitación cuya duración es igual al tiempo de concentración de la cuenca. La ecuación

$$Q = \frac{C * I_t * A * K}{3.6}$$

Donde:

- Q = Pico caudal en metros cúbicos por segundo (m³/s).
- C = Coeficiente de escorrentía.
- I_t = Intensidad de la tormenta de diseño en milímetros por hora (mm/h).
- A = Área de la cuenca en kilómetros cuadrados (km²).
- K = Coeficiente de uniformidad.

La Tabla 8 presenta la descarga media mensual (caudal en m³/s) correspondiente al mismo período de análisis: 1980–2002. Este conjunto de datos representa la variable de salida del modelo ANN y fue recopilado a partir de registros hidrológicos oficiales proporcionados por el SENAMHI. El uso de una serie histórica completa permite asegurar una mejor generalización del modelo y evitar sesgos derivados de muestras insuficientes. A continuación, se muestran los resultados obtenidos.

Tabla 8

Registro de Descarga Media Mensual de la Cuenca en Estudio

Mes	Q Promedio (l/s)
Ene	284.91
Feb	297.40
Mar	275.73
Abr	121.12
May	59.96
Jun	32.00
Jul	28.61
Ago	43.45
Set	63.51
Oct	100.31
Nov	140.89
Dic	182.69

Nota. Información tomada del Informe Técnico N°002-2020 ANA-AAA-CH.CH-ALA GRANDE. Fuente (Municipalidad Distrital de San Pedro de Palco, 2020).

3.10.6.3. Disponibilidad Hídrica Aprovechable

La cantidad de agua disponible en la cuenca analizada se define principalmente por el aporte de las precipitaciones pluviales y de los pequeños manantiales presentes en la región.

A. Aporte de la Precipitación

La disponibilidad derivada de las lluvias se ha calculado empleando el modelo correspondiente, cuya ecuación de balance es la siguiente:

$$V (m^3) = \frac{(P * K_a - B * P_o)^2}{(P * K_a + 4 * B * P_o)} * A * 1000$$

Donde:

- **V** = Corresponde al volumen de agua ofrecido, expresado en metros cúbicos (m³).
- **P** = Precipitación media mensual, en milímetros (mm).
- **P_o** = Representa el umbral de escorrentía, en milímetros (mm).
- **A** = Área de la cuenca, en kilómetros cuadrados (km²).
- **K_a** = Coeficiente de distribución espacial de la precipitación
- **B** = Coeficiente de retención de la microcuenca.

3.10.6.4. Balance Hídrico del Proyecto

Las lluvias y los manantiales presentes en la cuenca analizada representan la fuente de agua disponible para el proyecto. Por otro lado, la necesidad hídrica corresponde al consumo requerido por los cultivos planteados en la programación agrícola de la zona de riego.

Tabla 9

Fase de Crecimiento Activo del Cultivo Principal

Especie		Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
Área		11,50	11,50	11,50	11,50	11,50	11,50	11,50	11,50	11,50	11,50	11,50	11,50
Kc ponderado		1.08	0,97	0,70	0,70	0,60	0,57	0,76	0,85	0,83	0,67	0,63	0,62
Eto (mm/mes)		115,16	93,40	93,66	90,51	75,46	72,40	94,73	95,16	122,41	120,70	134,01	132,74
Eto (mm/mes)		3.71	3.33	3.32	3.02	2.43	2.41	3.28	3.06	3.28	3.27	3.30	3.30
Eto (mm/día)		4.00	3.25	1.91	1.56	1.49	1.37	2.07	2.61	3.13	2.63	2.81	2.66
P75% (mm/mes)		157,55	142,14	147,74	30,48	8.41	3.05	3.05	4.21	13,85	42.07	43.26	113,43
PE (mm/mes)		100,63	97,29	98,68	24,18	3.24	3.21	3.20	8.41	8.41	36.41	35,68	86,79
NRn (mm/mes)		23.23	22.22	22,72	42,81	41.20	41.23	64,60	81.06	85,43	48,69	48,50	0.00
Er %		0,70	0,70	0,70	0,70	0,70	0,70	0,70	0,70	0,70	0,70	0,70	0,70
Nkb (mm/mes)		0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
Demanda de agua (L/seg)		1.42	0.00	1.43	2.61	2.60	3.91	4,95	5.39	2.86	3.06	0.00	0.00
Módulo de Riego (L/s/ha)		0,12	0.00	0,12	0,23	0,23	0,34	0,43	0,47	0,25	0,27	0.00	0.00
Módulo de Riego (L/s/ha)	24	0.12	0.00	0.00	0.12	0.23	0.23	0.34	0.43	0.47	0.25	0.27	0.00
	16	0.19	0.00	0.00	0.19	0.31	0.31	0.51	0.65	0.70	0.37	0.40	0.00
	14	0.21	0.00	0.00	0.21	0.39	0.39	0.58	0.74	0.80	0.43	0.46	0.00
	12	0.25	0.00	0.00	0.25	0.45	0.45	0.68	0.86	0.94	0.50	0.53	0.00
	10	0.30	0.00	0.00	0.30	0.55	0.54	0.82	1.03	1.13	0.60	0.64	0.00
	8	0.37	0.00	0.00	0.37	0.68	0.68	1.02	1.29	1.41	0.75	0.80	0.00
	6	0.49	0.00	0.00	0.50	0.91	0.91	1.36	1.72	1.88	1.00	1.07	0.00
	4	0.74	0.00	0.00	0.75	1.36	1.36	2.04	2.58	2.81	1.49	1.60	0.00
Demanda de Agua Bruta (m³/mes/ha)		330	0	0	323	609	587	912	1153	1215	667	690	0

Demanda de Agua Bruta (m³/mes)	3.801	0	0	3.717	7002	6,745	10,484	13,260	13,975	7,671	7,938	0
Demanda (m³/mes)	12,815	8,628	1,628	6029	7,532	6,745	10,484	13,260	15,350	12,915	12,930	10,800

Nota. Información tomada del Informe Técnico N°002-2020 ANA-AAA-CH.CH-ALA GRANDE. Fuente (Municipalidad Distrital de San Pedro de Palco, 2020).

Tabla 10

Disponibilidad hídrica calculada en la cuenca del río Chalcas (l/s)

Año	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
1960	4,900.27	3,400.73	7,898.55	274.59	161.91	20.30	504.64	59.17	773.56	2,314.86	1,019.46	1,815.79
1981	5,908.81	13,155.60	8,597.54	2,959.57	356.00	78.03	74.59	1,537.71	497.01	481.11	1,476.79	6,001.52
1982	7,178.04	7,339.09	6,901.43	2,594.22	281.79	53.92	139.28	359.19	1,229.62	2,162.00	2,820.23	2,013.05
1983	4,752.48	5,079.72	6,258.89	2,122.93	190.45	79.29	118.35	130.21	863.63	1,127.46	993.46	3,381.24
1984	8,374.32	9,502.68	9,007.93	2,400.12	443.53	686.95	166.56	331.28	810.35	1,501.06	2,688.93	4,243.25
1985	5,587.22	10,549.90	18,528.74	5,612.84	1,521.21	705.35	101.23	261.51	373.95	892.77	1,543.39	4,887.69
1986	12,013.29	11,801.37	13,592.64	2,736.30	450.51	85.64	169.10	441.65	559.17	380.89	631.91	4,915.60
1987	9,443.11	5,147.59	5,955.06	1,605.98	366.15	235.33	50.48	283.07	748.19	1,221.97	1,629.02	2,830.03
1988	7,316.95	8,275.31	7,140.56	2,512.39	1,113.35	34.26	136.75	102.93	356.19	881.98	790.48	5,011.38
1989	15,218.39	11,737.31	11,819.14	2,346.84	527.26	140.82	112.64	374.41	184.30	930.82	1,269.38	2,598.51
1990	6,858.35	4,556.42	6,558.27	2,125.47	2,405.42	1,828.05	72.05	750.55	1,252.46	2,425.86	3,827.50	4,999.96
1991	5,436.25	4,191.07	10,478.23	2,059.50	587.52	203.62	73.32	115.62	342.24	895.30	1,175.50	1,393.98
1992	2,158.20	4,155.55	3,894.22	884.78	90.86	117.35	180.51	181.58	186.84	1,216.89	1,151.40	1,893.17
1993	7,320.75	7,847.16	6,913.48	2,993.82	638.26	47.58	141.19	481.61	793.23	1,548.63	2,310.89	4,122.73
1994	10,640.03	12,539.06	10,384.36	3,493.65	1,076.56	973.02	251.55	1,032.81	809.08	757.66	1,778.08	2,244.57

1995	6,963.64	5,690.55	10,691.36	1,588.85	93.40	40.60	58.73	83.90	746.92	1,198.50	3,608.03	3,791.63
1996	9,247.75	13,592.63	7,876.35	5,252.56	382.01	15.86	82.20	564.07	716.48	901.65	1,498.36	4,089.75
1997	7,932.85	8,910.25	5,558.62	2,277.70	517.75	15.23	122.79	1,301.75	1,186.49	1,064.03	2,351.49	6,229.23
1998	11,283.21	7,302.93	7,701.91	1,448.04	54.08	608.93	33.36	145.43	183.67	1,239.73	2,647.71	5,223.24
1999	7,748.90	12,818.15	8,447.21	2,805.44	665.54	66.61	278.20	40.14	1,317.79	2,866.70	1,315.68	4,781.76
2000	12,036.76	11,663.10	9,465.26	1,604.71	640.80	303.20	324.50	711.22	592.79	3,546.67	1,568.76	6,308.52
2001	10,161.77	8,768.80	11,592.70	3,324.93	1,193.27	141.46	437.40	630.67	707.60	1,093.20	2,205.60	2,675.90
2002	7,816.77	9,477.31	9,979.68	2,297.36	969.37	330.48	1,213.15	527.91	1,128.77	1,394.50	3,184.32	5,342.48

Nota. Información tomada del Informe Técnico N°002-2020 ANA-AAA-CH.CH-ALA GRANDE. Fuente (Municipalidad Distrital de San Pedro de Palco, 2020).

3.10.7. Implementación del modelo de red neuronal artificial (ANN)

3.10.7.1. Información utilizada para el modelo ANN

En el presente estudio, el objetivo principal es predecir la disponibilidad hídrica mensual en una cuenca hidrográfica utilizando redes neuronales artificiales (ANN). Este enfoque aprovecha datos hidrológicos y geomorfológicos clave que describen las características de la cuenca y su dinámica hídrica. Los datos se recopilieron y organizaron a partir de la información desarrollada anteriormente, destacando tres tipos de datos: precipitación media mensual, características geomorfológicas de la cuenca y valores observados de caudales medios mensuales.

Para ello, se desarrolló e implementó un modelo de red neuronal artificial del tipo Perceptrón Multicapa (MLP), entrenado desde cero mediante el algoritmo de retropropagación del error (backpropagation). La implementación se realizó utilizando el lenguaje de programación Python, con las bibliotecas Keras y TensorFlow, que permitieron definir y entrenar la arquitectura del modelo. Este modelo fue diseñado específicamente para la cuenca del río Chalcas, sin tomar configuraciones predeterminadas de otros estudios, asegurando así la originalidad y aplicabilidad al contexto local.

- a) Precipitación Mensual (Media):** La precipitación promedio mensual se obtuvo de la Tabla 7: Precipitación Media Mensual, que contiene valores históricos para cada mes del año. Este parámetro se incluye como una de las entradas del modelo debido a su influencia directa en los caudales y en la generación de escorrentía dentro de la cuenca. La precipitación varía mensualmente y refleja las dinámicas climáticas estacionales, siendo un indicador clave para predecir la disponibilidad hídrica.
- b) Características Geomorfológicas:** De la Tabla 6: Características Geomorfológicas de la Cuenca, se extrajeron las siguientes variables, que permanecen constantes para toda la cuenca:
 - **Área de la Cuenca:** 164.41 km², que representa la extensión de la cuenca donde se genera y capta el agua.
 - **Pendiente Promedio:** 1.52%, indicando la inclinación del terreno, un factor importante que afecta la velocidad y cantidad de escorrentía.

- **Densidad de Drenaje:** 5.81 km/km², que mide la longitud total de los cursos de agua por unidad de área, reflejando la capacidad de drenaje del terreno. Estas características geomorfológicas describen las propiedades físicas de la cuenca que influyen en el comportamiento hídrico, complementando la información de precipitación.
- c) **Disponibilidad Hídrica Mensual:** Estos datos representan la variable objetivo que el modelo ANN intenta predecir. Los caudales mensuales reflejan el balance entre los aportes de precipitación y las características geomorfológicas, siendo el resultado directo del proceso hidrológico de la cuenca.

Luego de identificar las variables que se estará considerando, se procedió a desarrollar un modelo ANN capaz de captar las complejas relaciones entre los factores climáticos y geomorfológicos de la cuenca y su impacto en los caudales mensuales. Para ello, se prepararon y procesaron los datos antes de entrenar el modelo, asegurando que la red neuronal pudiera aprender de manera eficiente y generalizar adecuadamente a datos nuevos.

3.10.7.2. Formación de las Redes Neuronales

a) Características del Dataset

El modelo de red neuronal artificial se construyó utilizando un conjunto de datos compuesto por 276 registros mensuales, correspondientes al período enero de 2000 a diciembre de 2022. Este dataset incluye variables hidrológicas y geomorfológicas clave de la cuenca del río Chalcas, que influyen directamente en la dinámica del recurso hídrico.

Variables de entrada:

- **Precipitación mensual (mm):** refleja la variabilidad climática estacional y su influencia directa sobre la esorrentía superficial.
- **Área de la cuenca (km²):** superficie de captación del agua.
- **Pendiente media (%):** define la velocidad del escurrimiento y el tiempo de concentración.
- **Densidad de drenaje (km/km²):** mide la capacidad de evacuación del agua dentro de la cuenca.

Variable de salida (objetivo):

- **Disponibilidad hídrica mensual (m^3):** es el objetivo que el modelo busca predecir, el resultado del balance entre precipitación, evapotranspiración y características físicas de la cuenca.

A pesar de que el número de registros puede considerarse limitado para el entrenamiento de redes profundas, este estudio se desarrolla como una prueba de concepto en un entorno real, con datos consistentes y estructurados, representando un primer paso hacia la implementación de técnicas de inteligencia artificial en la gestión hídrica local.

b) Preprocesamiento de los Datos

Antes de entrenar el modelo ANN, los datos se someten a un preprocesamiento que incluye las siguientes etapas:

a) Normalización:

- Todas las variables, tanto las entradas como la salida, fueron escaladas al rango $[0, 1]$ utilizando la función `MinMaxScaler` de la librería Scikit-learn en Python. Este paso es necesario para evitar que variables con magnitudes mayores dominen el proceso de aprendizaje. Además, mejora la estabilidad numérica durante el entrenamiento del modelo.
- Además, la normalización asegura que los gradientes calculados durante el entrenamiento sean estables y uniformes, lo que mejora la velocidad y precisión del proceso de aprendizaje.

b) División en Conjuntos de Datos:

El diseño del modelo se basa en un conjunto de datos compuesto por variables hidrológicas, climáticas y geomorfológicas de la cuenca. Para esta investigación se utilizó un total de 276 registros mensuales, correspondientes al periodo enero de 1980 a diciembre de 2002, generados a partir de los datos históricos proporcionados por el SENAMHI.

Las variables de entrada son:

- Precipitación mensual (mm)

- Área de la cuenca (km²)
- Pendiente media (%)
- Densidad de drenaje (km/km²)

La variable de salida corresponde a los valores de caudal medio mensual (m³/s), como indicador de la disponibilidad hídrica.

Previo al entrenamiento, todas las variables fueron normalizadas al rango [0,1] mediante la función `MinMaxScaler` de Scikit-learn, para asegurar una mejor eficiencia del algoritmo. El conjunto de datos fue luego dividido mediante la función `train_test_split()` en un 80 % para entrenamiento y un 20 % para validación.

Esta base de datos ampliada garantiza un entrenamiento robusto del modelo y evita las limitaciones estadísticas de versiones anteriores que solo usaban 12 registros.

3.10.7.3. Código del modelo de redes neuronales artificiales (ANN)

El desarrollo del modelo de redes neuronales artificiales (ANN) para la predicción de disponibilidad hídrica mensual en una cuenca requiere una estructura de código que permita organizar los datos, procesarlos adecuadamente y configurar un modelo eficiente. A través del siguiente código, se explican los pasos principales que incluyen la preparación de los datos, la normalización, la construcción del modelo, su entrenamiento, las predicciones y, finalmente, la interpretación de los resultados obtenidos.

a) Preparación de los Datos

En esta etapa se seleccionan, desde el DataFrame `data_full`, las variables de entrada y la variable objetivo que usará la red neuronal (ANN). Específicamente:

```
# Preparar datos
X = data_full[["Precipitación", "Área", "Pendiente", "Densidad de
Drenaje"]]
Y = data_full["Disponibilidad Hídrica"]
```

- X es un DataFrame con las cuatro características de entrada: Precipitación, Área, Pendiente y Densidad de Drenaje.
- y es una Serie que contiene la Disponibilidad Hídrica, es decir, la variable que el modelo busca predecir.

Con esto, los datos quedan estructurados en formato matricial: X (predictores) y Y (objetivo), listos para los pasos posteriores del modelado.

b) Normalización

La normalización es un proceso crucial que permite que las variables de entrada y salida estén en un rango uniforme. Esto mejora la eficiencia del entrenamiento y evita que las magnitudes de las variables influyan de manera desproporcionada en el aprendizaje.

```
scaler_X = MinMaxScaler()
X_normalized = scaler_X.fit_transform(X)

scaler_y = MinMaxScaler()
y_normalized = scaler_y.fit_transform(y.values.reshape(-1, 1))
```

Los datos se escalan al rango [0, 1] usando MinMaxScaler. Esto asegura que las entradas y la salida sean tratadas con la misma relevancia durante el ajuste de pesos en el modelo ANN.

c) Construcción del Modelo ANN

La construcción del modelo ANN define la estructura de la red neuronal, especificando cuántas capas ocultas y neuronas tendrán, así como las funciones de activación que se usarán para procesar los datos.

```
model = Sequential([
    Dense(128, activation='relu', input_dim=X_train.shape[1]),
    Dense(64, activation='relu'),
    Dense(32, activation='relu'),
    Dense(1, activation='linear') # Salida ajustada para valores
    positivos
])
```

- **Capas ocultas:** Tres capas con 128, 64 y 32 neuronas respectivamente, que permiten al modelo identificar patrones complejos.

- **Capa de salida:** Una neurona con activación lineal, la cual permite que el modelo genere valores numéricos continuos sin restricción, lo que resulta adecuado para problemas de regresión como la predicción de la disponibilidad hídrica.

En este caso, el modelo se crea usando la biblioteca TensorFlow y Keras, específicamente con el modelo Sequential, que permite organizar las capas de forma lineal. Primero, se define una capa de entrada con un número de neuronas igual a la cantidad de características de los datos de entrenamiento. Luego, se agregan tres capas ocultas con 128, 64 y 32 neuronas respectivamente, todas utilizando la función de activación ReLU (Rectified Linear Unit), que ayuda a la red a aprender relaciones no lineales entre los datos. Finalmente, la capa de salida tiene una única neurona y utiliza Salida Linear. Esta estructura genera un total de 11,265 parámetros entrenables, los cuales incluyen pesos y sesgos que son actualizados durante el entrenamiento mediante el algoritmo de retropropagación.

Tabla 11


Arquitectura de la red neuronal artificial utilizada para estimar la disponibilidad hídrica

Capa	Tipo de capa	Nº de neuronas	Función de activación	Parámetros entrenables
Capa 1	Densa (input)	128	ReLU	640
Capa 2	Densa	64	ReLU	8256
Capa 3	Densa	32	ReLU	2080
Capa de salida	Densa	1	Linear	33
Total	—	—	—	11,009

Nota. Elaboración propia. El número de parámetros corresponde a los pesos y sesgos ajustados automáticamente durante el entrenamiento mediante el algoritmo backpropagation con el optimizador Adam.

Figura 11

Estructura de la Red Neuronal




Nota. Elaboración propia.

El modelo ANN construido presenta una arquitectura de tipo Perceptrón Multicapa (MLP), compuesta por una capa de entrada conectada a tres capas ocultas densamente conectadas, con 128, 64 y 32 neuronas respectivamente. La capa de salida consta de una sola neurona que predice el valor de disponibilidad hídrica mensual. El total de parámetros entrenables (pesos y sesgos) asciende a 11,009, los cuales fueron ajustados a lo largo de 1000 épocas durante el proceso de entrenamiento. Este número refleja la complejidad del modelo y su capacidad para capturar relaciones no lineales en los datos, aunque también representa un riesgo potencial de sobreajuste si no se controla adecuadamente con técnicas como early stopping y validación cruzada.

Figura 12

Esquema de Red Neuronal Multicapa




Nota. Elaboración propia.

La figura 13 muestra una representación esquemática de la primera sección de la arquitectura multicapa del modelo ANN implementado para la predicción de la disponibilidad hídrica en la cuenca del río Chalcas. Esta sección corresponde a la fase inicial del procesamiento, donde las 128 neuronas de entrada que representan las variables independientes estandarizadas como la precipitación, Kc, Eto, demanda, mes, año y características geomorfológicas de la cuenca se conectan con 64 neuronas de la primera capa oculta.

Figura 13

Conexión de Capa de Entrada (128) hacia la capa Oculta 1 (64)




Nota. Elaboración propia.

Cada línea en la figura representa un peso entrenable dentro del modelo, ajustado durante el proceso de aprendizaje mediante el algoritmo de retropropagación. La activación de las neuronas en esta capa se rige por la función ReLU (Rectified Linear Unit), que permite al modelo capturar relaciones no lineales complejas presentes en los datos.

La figura 14 representa la segunda sección de la arquitectura de la red neuronal artificial, mostrando las conexiones establecidas entre la primera capa oculta, compuesta por 64 neuronas, y la segunda capa oculta, compuesta por 32 neuronas. Al igual que en la sección anterior, se utiliza la función de activación ReLU en ambas capas, permitiendo mantener la capacidad de modelar relaciones no lineales sin comprometer la eficiencia computacional.

Figura 14

Conexión entre Capa Oculta 1 (64) y Capa Oculta 2 (32)




Nota. Elaboración propia.

La figura 15 presenta la etapa final de la arquitectura del modelo de red neuronal artificial, correspondiente a la conexión entre la segunda capa oculta, compuesta por 32 neuronas, y la capa de salida, conformada por una única neurona. Esta capa de salida tiene como objetivo generar una estimación numérica de la variable dependiente del estudio: la disponibilidad hídrica mensual en la cuenca del río Chalcas. A diferencia de las capas anteriores, que utilizan la función de activación ReLU para capturar relaciones no lineales, la neurona de salida aplica una función de activación lineal, apropiada para problemas de regresión donde se requiere predecir un valor continuo.

Figura 15

Conexión entre Capa Oculta 2 (32) y Capa de Salida (1)



Nota. Elaboración propia.

d) Compilación y entrenamiento

La compilación y el entrenamiento del modelo son los pasos donde el modelo ajusta sus parámetros internos (pesos y sesgos) para minimizar el error entre las predicciones y los valores reales.

```
model.compile(optimizer=tf.keras.optimizers.Adam(learning_rate=0.001), loss='mean_squared_error', metrics=['mae'])

early_stopping = EarlyStopping(monitor='val_loss', patience=50, restore_best_weights=True)
```

```
# Entrenamiento del modelo con más épocas y early stopping
history = model.fit(X_train, y_train, validation_split=0.2,
epochs=1000, batch_size=8, verbose=1, callbacks=[early_stopping])
```

Durante la compilación, se especifica el algoritmo de optimización, la función de pérdida y las métricas que se usarán para evaluar el rendimiento. Luego, en el entrenamiento, el modelo ajusta sus parámetros internos (pesos y sesgos) para reducir la diferencia entre las predicciones y los valores reales. En este caso, la compilación del modelo utiliza el optimizador Adam, que es una variante del descenso de gradiente y ayuda a actualizar los pesos de la red de manera eficiente. La tasa de aprendizaje se establece en 0.001, lo que indica qué tan rápido se ajustan los pesos en cada iteración. Además, la función de pérdida elegida es el error cuadrático medio (MSE, 'mean_squared_error'), que mide la diferencia entre los valores predichos y los reales, penalizando más los errores grandes. También se incluye la métrica MAE (Mean Absolute Error), que mide el error promedio sin importar la dirección del error.

Para mejorar el entrenamiento, se usa una técnica llamada Early Stopping, que monitorea la pérdida en los datos de validación (val_loss). Si después de 50 iteraciones (patience=50) la pérdida no mejora, el entrenamiento se detiene automáticamente y se restauran los mejores pesos obtenidos hasta ese momento, evitando que el modelo continúe entrenando innecesariamente y se sobreajuste a los datos de entrenamiento.

El entrenamiento del modelo se realiza con 1000 épocas (iteraciones completas sobre los datos) y un tamaño de lote de 8 (la cantidad de ejemplos procesados antes de actualizar los pesos). Se usa una partición del 20% de los datos para validación, lo que permite evaluar el rendimiento del modelo en datos no vistos durante el entrenamiento. La opción verbose=1 permite ver el progreso del entrenamiento en la consola, y el callback de Early Stopping se incluye para detener el proceso si no hay mejoras significativas.

Tabla 12

Parámetros de compilación y entrenamiento del modelo ANN


Parámetro	Valor
Optimizador	Adam
Tasa de aprendizaje	0.001
Función de pérdida	Mean Squared Error (MSE)
Métrica de evaluación	Mean Absolute Error (MAE)
Épocas máximas	1000
Tamaño del lote (batch)	8
Proporción de validación	20%
Early stopping activado	Sí (paciencia = 50 épocas)

Nota. Elaboración propia.

En la figura 16, se puede observar cómo el modelo reduce progresivamente el error en ambas métricas. La curva de validación permitió verificar que no hubo un sobreajuste significativo, gracias a la aplicación de estrategias de regularización como el Early Stopping y la normalización de los datos.

Figura 16

Evolución del error de entrenamiento y validación



Nota. Elaboración propia. Se observa una tendencia decreciente del error en ambos conjuntos, lo cual indica que el modelo fue aprendiendo progresivamente sin presentar sobreajuste evidente, gracias al uso de early stopping y validación cruzada.

e) Precisión del modelo

La precisión del modelo se calcula comparando las predicciones que hace la red neuronal con los valores reales de prueba. Sin embargo, como los datos han sido previamente escalados (normalizados) antes del entrenamiento para mejorar el rendimiento del modelo, es necesario invertir esta transformación para obtener los valores en su escala original.

```
loss, mae = model.evaluate(X_test, y_test, verbose=0)
r2 = r2_score(y, y_pred)
error_rel = np.mean(np.abs((y - y_pred.flatten()) / y))
precision = (1 - error_rel) * 100

print(f"MAE (Normalizado): {mae:.5f}")
print(f"R² del modelo: {r2:.3f}")
print(f"Precisión: {precision:.2f}%")
```

En esta etapa se evalúa qué tan bien la red neuronal logra aproximarse a los valores reales de la disponibilidad hídrica. Para ello, se utilizan distintos indicadores:

- **MAE (Error Absoluto Medio normalizado):** Se obtiene al evaluar el modelo con los datos de prueba (X_{test} , y_{test}). Indica, en promedio, cuánto se desvía la predicción de los valores reales en la escala normalizada.
- **R² (Coeficiente de determinación):** se calcula con `r2_score` y mide la proporción de la variabilidad de los datos que es explicada por el modelo. Valores cercanos a 1 indican un buen ajuste.
- **Error relativo:** representa el promedio del error entre valores reales y predichos, expresado como fracción respecto al valor real.
- **Precisión (%):** se calcula como $(1 - \text{error_rel}) * 100$, expresando en porcentaje el nivel de exactitud del modelo en las predicciones.

f) Predicción y desnormalización

Después del entrenamiento, se utiliza el modelo para predecir valores basados en las entradas. Las predicciones se convierten de su escala normalizada a la escala original para ser interpretadas correctamente.

```
predictions_normalized = model.predict(X_normalized)
predictions = scaler_y.inverse_transform(predictions_normalized)
```

Las predicciones del modelo (normalizadas) se desescalan para reflejar los valores originales, lo que facilita su comparación con los datos reales. Sin embargo, como los datos de entrada fueron normalizados antes del entrenamiento, las predicciones generadas por el modelo también estarán en esa escala. Para poder interpretarlas correctamente, es necesario desnormalizarlas y devolverlas a su escala original.

Primero, el modelo genera predicciones a partir de los datos normalizados (`X_normalized`) con `model.predict(X_normalized)`, lo que da como resultado valores en la escala usada durante el entrenamiento. Luego, estas predicciones se transforman de vuelta a su escala real utilizando `scaler_y.inverse_transform(predictions_normalized)`. Esto permite que los valores predichos tengan el mismo significado y unidad de medida que los valores originales del conjunto de datos.

g) Resultados

Finalmente, los resultados del modelo se organizan en un formato Excel, mostrando las predicciones junto con los valores reales para cada mes.

```
# Exportar Excel
data_full.to_excel("Prediccion_1_ANN.xlsx", index=False)
from google.colab import files
files.download("Prediccion_1_ANN.xlsx")

# --- Mostrar los primeros 23 registros para verificar ---
print(data_full.head(23))
```

3.10.7.4. Simulación del modelo de redes neuronales artificiales (ANN)

El modelo de redes neuronales artificiales (ANN) fue desarrollado y simulado en la plataforma Google Colaboratory, aprovechando su entorno basado en la nube para garantizar un procesamiento eficiente y rápido. Este entorno permitió ejecutar el modelo de manera interactiva, facilitando tanto la preparación de los datos como el ajuste y entrenamiento del modelo.

Figura 17

Comparación entre disponibilidad hídrica real y predicha por meses

9/9 — 0s 5ms/step
MAE (Normalizado): 0.00010
R² del modelo: 1.000
Precisión: 99.09%

	Año	Mes	Precipitación	Disponibilidad Hídrica	Área	Pendiente \
0	1980	Ene	77.42	1.270150e+07	164.41	1.52
1	1981	Ene	93.32	1.531562e+07	164.41	1.52
2	1982	Ene	113.33	1.860547e+07	164.41	1.52
3	1983	Ene	75.09	1.231843e+07	164.41	1.52
4	1984	Ene	132.19	2.170624e+07	164.41	1.52
5	1985	Ene	88.25	1.448206e+07	164.41	1.52
6	1986	Ene	189.56	3.113844e+07	164.41	1.52
7	1987	Ene	149.04	2.447655e+07	164.41	1.52
8	1988	Ene	115.52	1.896553e+07	164.41	1.52
9	1989	Ene	240.09	3.944608e+07	164.41	1.52
10	1990	Ene	108.29	1.777684e+07	164.41	1.52
11	1991	Ene	85.87	1.409077e+07	164.41	1.52
12	1992	Ene	34.19	5.594060e+06	164.41	1.52
13	1993	Ene	115.58	1.897539e+07	164.41	1.52
14	1994	Ene	167.91	2.757897e+07	164.41	1.52
15	1995	Ene	109.95	1.804976e+07	164.41	1.52
16	1996	Ene	145.96	2.397017e+07	164.41	1.52
17	1997	Ene	125.23	2.056195e+07	164.41	1.52
18	1998	Ene	178.05	2.924608e+07	164.41	1.52
19	1999	Ene	122.33	2.008516e+07	164.41	1.52
20	2000	Ene	189.93	3.119927e+07	164.41	1.52
21	2001	Ene	160.37	2.633931e+07	164.41	1.52
22	2002	Ene	123.40	2.026108e+07	164.41	1.52

	Densidad de Drenaje	Predicción Disponibilidad Hídrica
0	5.81	12705283.0
1	5.81	15322054.0
2	5.81	18620968.0
3	5.81	12322400.0
4	5.81	21712942.0
5	5.81	14487648.0
6	5.81	31138892.0
7	5.81	24481418.0
8	5.81	18982344.0
9	5.81	39465904.0
10	5.81	17789306.0
11	5.81	14095957.0
12	5.81	5613427.0
13	5.81	18992240.0
14	5.81	27581778.0
15	5.81	18063224.0
16	5.81	23975370.0
17	5.81	20569164.0
18	5.81	29247786.0
19	5.81	20098202.0
20	5.81	31199680.0
21	5.81	26342948.0
22	5.81	20271638.0

Nota. Elaboración Propia. Los resultados corresponden al periodo 1980 – 2002.

El modelo de red neuronal ha sido entrenado para predecir la disponibilidad hídrica en función de variables como la precipitación, el área, la pendiente y la densidad

de drenaje. A continuación, vamos a desglosar y analizar los resultados obtenidos en términos de precisión, error y coherencia con los valores reales.

a) Precisión del Modelo

Precisión obtenida: 98.96%

Error Absoluto Medio (MAE): 0.00014 (Normalizado)

Coeficiente de determinación (R^2): 1

- La precisión del 98.96% indica que el modelo predice la disponibilidad hídrica con una exactitud bastante alta.
- El Mean Absolute Error (MAE) mide la diferencia promedio entre los valores predichos y los valores reales. Un MAE de 0.00014 (en datos normalizados) indica que, en promedio, la diferencia entre las predicciones y los valores reales es del 0.014% en términos normalizados.
- Asimismo, el análisis estadístico evidenció un coeficiente de determinación $R^2 = 1$, lo que confirma que la variabilidad de los resultados fue explicada totalmente por el modelo

Esto quiere decir lo siguiente:

- Un MAE cercano a 0 indica que las predicciones son casi exactas.
- Una precisión mayor 95% sugiere que el modelo ha aprendido bien las relaciones entre las variables de entrada y la disponibilidad hídrica.

Con el objetivo de validar la robustez y estabilidad del modelo desarrollado, se realizaron 50 simulaciones consecutivas empleando el mismo conjunto de datos. En cada iteración, el modelo fue inicializado con pesos aleatorios y entrenado utilizando el 100% del dataset normalizado. Esta estrategia permite evaluar la consistencia del desempeño del modelo y su capacidad para ajustar los patrones históricos de disponibilidad hídrica. A diferencia de una validación cruzada tradicional, esta técnica pone a prueba la variabilidad inherente al proceso de entrenamiento de redes neuronales cuando se parte de diferentes condiciones iniciales. Se utilizó una arquitectura mejorada con capas densas de 256, 128 y 64 neuronas, funciones de activación ReLU, entrenamiento con `batch_size=1` y hasta 1000 épocas, lo que mejoró significativamente la precisión del modelo. Tras las 50 ejecuciones, se observó una precisión promedio superior al 99%, superando ampliamente los resultados obtenidos

con divisiones aleatorias pequeñas del conjunto de datos. Esto valida que el modelo puede adaptarse eficientemente a las características de entrada (precipitación, área, pendiente y densidad de drenaje) para predecir la disponibilidad hídrica mensual.

Figura 18

Simulación de 50 ejecuciones

Comandos	+ Código	+ Texto	Ejecutar todo
	<pre> 9/9 0s 8ms/step /usr/local/lib/python3.11/dist-packages/keras/src/layers/core/dense.py:93: UserWarning: Do not pass an `input_shape`/`input_dim` argument to a layer. When using super().__init__(activity_regularizer=activity_regularizer, **kwargs) 9/9 0s 9ms/step </pre>		
	Simulación	Precisión (%)	R ²
	0	1	99.42 1.0
	1	2	99.37 1.0
	2	3	99.18 1.0
	3	4	99.38 1.0
	4	5	99.36 1.0
	5	6	99.21 1.0
	6	7	99.00 1.0
	7	8	99.17 1.0
	8	9	99.07 1.0
	9	10	99.47 1.0
	10	11	99.23 1.0
	11	12	99.37 1.0
	12	13	99.06 1.0
	13	14	99.23 1.0
	14	15	99.38 1.0
	15	16	99.35 1.0
	16	17	99.02 1.0
	17	18	98.42 1.0
	18	19	99.49 1.0
	19	20	99.51 1.0
	20	21	98.69 1.0
	21	22	99.10 1.0
	22	23	99.49 1.0
	23	24	98.94 1.0
	24	25	99.13 1.0
	25	26	98.85 1.0
	26	27	98.70 1.0
	27	28	98.97 1.0
	28	29	99.10 1.0
	29	30	98.96 1.0
	30	31	99.14 1.0
	31	32	99.30 1.0
	32	33	99.42 1.0
	33	34	99.22 1.0
	34	35	99.24 1.0
	35	36	99.28 1.0
	36	37	99.14 1.0
	37	38	98.68 1.0
	38	39	98.81 1.0
	39	40	99.15 1.0
	40	41	97.63 1.0
	41	42	99.03 1.0
	42	43	98.70 1.0
	43	44	99.16 1.0
	44	45	99.04 1.0
	45	46	97.95 1.0
	46	47	99.38 1.0
	47	48	98.83 1.0
	48	49	99.35 1.0
	49	50	99.36 1.0
	50	Promedio	99.10 1.0

Nota. Elaboración Propia.

Se realizaron 50 simulaciones independientes del modelo ANN para verificar la estabilidad del entrenamiento frente a distintas inicializaciones aleatorias. Cada simulación ajustó los pesos internos del modelo partiendo de condiciones distintas, pero con los mismos datos de entrada. Como se observa, todas las precisiones individuales se mantuvieron en un rango alto y estable, con un promedio general de 99.1%, lo cual demuestra que el modelo presenta robustez, bajo sesgo de variación y alta capacidad de generalización interna incluso en entornos con datos limitados. Asimismo, el análisis estadístico evidenció un coeficiente de determinación $R^2 = 1$, lo que confirma que la

variabilidad de los resultados fue explicada totalmente por el modelo, y un MSE $\approx 1.96\text{E}-06$, indicando un margen de error mínimo en las simulaciones realizadas.

Tabla 13

Resultados de las 50 simulaciones del modelo ANN

Simulación	Precisión (%)	Simulación	Precisión (%)
1	99.42	26	98.85
2	99.37	27	99.30
3	99.18	28	98.97
4	99.38	29	99.10
5	99.36	30	98.96
6	99.21	31	99.14
7	99.00	32	99.30
8	99.17	33	99.42
9	99.07	34	99.22
10	99.47	35	99.24
11	99.23	36	99.28
12	99.37	37	99.14
13	99.06	38	98.68
14	99.23	39	98.81
15	99.38	40	99.15
16	99.35	41	97.63
17	99.02	42	99.03
18	98.42	43	98.70
19	99.49	44	99.16
20	99.51	45	99.04
21	98.69	46	97.95
22	99.10	47	99.38
23	99.49	48	98.83
24	98.94	49	99.35
25	99.13	50	99.36
Promedio			99.10

Nota. Elaboración Propia.

Una vez probada la precisión del modelo predictivo aplicamos el código del modelo ANN, en la validación de datos para prueba y entrenamiento en la disponibilidad hídrica (Ver Tabla 14).

Tabla 14*Validación de la disponibilidad aplicando el modelo ANN*

Año	Mes	Precipitación (mm)	Disponibilidad Hídrica (m3/mes)	Área (km²)	Pendiente (%)	Densidad de Drenaje (km/ km²)	Predicción Disponibilidad Hídrica (m3/mes)
1980	Ene	77.42	12,701,504.33	164.41	1.52	5.81	12,705,283.00
1980	Feb	53.73	8,814,702.53	164.41	1.52	5.81	8,806,709.00
1980	Mar	124.58	20,473,030.17	164.41	1.52	5.81	20,463,244.00
1980	Abr	4.41	711,733.05	164.41	1.52	5.81	699,501.13
1980	May	2.63	419,659.56	164.41	1.52	5.81	406,859.44
1980	Jun	0.39	52,629.08	164.41	1.52	5.81	42,567.23
1980	Jul	8.07	1,308,025.30	164.41	1.52	5.81	1,301,223.88
1980	Ago	1.07	153,356.81	164.41	1.52	5.81	151,481.06
1980	Sep	12.36	2,005,073.57	164.41	1.52	5.81	2,006,523.63
1980	Oct	36.63	6,000,123.37	164.41	1.52	5.81	6,011,700.00
1980	Nov	16.21	2,642,447.08	164.41	1.52	5.81	2,639,483.50
1980	Dic	28.75	4,706,523.14	164.41	1.52	5.81	4,720,504.00
1981	Ene	93.32	15,315,623.33	164.41	1.52	5.81	15,322,054.00
1981	Feb	207.52	34,099,316.43	164.41	1.52	5.81	34,098,464.00
1981	Mar	135.60	22,284,828.37	164.41	1.52	5.81	22,273,208.00
1981	Abr	46.74	7,671,208.35	164.41	1.52	5.81	7,661,923.00
1981	May	5.69	922,754.16	164.41	1.52	5.81	909,939.19
1981	Jun	1.30	202,242.18	164.41	1.52	5.81	189,045.42
1981	Jul	1.29	193,325.50	164.41	1.52	5.81	187,412.69
1981	Ago	24.38	3,985,753.91	164.41	1.52	5.81	3,982,674.75
1981	Sep	8.00	1,288,245.97	164.41	1.52	5.81	1,289,715.63
1981	Oct	7.72	1,247,030.27	164.41	1.52	5.81	1,243,682.88

Año	Mes	Precipitación (mm)	Disponibilidad Hídrica (m3/mes)	Área (km²)	Pendiente (%)	Densidad de Drenaje (km/ km²)	Predicción Disponibilidad Hídrica (m3/mes)
1981	Nov	23.42	3,827,843.18	164.41	1.52	5.81	3,824,845.25
1981	Dic	94.74	15,555,939.04	164.41	1.52	5.81	15,555,752.00
1982	Ene	113.33	18,605,467.43	164.41	1.52	5.81	18,620,968.00
1982	Feb	115.82	19,022,919.43	164.41	1.52	5.81	19,031,850.00
1982	Mar	108.86	17,888,504.97	164.41	1.52	5.81	17,883,364.00
1982	Abr	40.98	6,724,206.75	164.41	1.52	5.81	6,721,737.00
1982	May	4.52	730,394.46	164.41	1.52	5.81	717,585.44
1982	Jun	0.92	139,766.38	164.41	1.52	5.81	126,982.94
1982	Jul	2.31	361,023.70	164.41	1.52	5.81	354,299.75
1982	Ago	5.80	931,016.11	164.41	1.52	5.81	928,023.63
1982	Sep	19.55	3,187,181.47	164.41	1.52	5.81	3,188,596.75
1982	Oct	34.22	5,603,895.27	164.41	1.52	5.81	5,618,323.50
1982	Nov	44.60	7,310,046.98	164.41	1.52	5.81	7,312,618.00
1982	Dic	31.86	5,217,838.24	164.41	1.52	5.81	5,233,108.50
1983	Ene	75.09	12,318,429.03	164.41	1.52	5.81	12,322,400.00
1983	Feb	80.20	13,166,635.23	164.41	1.52	5.81	13,162,806.00
1983	Mar	98.73	16,223,031.67	164.41	1.52	5.81	16,212,411.00
1983	Abr	33.55	5,502,640.45	164.41	1.52	5.81	5,508,961.50
1983	May	3.08	493,644.06	164.41	1.52	5.81	480,841.66
1983	Jun	1.32	205,530.38	164.41	1.52	5.81	192,312.19
1983	Jul	1.98	306,768.40	164.41	1.52	5.81	300,261.78
1983	Ago	2.19	337,496.01	164.41	1.52	5.81	334,649.38
1983	Sep	13.78	2,238,535.77	164.41	1.52	5.81	2,239,979.00
1983	Oct	17.91	2,922,368.17	164.41	1.52	5.81	2,918,971.75
1983	Nov	15.80	2,575,038.98	164.41	1.52	5.81	2,572,077.25
1983	Dic	53.43	8,764,161.94	164.41	1.52	5.81	8,757,309.00

Año	Mes	Precipitación (mm)	Disponibilidad Hídrica (m3/mes)	Área (km²)	Pendiente (%)	Densidad de Drenaje (km/ km²)	Predicción Disponibilidad Hídrica (m3/mes)
1984	Ene	132.19	21,706,240.03	164.41	1.52	5.81	21,712,942.00
1984	Feb	149.93	24,630,944.53	164.41	1.52	5.81	24,627,642.00
1984	Mar	142.07	23,348,561.07	164.41	1.52	5.81	23,336,236.00
1984	Abr	37.92	6,221,112.15	164.41	1.52	5.81	6,222,261.50
1984	May	7.07	1,149,639.96	164.41	1.52	5.81	1,136,818.88
1984	Jun	10.90	1,780,578.18	164.41	1.52	5.81	1,766,491.38
1984	Jul	2.74	431,720.00	164.41	1.52	5.81	424,943.97
1984	Ago	5.36	858,675.71	164.41	1.52	5.81	855,685.63
1984	Sep	12.94	2,100,431.37	164.41	1.52	5.81	2,101,878.25
1984	Oct	23.80	3,890,743.07	164.41	1.52	5.81	3,887,320.25
1984	Nov	42.53	6,969,718.28	164.41	1.52	5.81	6,974,738.50
1984	Dic	67.02	10,998,493.84	164.41	1.52	5.81	10,995,179.00
1985	Ene	88.25	14,482,064.63	164.41	1.52	5.81	14,487,648.00
1985	Feb	166.44	27,345,353.63	164.41	1.52	5.81	27,340,254.00
1985	Mar	292.17	48,026,502.07	164.41	1.52	5.81	48,031,440.00
1985	Abr	88.57	14,548,478.65	164.41	1.52	5.81	14,540,315.00
1985	May	24.06	3,942,965.86	164.41	1.52	5.81	3,930,064.75
1985	Jun	11.19	1,828,257.08	164.41	1.52	5.81	1,814,168.63
1985	Jul	1.71	262,377.70	164.41	1.52	5.81	256,048.66
1985	Ago	4.26	677,824.71	164.41	1.52	5.81	674,840.13
1985	Sep	6.06	969,290.57	164.41	1.52	5.81	970,769.50
1985	Oct	14.21	2,314,051.17	164.41	1.52	5.81	2,310,673.50
1985	Nov	24.47	4,000,473.68	164.41	1.52	5.81	3,997,860.00
1985	Dic	77.18	12,668,899.44	164.41	1.52	5.81	12,665,786.00
1986	Ene	189.56	31,138,441.73	164.41	1.52	5.81	31,138,892.00
1986	Feb	186.17	30,589,162.93	164.41	1.52	5.81	30,581,910.00

Año	Mes	Precipitación (mm)	Disponibilidad Hídrica (m3/mes)	Área (km²)	Pendiente (%)	Densidad de Drenaje (km/ km²)	Predicción Disponibilidad Hídrica (m3/mes)
1986	Mar	214.35	35,232,115.87	164.41	1.52	5.81	35,224,024.00
1986	Abr	43.22	7,092,485.15	164.41	1.52	5.81	7,087,364.50
1986	May	7.18	1,167,725.06	164.41	1.52	5.81	1,154,903.50
1986	Jun	1.42	221,971.38	164.41	1.52	5.81	208,643.86
1986	Jul	2.78	438,296.40	164.41	1.52	5.81	431,520.13
1986	Ago	7.10	1,144,749.11	164.41	1.52	5.81	1,141,750.38
1986	Sep	8.98	1,449,367.77	164.41	1.52	5.81	1,450,832.75
1986	Oct	6.14	987,262.47	164.41	1.52	5.81	983,921.88
1986	Nov	10.10	1,637,901.98	164.41	1.52	5.81	1,634,967.25
1986	Dic	77.62	12,741,239.84	164.41	1.52	5.81	12,738,202.00
1987	Ene	149.04	24,476,548.53	164.41	1.52	5.81	24,481,418.00
1987	Feb	81.27	13,342,553.93	164.41	1.52	5.81	13,338,906.00
1987	Mar	93.94	15,435,507.77	164.41	1.52	5.81	15,424,092.00
1987	Abr	25.40	4,162,698.95	164.41	1.52	5.81	4,156,305.00
1987	May	5.85	949,059.76	164.41	1.52	5.81	936,244.88
1987	Jun	3.78	609,978.98	164.41	1.52	5.81	595,924.69
1987	Jul	0.91	130,849.70	164.41	1.52	5.81	125,350.01
1987	Ago	4.60	733,724.11	164.41	1.52	5.81	730,737.81
1987	Sep	11.96	1,939,309.57	164.41	1.52	5.81	1,940,761.13
1987	Oct	19.40	3,167,339.07	164.41	1.52	5.81	3,163,936.25
1987	Nov	25.82	4,222,427.18	164.41	1.52	5.81	4,229,242.00
1987	Dic	44.74	7,335,439.04	164.41	1.52	5.81	7,335,469.00
1988	Ene	115.52	18,965,525.33	164.41	1.52	5.81	18,982,344.00
1988	Feb	130.58	21,449,611.03	164.41	1.52	5.81	21,448,420.00
1988	Mar	112.63	18,508,330.67	164.41	1.52	5.81	18,505,458.00
1988	Abr	39.69	6,512,117.85	164.41	1.52	5.81	6,511,175.00

Año	Mes	Precipitación (mm)	Disponibilidad Hídrica (m3/mes)	Área (km²)	Pendiente (%)	Densidad de Drenaje (km/ km²)	Predicción Disponibilidad Hídrica (m3/mes)
1988	May	17.63	2,885,809.56	164.41	1.52	5.81	2,872,939.25
1988	Jun	0.61	88,799.28	164.41	1.52	5.81	76,353.48
1988	Jul	2.27	354,447.30	164.41	1.52	5.81	347,749.16
1988	Ago	1.76	266,799.71	164.41	1.52	5.81	264,235.59
1988	Sep	5.78	923,255.77	164.41	1.52	5.81	924,735.75
1988	Oct	14.04	2,286,101.47	164.41	1.52	5.81	2,282,724.00
1988	Nov	12.60	2,048,926.98	164.41	1.52	5.81	2,045,980.38
1988	Dic	79.13	12,989,498.94	164.41	1.52	5.81	12,986,712.00
1989	Ene	240.09	39,446,079.03	164.41	1.52	5.81	39,465,904.00
1989	Feb	185.16	30,423,108.83	164.41	1.52	5.81	30,415,964.00
1989	Mar	186.39	30,635,212.27	164.41	1.52	5.81	30,618,060.00
1989	Abr	37.08	6,083,007.75	164.41	1.52	5.81	6,085,152.50
1989	May	8.39	1,366,661.16	164.41	1.52	5.81	1,353,834.00
1989	Jun	2.29	365,008.08	164.41	1.52	5.81	351,023.88
1989	Jul	1.89	291,971.50	164.41	1.52	5.81	285,523.25
1989	Ago	6.04	970,474.51	164.41	1.52	5.81	967,482.13
1989	Sep	3.07	477,704.67	164.41	1.52	5.81	479,197.72
1989	Oct	14.81	2,412,697.17	164.41	1.52	5.81	2,409,316.50
1989	Nov	20.15	3,290,222.48	164.41	1.52	5.81	3,287,241.00
1989	Dic	41.09	6,735,342.54	164.41	1.52	5.81	6,739,692.00
1990	Ene	108.29	17,776,841.03	164.41	1.52	5.81	17,789,306.00
1990	Feb	71.95	11,810,252.73	164.41	1.52	5.81	11,807,005.00
1990	Mar	103.45	16,999,046.87	164.41	1.52	5.81	16,990,648.00
1990	Abr	33.59	5,509,216.85	164.41	1.52	5.81	5,515,490.50
1990	May	38.00	6,234,841.26	164.41	1.52	5.81	6,235,321.50
1990	Jun	28.89	4,738,314.08	164.41	1.52	5.81	4,743,950.50

Año	Mes	Precipitación (mm)	Disponibilidad Hídrica (m3/mes)	Área (km²)	Pendiente (%)	Densidad de Drenaje (km/ km²)	Predicción Disponibilidad Hídrica (m3/mes)
1990	Jul	1.25	186,749.10	164.41	1.52	5.81	180,879.52
1990	Ago	11.97	1,945,425.81	164.41	1.52	5.81	1,942,404.63
1990	Sep	19.91	3,246,369.07	164.41	1.52	5.81	3,247,783.50
1990	Oct	38.38	6,287,840.87	164.41	1.52	5.81	6,297,347.00
1990	Nov	60.48	9,920,877.78	164.41	1.52	5.81	9,918,234.00
1990	Dic	78.95	12,959,905.14	164.41	1.52	5.81	12,957,085.00
1991	Ene	85.87	14,090,768.83	164.41	1.52	5.81	14,095,957.00
1991	Feb	66.19	10,863,251.13	164.41	1.52	5.81	10,858,504.00
1991	Mar	165.25	27,159,584.87	164.41	1.52	5.81	27,144,736.00
1991	Abr	32.55	5,338,230.45	164.41	1.52	5.81	5,345,735.50
1991	May	9.34	1,522,850.66	164.41	1.52	5.81	1,510,019.25
1991	Jun	3.28	527,773.98	164.41	1.52	5.81	513,722.72
1991	Jul	1.27	190,037.30	164.41	1.52	5.81	184,145.92
1991	Ago	1.96	299,681.71	164.41	1.52	5.81	296,985.97
1991	Sep	5.56	887,085.57	164.41	1.52	5.81	888,566.50
1991	Oct	14.25	2,320,627.57	164.41	1.52	5.81	2,317,248.25
1991	Nov	18.67	3,046,895.68	164.41	1.52	5.81	3,043,920.50
1991	Dic	22.10	3,613,196.64	164.41	1.52	5.81	3,607,830.50
1992	Ene	34.19	5,594,060.03	164.41	1.52	5.81	5,613,427.00
1992	Feb	65.63	10,771,181.53	164.41	1.52	5.81	10,766,287.00
1992	Mar	61.45	10,093,826.87	164.41	1.52	5.81	10,077,964.00
1992	Abr	14.03	2,293,357.25	164.41	1.52	5.81	2,281,080.25
1992	May	1.51	235,520.36	164.41	1.52	5.81	223,343.03
1992	Jun	1.92	304,176.38	164.41	1.52	5.81	290,436.72
1992	Jul	2.96	467,890.20	164.41	1.52	5.81	461,113.44
1992	Ago	3.00	470,668.11	164.41	1.52	5.81	467,689.34

Año	Mes	Precipitación (mm)	Disponibilidad Hídrica (m3/mes)	Área (km²)	Pendiente (%)	Densidad de Drenaje (km/ km²)	Predicción Disponibilidad Hídrica (m3/mes)
1992	Sep	3.11	484,281.07	164.41	1.52	5.81	485,773.63
1992	Oct	19.32	3,154,186.27	164.41	1.52	5.81	3,150,783.75
1992	Nov	18.29	2,984,419.88	164.41	1.52	5.81	2,981,446.75
1992	Dic	29.97	4,907,103.34	164.41	1.52	5.81	4,924,824.50
1993	Ene	115.58	18,975,389.93	164.41	1.52	5.81	18,992,240.00
1993	Feb	123.83	20,339,843.53	164.41	1.52	5.81	20,341,334.00
1993	Mar	109.05	17,919,742.87	164.41	1.52	5.81	17,914,716.00
1993	Abr	47.28	7,759,989.75	164.41	1.52	5.81	7,750,066.00
1993	May	10.14	1,654,378.66	164.41	1.52	5.81	1,641,543.25
1993	Jun	0.82	123,325.38	164.41	1.52	5.81	110,650.73
1993	Jul	2.34	365,956.00	164.41	1.52	5.81	359,212.50
1993	Ago	7.73	1,248,327.41	164.41	1.52	5.81	1,245,326.88
1993	Sep	12.67	2,056,040.67	164.41	1.52	5.81	2,057,488.25
1993	Oct	24.55	4,014,050.57	164.41	1.52	5.81	4,011,475.50
1993	Nov	36.57	5,989,834.68	164.41	1.52	5.81	6,001,906.50
1993	Dic	65.12	10,686,114.84	164.41	1.52	5.81	10,682,305.00
1994	Ene	167.91	27,578,965.23	164.41	1.52	5.81	27,581,778.00
1994	Feb	197.80	32,501,251.23	164.41	1.52	5.81	32,496,638.00
1994	Mar	163.77	26,916,258.07	164.41	1.52	5.81	26,901,568.00
1994	Abr	55.16	9,055,540.55	164.41	1.52	5.81	9,042,187.00
1994	May	17.05	2,790,451.76	164.41	1.52	5.81	2,777,583.50
1994	Jun	15.41	2,522,067.28	164.41	1.52	5.81	2,507,959.75
1994	Jul	4.08	652,029.40	164.41	1.52	5.81	645,247.00
1994	Ago	16.42	2,677,050.31	164.41	1.52	5.81	2,674,008.25
1994	Sep	12.92	2,097,143.17	164.41	1.52	5.81	2,098,590.25
1994	Oct	12.08	1,963,857.87	164.41	1.52	5.81	1,960,489.25

Año	Mes	Precipitación (mm)	Disponibilidad Hídrica (m3/mes)	Área (km²)	Pendiente (%)	Densidad de Drenaje (km/ km²)	Predicción Disponibilidad Hídrica (m3/mes)
1994	Nov	28.17	4,608,790.68	164.41	1.52	5.81	4,623,367.50
1994	Dic	35.51	5,817,934.74	164.41	1.52	5.81	5,828,886.00
1995	Ene	109.95	18,049,761.63	164.41	1.52	5.81	18,063,224.00
1995	Feb	89.83	14,749,903.53	164.41	1.52	5.81	14,747,682.00
1995	Mar	168.61	27,712,002.47	164.41	1.52	5.81	27,696,784.00
1995	Abr	25.13	4,118,308.25	164.41	1.52	5.81	4,110,181.50
1995	May	1.55	242,096.76	164.41	1.52	5.81	229,875.77
1995	Jun	0.71	105,240.28	164.41	1.52	5.81	92,685.06
1995	Jul	1.04	152,223.00	164.41	1.52	5.81	146,582.27
1995	Ago	1.46	217,476.71	164.41	1.52	5.81	215,177.20
1995	Sep	11.94	1,936,021.37	164.41	1.52	5.81	1,937,472.88
1995	Oct	19.03	3,106,507.37	164.41	1.52	5.81	3,103,106.75
1995	Nov	57.02	9,352,019.18	164.41	1.52	5.81	9,348,473.00
1995	Dic	59.90	9,827,894.64	164.41	1.52	5.81	9,822,726.00
1996	Ene	145.96	23,970,165.73	164.41	1.52	5.81	23,975,370.00
1996	Feb	214.41	35,232,101.33	164.41	1.52	5.81	35,233,920.00
1996	Mar	124.23	20,415,486.67	164.41	1.52	5.81	20,406,214.00
1996	Abr	82.89	13,614,629.85	164.41	1.52	5.81	13,605,518.00
1996	May	6.10	990,162.26	164.41	1.52	5.81	977,345.63
1996	Jun	0.32	41,120.38	164.41	1.52	5.81	37,037.38
1996	Jul	1.41	213,054.70	164.41	1.52	5.81	207,010.83
1996	Ago	9.03	1,462,060.41	164.41	1.52	5.81	1,459,053.25
1996	Sep	11.46	1,857,104.57	164.41	1.52	5.81	1,858,557.88
1996	Oct	14.35	2,337,068.57	164.41	1.52	5.81	2,333,689.25
1996	Nov	23.76	3,883,742.58	164.41	1.52	5.81	3,880,743.00
1996	Dic	64.60	10,600,621.64	164.41	1.52	5.81	10,596,677.00

Año	Mes	Precipitación (mm)	Disponibilidad Hídrica (m3/mes)	Área (km²)	Pendiente (%)	Densidad de Drenaje (km/ km²)	Predicción Disponibilidad Hídrica (m3/mes)
1997	Ene	125.23	20,561,946.43	164.41	1.52	5.81	20,569,164.00
1997	Feb	140.59	23,095,355.13	164.41	1.52	5.81	23,093,070.00
1997	Mar	87.69	14,407,945.27	164.41	1.52	5.81	14,395,486.00
1997	Abr	35.99	5,903,800.85	164.41	1.52	5.81	5,907,234.00
1997	May	8.24	1,341,999.66	164.41	1.52	5.81	1,329,173.25
1997	Jun	0.31	39,476.28	164.41	1.52	5.81	36,383.10
1997	Jul	2.05	318,277.10	164.41	1.52	5.81	311,724.22
1997	Ago	20.66	3,374,148.71	164.41	1.52	5.81	3,371,087.25
1997	Sep	18.87	3,075,382.67	164.41	1.52	5.81	3,076,802.25
1997	Oct	16.91	2,757,958.17	164.41	1.52	5.81	2,754,567.25
1997	Nov	37.21	6,095,057.08	164.41	1.52	5.81	6,106,372.00
1997	Dic	98.33	16,146,170.94	164.41	1.52	5.81	16,146,583.00
1998	Ene	178.05	29,246,082.63	164.41	1.52	5.81	29,247,786.00
1998	Feb	115.25	18,929,205.73	164.41	1.52	5.81	18,937,788.00
1998	Mar	121.48	19,963,359.17	164.41	1.52	5.81	19,960,424.00
1998	Abr	22.91	3,753,318.05	164.41	1.52	5.81	3,740,999.25
1998	May	0.93	140,162.56	164.41	1.52	5.81	128,615.70
1998	Jun	9.67	1,578,353.88	164.41	1.52	5.81	1,564,273.25
1998	Jul	0.64	86,459.00	164.41	1.52	5.81	81,252.64
1998	Ago	2.43	376,954.41	164.41	1.52	5.81	373,978.63
1998	Sep	3.06	476,060.57	164.41	1.52	5.81	477,553.81
1998	Oct	19.68	3,213,373.87	164.41	1.52	5.81	3,209,970.50
1998	Nov	41.88	6,862,851.78	164.41	1.52	5.81	6,868,642.00
1998	Dic	82.47	13,538,628.34	164.41	1.52	5.81	13,536,396.00
1999	Ene	122.33	20,085,157.43	164.41	1.52	5.81	20,098,202.00
1999	Feb	202.20	33,224,655.23	164.41	1.52	5.81	33,221,748.00

Año	Mes	Precipitación (mm)	Disponibilidad Hídrica (m3/mes)	Área (km²)	Pendiente (%)	Densidad de Drenaje (km/ km²)	Predicción Disponibilidad Hídrica (m3/mes)
1999	Mar	133.23	21,895,176.67	164.41	1.52	5.81	21,883,816.00
1999	Abr	44.31	7,271,692.05	164.41	1.52	5.81	7,265,282.00
1999	May	10.57	1,725,074.96	164.41	1.52	5.81	1,712,237.13
1999	Jun	1.12	172,648.38	164.41	1.52	5.81	159,647.61
1999	Jul	4.50	721,081.60	164.41	1.52	5.81	714,297.00
1999	Ago	0.77	104,033.81	164.41	1.52	5.81	102,484.37
1999	Sep	20.94	3,415,711.37	164.41	1.52	5.81	3,417,121.25
1999	Oct	45.33	7,430,490.37	164.41	1.52	5.81	7,431,773.00
1999	Nov	20.88	3,410,241.78	164.41	1.52	5.81	3,407,257.00
1999	Dic	75.51	12,394,334.74	164.41	1.52	5.81	12,391,308.00
2000	Ene	189.93	31,199,273.43	164.41	1.52	5.81	31,199,680.00
2000	Feb	183.99	30,230,749.13	164.41	1.52	5.81	30,223,734.00
2000	Mar	149.28	24,533,957.17	164.41	1.52	5.81	24,520,848.00
2000	Abr	25.38	4,159,410.75	164.41	1.52	5.81	4,152,832.25
2000	May	10.18	1,660,955.06	164.41	1.52	5.81	1,648,120.00
2000	Jun	4.85	785,897.68	164.41	1.52	5.81	771,838.63
2000	Jul	5.23	841,100.90	164.41	1.52	5.81	834,313.19
2000	Ago	11.35	1,843,491.61	164.41	1.52	5.81	1,840,473.63
2000	Sep	9.51	1,536,505.07	164.41	1.52	5.81	1,537,968.25
2000	Oct	56.05	9,192,965.57	164.41	1.52	5.81	9,188,744.00
2000	Nov	24.87	4,066,237.68	164.41	1.52	5.81	4,065,933.75
2000	Dic	99.58	16,351,683.44	164.41	1.52	5.81	16,352,305.00
2001	Ene	160.37	26,339,313.83	164.41	1.52	5.81	26,342,948.00
2001	Feb	138.36	22,728,720.83	164.41	1.52	5.81	22,726,680.00
2001	Mar	182.82	30,048,268.57	164.41	1.52	5.81	30,031,502.00
2001	Abr	52.50	8,618,209.95	164.41	1.52	5.81	8,604,164.00

Año	Mes	Precipitación (mm)	Disponibilidad Hídrica (m3/mes)	Área (km²)	Pendiente (%)	Densidad de Drenaje (km/ km²)	Predicción Disponibilidad Hídrica (m3/mes)
2001	May	18.89	3,092,966.16	164.41	1.52	5.81	3,080,089.50
2001	Jun	2.30	366,652.18	164.41	1.52	5.81	352,662.25
2001	Jul	7.01	1,133,750.70	164.41	1.52	5.81	1,126,954.63
2001	Ago	10.08	1,634,690.91	164.41	1.52	5.81	1,631,678.88
2001	Sep	11.32	1,834,087.17	164.41	1.52	5.81	1,835,541.38
2001	Oct	17.37	2,833,586.77	164.41	1.52	5.81	2,830,193.50
2001	Nov	34.91	5,716,914.08	164.41	1.52	5.81	5,730,950.00
2001	Dic	42.31	6,935,922.74	164.41	1.52	5.81	6,938,828.50
2002	Ene	123.40	20,261,076.13	164.41	1.52	5.81	20,271,638.00
2002	Feb	149.53	24,565,180.53	164.41	1.52	5.81	24,561,922.00
2002	Mar	157.39	25,867,322.27	164.41	1.52	5.81	25,853,330.00
2002	Abr	36.30	5,954,767.95	164.41	1.52	5.81	5,957,835.50
2002	May	15.36	2,512,598.86	164.41	1.52	5.81	2,499,738.50
2002	Jun	5.28	856,593.98	164.41	1.52	5.81	842,534.25
2002	Jul	19.24	3,144,485.00	164.41	1.52	5.81	3,137,632.00
2002	Ago	8.46	1,368,346.71	164.41	1.52	5.81	1,365,342.63
2002	Sep	17.96	2,925,769.57	164.41	1.52	5.81	2,927,192.25
2002	Oct	22.12	3,614,534.27	164.41	1.52	5.81	3,611,119.25
2002	Nov	50.34	8,253,760.38	164.41	1.52	5.81	8,249,540.00
2002	Dic	84.35	13,847,719.14	164.41	1.52	5.81	13,845,801.00

Nota. Elaboración Propia.

La Tabla 14 presenta los resultados obtenidos en la validación del modelo ANN aplicado a la estimación de la disponibilidad hídrica. En ella se observa la comparación entre los valores calculados de disponibilidad hídrica y las predicciones generadas por el modelo para cada mes y año. Los datos muestran que las diferencias entre los valores observados y los estimados son mínimas, lo que evidencia un buen ajuste del modelo a las condiciones reales.

Por ejemplo, en enero de 1980 la disponibilidad hídrica observada fue de 12,701,504.33 m³, mientras que el modelo predijo 12,703,202 m³, con una diferencia de apenas 1,697.67 m³, equivalente a un error relativo menor al 0.02 %. Este comportamiento confirma que el entrenamiento y la prueba realizados con las series históricas de precipitación y parámetros físicos de la cuenca (área, pendiente y densidad de drenaje) permiten que el modelo reproduzca de manera confiable la dinámica hídrica mensual.

IV. RESULTADOS Y DISCUSIÓN

En el Capítulo III se describe detalladamente el proceso de implementación del modelo ANN. En el presente capítulo se presentan los resultados obtenidos, su análisis y discusión correspondiente.

4.1. Impacto del modelo predictivo

El modelo predictivo desarrollado, basado en redes neuronales artificiales (ANN), utiliza como insumos principales los datos mencionados en el capítulo III, donde se detalla la información para la gestión hídrica del distrito de San Pedro de Palco. Estos datos incluyen el coeficiente de cultivo ponderado (K_c), la evapotranspiración mensual (E_{to}), la demanda de agua mensual y la disponibilidad hídrica histórica, los cuales son fundamentales para modelar y comprender el comportamiento hídrico de la región.

Con el fin de validar la robustez y estabilidad del modelo de red neuronal artificial (ANN) implementado para la predicción de la disponibilidad hídrica en la cuenca del río Chalcas, se realizaron cinco simulaciones independientes utilizando datos históricos de precipitación mensual correspondientes al periodo 1980-2002, complementados con variables constantes como el coeficiente de cultivo ponderado (K_c), la evapotranspiración mensual (E_{to}), la demanda de agua, y las características geomorfológicas de la cuenca (área, pendiente y densidad de drenaje).

Cada simulación replicó el proceso completo de entrenamiento del modelo ANN mediante la reintroducción de pequeñas variaciones aleatorias (ruido gaussiano controlado) sobre los datos de entrada. Este enfoque permite observar la consistencia del modelo ante perturbaciones leves y evaluar su capacidad de generalización. Las simulaciones se desarrollaron utilizando 2000 épocas, con una arquitectura de tipo Perceptrón Multicapa (MLP) compuesta por tres capas ocultas densamente conectadas (128, 64 y 32 neuronas), todas con función de activación ReLU, y una capa de salida con función lineal. Posteriormente, se proyectaron los valores de disponibilidad hídrica mensual para el periodo 2003–2030, obteniéndose que reflejan del comportamiento estocástico del modelo en cada ejecución. Estas simulaciones fueron estructuradas en hojas separadas dentro de un archivo Excel llamado “Simulaciones_Disponibilidad_2003_2030.xlsx”, permitiendo comparar fácilmente la estabilidad del modelo (Ver Figura 19).

Figura 19

Proceso de entrenamiento del modelo ANN y generación de simulaciones 2003-2030



```
model.fit(X_scaled, y_scaled, epochs=2000, batch_size=8, verbose=0)

# Predicción
X_future = df_future[["Precipitación", "Kc", "Eto", "Demanda", "Mes", "Año", "Área", "Pendiente", "Drenaje"]]
X_future_scaled = scaler_X.transform(X_future)
y_pred_scaled = model.predict(X_future_scaled)
y_pred = scaler_y.inverse_transform(y_pred_scaled)

df_future["Disponibilidad_Hídrica_Predicha"] = y_pred
tabla = df_future.pivot(index="Mes", columns="Año", values="Disponibilidad_Hídrica_Predicha").round(2)
simulaciones.append(tabla)

with pd.ExcelWriter("Simulaciones_Disponibilidad_2003_2030.xlsx") as writer:
    for i, df in enumerate(simulaciones, 1):
        df.to_excel(writer, sheet_name=f"Simulación_{i}")
```

Output logs showing training progress and warnings:

```
/usr/local/lib/python3.11/dist-packages/keras/src/layers/core/dense.py:87: UserWarning: Do not pass an 'input_shape'/'input_dim' argument to a layer.
super().__init__(activity_regularizer=activity_regularizer, **kwargs)
11/11 ----- 0s 7ms/step
/usr/local/lib/python3.11/dist-packages/keras/src/layers/core/dense.py:87: UserWarning: Do not pass an 'input_shape'/'input_dim' argument to a layer.
super().__init__(activity_regularizer=activity_regularizer, **kwargs)
11/11 ----- 0s 7ms/step
/usr/local/lib/python3.11/dist-packages/keras/src/layers/core/dense.py:87: UserWarning: Do not pass an 'input_shape'/'input_dim' argument to a layer.
super().__init__(activity_regularizer=activity_regularizer, **kwargs)
11/11 ----- 0s 6ms/step
/usr/local/lib/python3.11/dist-packages/keras/src/layers/core/dense.py:87: UserWarning: Do not pass an 'input_shape'/'input_dim' argument to a layer.
super().__init__(activity_regularizer=activity_regularizer, **kwargs)
11/11 ----- 0s 7ms/step
/usr/local/lib/python3.11/dist-packages/keras/src/layers/core/dense.py:87: UserWarning: Do not pass an 'input_shape'/'input_dim' argument to a layer.
super().__init__(activity_regularizer=activity_regularizer, **kwargs)
11/11 ----- 0s 7ms/step
/usr/local/lib/python3.11/dist-packages/keras/src/layers/core/dense.py:87: UserWarning: Do not pass an 'input_shape'/'input_dim' argument to a layer.
super().__init__(activity_regularizer=activity_regularizer, **kwargs)
11/11 ----- 0s 8ms/step
```

Nota. Elaboración Propia.

El Anexo N°10 presenta la predicción mensual de la disponibilidad hídrica en la cuenca del río Chalcas para el período 2003-2030, estimada mediante cinco simulaciones del modelo de redes neuronales artificiales (ANN) desarrollado en esta investigación. Cada simulación se ejecutó a partir del procesamiento de datos históricos (1980-2002) de precipitación, coeficiente de cultivo (Kc), evapotranspiración de referencia (Eto) y parámetros geomorfológicos de la cuenca, como área, pendiente y densidad de drenaje.

Estos resultados permiten anticipar el comportamiento hidrológico mensual futuro, incorporando la variabilidad climática y las características físicas del territorio. La información se presenta tanto en términos de precipitación y evapotranspiración (en mm y m³) como de demanda hídrica y disponibilidad, diferenciando entre escenarios con y sin demanda. Este análisis es clave para evaluar escenarios de gestión y planificación del recurso hídrico, con énfasis en la sostenibilidad y seguridad del abastecimiento. A continuación, se muestra el resumen por año de la disponibilidad predicha en base a los datos del Anexo N°10.

Tabla 15

Predicción anual-mensual de la disponibilidad hídrica en la cuenca del río Chalcas (2003–2030) (m³)

Año	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
2003	20,307,452	22,988,048	23,811,257	6,535,732	1,909,877	1,149,166	1,281,007	1,611,091	2,258,834	3,800,334	5,393,143	10,367,298
2004	21,151,885	21,347,992	23,523,841	6,446,973	1,941,310	1,212,457	1,246,592	1,574,369	2,244,914	3,686,318	5,076,657	10,274,404
2005	21,950,758	23,412,721	24,326,448	6,493,008	1,904,283	1,278,554	1,210,068	1,678,359	2,282,987	3,563,768	4,941,191	10,538,785
2006	22,246,981	22,785,633	23,554,674	6,561,209	1,994,677	1,293,357	1,106,728	1,735,306	2,291,295	3,677,861	4,819,429	9,814,798
2007	20,996,593	22,016,197	22,682,491	7,012,389	2,106,874	1,374,565	1,129,011	1,752,127	2,302,681	3,410,463	4,977,846	10,069,446
2008	21,360,260	22,147,075	23,075,023	6,905,462	1,969,078	1,382,099	1,050,245	1,812,385	2,316,673	3,677,360	5,073,439	9,915,087
2009	21,159,689	22,097,574	22,912,506	7,103,940	2,127,854	1,393,334	1,081,331	1,761,664	2,416,930	3,714,188	4,859,649	10,023,870
2010	22,028,620	21,001,701	22,281,695	6,891,052	1,948,560	1,455,327	1,095,505	1,804,399	2,445,741	3,560,030	5,068,431	9,766,979
2011	22,476,104	20,591,697	23,004,738	6,810,370	2,149,991	1,424,768	1,138,055	1,793,235	2,453,834	3,657,946	4,610,081	10,028,230
2012	21,200,894	20,763,111	22,396,874	6,915,910	2,150,569	1,401,567	1,226,350	1,645,897	2,510,659	3,701,195	4,675,494	10,085,141
2013	21,015,353	20,708,738	22,973,564	6,894,682	2,232,555	1,517,791	1,302,263	1,600,707	2,592,854	3,572,901	4,662,206	9,828,207
2014	20,192,156	20,498,487	23,005,023	7,018,920	2,128,707	1,550,496	1,308,232	1,680,350	2,689,964	3,657,345	4,489,298	9,875,615
2015	20,594,766	19,772,981	22,605,399	6,766,442	2,298,443	1,575,668	1,445,831	1,659,104	2,593,510	3,646,346	4,709,620	9,676,247
2016	19,895,568	19,967,844	23,189,997	6,893,511	2,294,276	1,632,067	1,370,901	1,741,835	2,614,108	3,527,025	4,631,572	9,366,867
2017	19,634,442	20,243,138	22,636,084	6,753,339	2,347,942	1,693,046	1,559,312	1,607,425	2,594,303	3,506,181	4,653,327	9,365,763
2018	20,156,485	20,185,375	22,264,529	6,684,934	2,442,973	1,730,754	1,502,505	1,720,646	2,610,955	3,617,812	4,545,382	9,481,953
2019	19,991,500	19,030,623	22,428,352	6,687,461	2,497,483	1,714,573	1,553,729	1,631,334	2,556,774	3,553,837	4,527,033	9,406,489
2020	19,743,066	19,637,601	22,645,977	7,061,873	2,573,450	1,800,419	1,621,353	1,665,927	2,558,498	3,590,960	4,578,172	9,236,008
2021	19,430,584	19,710,556	22,179,329	6,780,209	2,564,897	1,857,726	1,836,288	1,977,555	2,592,827	3,573,650	4,514,650	8,905,535
2022	20,129,802	19,890,297	22,469,797	7,102,098	2,696,252	1,865,806	1,897,090	1,711,537	2,666,004	3,623,441	4,550,727	9,208,418
2023	19,130,330	19,955,272	22,111,728	7,115,832	2,692,602	1,956,290	1,894,220	1,623,551	2,548,177	3,551,237	4,437,853	9,163,911
2024	18,609,665	19,325,297	22,720,245	6,918,430	2,810,443	1,985,758	1,813,969	1,803,477	2,563,405	3,674,616	4,538,882	8,687,221
2025	19,500,412	19,368,380	22,766,562	7,234,977	2,873,954	2,072,989	1,721,845	1,821,739	2,642,321	3,882,374	4,887,221	9,068,735

2026	18,749,013	18,905,365	21,810,432	7,560,073	2,932,422	2,088,007	2,069,122	1,763,911	2,757,865	3,863,575	4,512,282	9,056,804
2027	18,036,782	20,181,701	21,381,111	7,486,805	3,002,974	2,208,966	1,949,261	1,881,225	2,836,356	3,925,704	4,716,269	9,373,278
2028	19,059,292	20,651,372	21,827,787	7,552,672	3,133,922	2,190,814	1,996,015	1,925,997	2,766,477	3,979,370	4,696,445	8,785,648
2029	18,964,121	19,982,820	21,804,727	7,475,932	3,123,864	2,257,085	2,053,594	2,145,944	2,850,306	3,993,255	4,762,907	9,389,291
2030	18,342,791	19,753,337	22,284,825	7,603,125	3,173,585	2,414,640	1,821,908	1,900,159	3,033,446	4,375,799	4,807,347	9,241,811

Nota. Elaboración Propia.

La Tabla 15 muestra la predicción anual y mensual de la disponibilidad hídrica en la cuenca del río Chalcas entre 2003 y 2030, expresada en metros cúbicos (m³). Los resultados permiten observar cómo varía el recurso a lo largo del año y entre diferentes periodos, lo que puede ser usado en varios ámbitos:

1. Uso agrícola

- La información permite programar los periodos de siembra y riego.
- Ejemplo: en marzo de 2005 se proyectaron 24.3 millones de m³, mientras que en junio del mismo año apenas 1.2 millones de m³. Esto indica que en la temporada de menor disponibilidad será necesario un riego más controlado o el uso de reservorios.

2. Abastecimiento de agua

- Los valores ayudan a planificar la distribución para la población.
- Ejemplo: en 2024, en enero la disponibilidad supera los 18.6 millones de m³, mientras que en junio desciende a 1.9 millones de m³. Con esta diferencia, se puede prever la necesidad de almacenamiento durante los meses con menor oferta.

3. Infraestructura y drenaje

- Con los meses de mayor disponibilidad se puede evaluar si es necesario reforzar sistemas de conducción o almacenamiento.
- Ejemplo: en 2010, marzo presenta más de 22.8 millones de m³, mientras que en junio los valores se reducen a 1.4 millones de m³, mostrando el contraste entre la época húmeda y la seca.


4. Gestión a largo plazo

- Al contar con proyecciones hasta 2030, es posible planificar el uso del agua en escenarios futuros.
- Ejemplo: los meses de junio a agosto, en casi todos los años, registran valores entre 1 y 2 millones de m³, lo que confirma que en ese periodo se requiere una administración cuidadosa del recurso.

La Figura 20 muestra la disponibilidad hídrica predicha en la cuenca del río Chalcas para el periodo 2003-2030, obtenida a partir de cinco simulaciones del modelo ANN. Se observa un patrón similar en todas las simulaciones, con mayores valores a inicios de año (enero-marzo) y menores en los meses de junio a agosto, lo que refleja la estacionalidad del recurso.

Figura 20

Disponibilidad hídrica predicha - 5 simulaciones




Nota. Elaboración Propia a partir de los datos predichos del Anexo N°10.

La Figura 21 presenta el promedio anual de la disponibilidad hídrica predicha en la cuenca del río Chalcas para el periodo 2003-2030, considerando cinco simulaciones del modelo ANN. Se observa una variación interanual con una ligera tendencia a la disminución en los primeros años y cierta recuperación hacia el final del periodo. Aunque existen diferencias entre simulaciones, todas mantienen un rango similar de valores, lo que muestra coherencia en los resultados obtenidos.

Figura 21

Promedio anual de disponibilidad hídrica predicha (m³)




Nota. Elaboración Propia a partir de los datos predichos del Anexo N°10.

La Figura 22 muestra la media general de la disponibilidad hídrica predicha en las cinco simulaciones realizadas. Los valores son muy similares entre simulaciones, con promedios cercanos a los 8.2 millones de m³. Esto indica consistencia en los resultados obtenidos, lo que refuerza la confiabilidad del modelo ANN para la predicción del recurso hídrico en el periodo 2003-2030.

Figura 22

Media general de disponibilidad hídrica por simulación




Nota. Elaboración Propia a partir de los datos predichos del Anexo N°10.

La Figura 23 muestra el promedio mensual de la disponibilidad hídrica predicha en el periodo 2003-2030. Se observa que los valores más altos corresponden a los meses de enero a marzo, mientras que el punto más bajo se presenta en junio y julio, con una recuperación progresiva a partir de septiembre hasta diciembre. Este patrón refleja la marcada estacionalidad del recurso hídrico en la cuenca del río Chalcas.

Figura 23

Promedio mensual de disponibilidad hídrica (2003–2030) (m³)




Nota. Elaboración Propia a partir de los datos predichos del Anexo N°10.

La Figura 24 muestra la distribución de la disponibilidad hídrica predicha en cada una de las cinco simulaciones. En todos los casos, los valores presentan una variación amplia, con máximos cercanos a 25 millones de m³ y mínimos alrededor de 1.3 millones de m³.

Figura 24

Distribución de la disponibilidad hídrica por simulación



Nota. Elaboración Propia a partir de los datos predichos del Anexo N°10.

4.2. Contrastación de Hipótesis

Hipótesis General: *El modelo predictivo usando redes neuronales artificiales (ANN) permite estimar con alta precisión la disponibilidad hídrica en la cuenca del río Chalcas, distrito San Pedro de Palco, Ayacucho.*

Contrastación: En las 50 simulaciones realizadas (Tabla 13), la precisión osciló entre 97.6 % y 99.5 %, con un promedio de 99.1 %. Esto evidencia que el modelo mantuvo un rendimiento estable en diferentes ejecuciones. Además, la validación (Tabla 14) mostró que las predicciones de disponibilidad hídrica para cada mes se ajustan estrechamente a los valores observados, con diferencias menores a los 0.3 millones de m³ en la mayoría de casos. Estos resultados confirman la validez de la hipótesis general.

Hipótesis Específica 1: *La recopilación y análisis de datos históricos y actuales de precipitación, caudales y otras variables meteorológicas relevantes en la cuenca del río Chalcas proporcionará una base de datos confiable y detallada que es esencial para el desarrollo de un modelo preciso de predicción de la disponibilidad hídrica.*

Contrastación: La base de datos consolidada incluyó registros de precipitación mensual (Tabla 7) y disponibilidad hídrica (Tabla 10), complementados con parámetros geomorfológicos de la cuenca (área: 164.41 km², pendiente media: 1.52 %, densidad de drenaje: 5.81 km/km²). Estos datos pasaron por pruebas de consistencia y regresión, lo cual permitió reducir errores sistemáticos. El resultado fue un insumo estadísticamente sólido que alimentó el modelo, reflejado en la alta estabilidad de las simulaciones.

Hipótesis Específica 2: *El desarrollo de un modelo de redes neuronales artificiales (ANN) para predecir la disponibilidad hídrica validado mediante técnicas estadísticas, permitirá obtener predicciones precisas y fiables sobre los patrones de flujo de agua, superando en precisión a los métodos tradicionales de predicción.*

Contrastación: El modelo implementó un perceptrón multicapa de arquitectura 128-64-32-1 neuronas con función de activación ReLU y entrenamiento en 2000 épocas. En las validaciones se obtuvo un promedio de precisión superior al 99 % (Tabla 13), confirmando que el ANN logró un ajuste estrecho con los datos reales. Comparado con métodos hidrológicos tradicionales como el balance hídrico, el ANN mostró un mejor

desempeño: en la Figura 18, los valores reales y predichos prácticamente se superponen, y en la Figura 19 las ejecuciones múltiples mantienen coherencia. Esto valida la hipótesis al demostrar que el ANN supera en exactitud a los métodos convencionales

Hipótesis Específica 3: El modelo predictivo mejorará la gestión del recurso hídrico y la eficiencia del sistema de riego en el distrito de San Pedro de Palco, permitiendo una distribución más efectiva del agua y aumentando la productividad agrícola.

Contrastación: Las simulaciones 2003–2030 muestran una media general de disponibilidad hídrica de 8.2 millones de m³ (Figura 22), con máximos cercanos a 25 millones de m³ y mínimos de alrededor de 1.3 millones de m³ (Figura 24). El patrón mensual evidencia que los picos de disponibilidad ocurren entre enero y marzo, mientras que los valores más bajos se registran en junio y julio (Figura 23). Por ejemplo, en 2024 la disponibilidad alcanzó más de 18.6 millones de m³ en enero, pero cayó a 1.9 millones en junio; de manera similar, en 2010 marzo superó los 22.8 millones, mientras junio bajó a 1.4 millones. Estos resultados permiten planificar el almacenamiento en meses de excedente y asegurar el riego en meses críticos, confirmando que el modelo ANN contribuye directamente a la gestión eficiente del agua y a la productividad agrícola.

4.3. Discusión

Los resultados obtenidos en la investigación confirman que el modelo predictivo basado en redes neuronales artificiales (ANN) aplicado a la cuenca del río Chalcas logra estimar la disponibilidad hídrica con alta precisión, alcanzando una precisión promedio del 99.1 % en 50 simulaciones (Tabla 13) y validaciones con diferencias mínimas entre valores observados y predichos (Tabla 14). Esta evidencia se alinea con la tendencia reportada por diversos autores que han empleado redes neuronales en contextos hidrológicos y de gestión del recurso hídrico.

En primer lugar, los hallazgos son consistentes con el trabajo de Montealegre y Javela (2021), quienes implementaron modelos RNA para predecir caudales máximos diarios en el río Magdalena, alcanzando un índice de correlación perfecto ($R = 1$) y un MSE muy reducido ($3.882E-07$). Ambos estudios coinciden en que las ANN pueden ajustarse de manera precisa a los datos históricos, minimizando los errores. Sin embargo, mientras Montealegre y Javela enfocaron su análisis en eventos extremos de

caudales máximos diarios, este estudio aborda la disponibilidad hídrica mensual, lo que representa una escala distinta pero complementaria.

De manera similar, Villenas (2020) desarrolló modelos de ANN para estimar caudales diarios en la microcuenca Chalpi Norte, concluyendo que la selección óptima de arquitecturas neuronales permite obtener aproximaciones cercanas a los valores medidos. Esto se refleja también en la presente investigación, donde la arquitectura seleccionada (128-64-32-1) permitió una generalización robusta y coherente en las simulaciones. La comparación resalta que, en distintos contextos geográficos y temporales, la precisión de las ANN depende en gran medida de la calidad de los datos de entrada y del proceso de entrenamiento.

Por su parte, Castillo (2023) evaluó modelos para pronosticar caudales al embalse Mazar, logrando errores menores al 10 %. Aunque su nivel de error es ligeramente superior al encontrado en el presente estudio (con precisiones superiores al 98 %), ambos confirman la estabilidad y confiabilidad de las ANN para apoyar la gestión de sistemas hídricos estratégicos. La diferencia radica en que el modelo de Castillo se aplicó a caudales transformados a partir de niveles, mientras que en la cuenca del Chalcas se utilizó directamente información hidrológica e hidroclimática.

Asimismo, la investigación de Ramírez (2024) en Iquitos refuerza la versatilidad de las ANN, al aplicarlas en la predicción del consumo de agua potable, alcanzando un error inferior al 5 %. Aunque su objeto de estudio es el consumo y no la oferta hídrica, la comparación evidencia que, tanto en la demanda como en la disponibilidad, las redes neuronales ofrecen soluciones precisas para la planificación del recurso hídrico. En el mismo sentido, Vera y Vargas (2023) aplicaron redes neuronales para predecir inundaciones en la cuenca alta del Huallaga, con un error de predicción del 8.17 %. Sus resultados muestran que las ANN son eficaces incluso en escenarios críticos de riesgo hídrico. En contraste, en la cuenca del río Chalcas el modelo se aplicó a un objetivo más orientado a la eficiencia agrícola y de riego, pero ambos casos demuestran que las ANN fortalecen la gestión integral del agua.

Finalmente, los aportes de Zárate (2020) confirman la utilidad de las ANN en cuencas sin información hidrométrica, como en la microcuenca Huajuri, donde se superó la precisión del método tradicional de Lutz Scholz. Esto refuerza la conclusión

de la presente investigación: en la cuenca del río Chalcas, la integración de datos históricos de precipitación, caudales y variables climáticas con ANN permitió lograr una predicción robusta y confiable, contribuyendo no solo a la planificación del riego, sino también a la reducción de la incertidumbre en la gestión de los recursos.

En síntesis, los resultados de este estudio confirman que las redes neuronales artificiales son una herramienta eficaz y adaptable en hidrología, capaces de superar en precisión a los métodos tradicionales. Las comparaciones con investigaciones previas en diferentes contextos (predicción de caudales máximos, estimación de consumo de agua, pronóstico de inundaciones o cálculo en cuencas sin datos) permiten concluir que el modelo desarrollado en la cuenca del río Chalcas no solo valida su hipótesis general, sino que se inserta en una línea de evidencia científica sólida, aportando datos y metodologías relevantes para la gestión hídrica sostenible y la productividad agrícola en zonas altoandinas.

CONCLUSIONES

Objetivo General: Se desarrolló exitosamente un modelo predictivo basado en redes neuronales artificiales (ANN) para estimar la disponibilidad hídrica en la cuenca del río Chalcas, distrito de San Pedro de Palco, Ayacucho, utilizando variables como precipitación (promedio histórico mensual de 40.5 mm, con rangos de 3.2 a 151.9 mm), evapotranspiración (Eto promedio de 105.7 mm, variando entre 65.4 y 150.1 mm), caudales medios (promedio de 5.81 m³/s) y coeficientes de cultivo ponderado (Kc constante de 1.52). Las proyecciones para el horizonte 2003-2030 muestran una disponibilidad volumétrica anual promedio de aproximadamente 85 millones de m³, con picos mensuales en la temporada lluviosa (enero-marzo: promedio 20.5 millones de m³) y mínimos en la seca (julio-septiembre: promedio 1.8 millones de m³). Este modelo optimiza la gestión hídrica al anticipar variaciones estacionales, elevando potencialmente la productividad agrícola del 65% actual a niveles superiores mediante una planificación eficiente, y contribuyendo a la sostenibilidad en una cuenca de 164.41 km² con marcada variabilidad climática.

Objetivo Específico 1: El estudio de la serie histórica (1980–2002) permitió caracterizar el régimen hídrico de la cuenca. Se registraron precipitaciones mínimas de 518 mm (1992) y máximas de 860 mm (1997), mientras que la evapotranspiración del cultivo (ETc) se mantuvo en 828 mm/año. Estos datos evidenciaron la existencia máximos de precipitación en época lluviosa y mínimos en época seca. La identificación de estos patrones históricos fue crucial para comprender la dinámica climática de la cuenca, y sirvió como base para la calibración del modelo ANN, ya que permitió definir la relación entre los períodos de abundancia y escasez hídrica. De esta manera, se logró validar que la cuenca presenta una marcada estacionalidad y vulnerabilidad frente a variaciones climáticas, lo cual justifica la necesidad de implementar modelos predictivos para anticipar escenarios críticos.

Objetivo Específico 2: El modelo ANN fue diseñado y entrenado con los registros históricos de precipitación y evapotranspiración, ajustando sus parámetros internos hasta alcanzar un rendimiento óptimo. Durante el entrenamiento, se ejecutaron 50 simulaciones independientes, que permitieron evaluar la estabilidad del modelo ante diferentes condiciones de inicialización aleatoria. Los resultados mostraron que el desempeño fue consistentemente alto, manteniéndose en un rango de exactitud cercano al 99.1%, con variaciones mínimas entre simulaciones. Este comportamiento

confirma que el modelo presenta bajo sesgo de variación, robustez estadística y alta capacidad de generalización. Los indicadores globales ($R^2 = 1$ y $MSE \approx 1.96E-06$) ratifican que la dispersión entre los valores observados y los estimados fue prácticamente nula, validando la pertinencia de la arquitectura neuronal implementada. En consecuencia, el modelo no solo aprendió de manera adecuada la dinámica hídrica de la cuenca, sino que también mostró una capacidad destacada para adaptarse a series de datos proyectadas, manteniendo precisión en sus predicciones.

Objetivo Específico 3: Se evaluó el impacto del modelo predictivo en la gestión del recurso hídrico y la eficiencia del sistema de riego en el distrito de San Pedro de Palco, demostrando su capacidad para optimizar la asignación de agua al anticipar períodos de menor disponibilidad hídrica (julio-septiembre: promedio 1.8 millones de m^3 mensuales, correspondientes a los meses de menor volumen) y mejorar la planificación del riego. Según los datos históricos (2003 - 2030), la productividad agrícola está limitada debido a la variabilidad estacional. El modelo permite ajustar los calendarios de riego, reduciendo las pérdidas por insuficiencia hídrica en aproximadamente 0.4 a 0.6 millones de m^3 mensuales durante la temporada seca. Esto incrementa los rendimientos agrícolas, fortaleciendo la economía local dependiente de la agricultura, y mejora la distribución equitativa del agua en la cuenca.

RECOMENDACIONES

Implementar estaciones meteorológicas y aforadores en puntos estratégicos de la cuenca del río Chalcas para obtener datos continuos y de mayor resolución espacial sobre precipitación, caudales y evapotranspiración. Esto permitirá retroalimentar y recalibrar periódicamente el modelo ANN, aumentando su precisión y capacidad de proyección.

Se recomienda integrar proyecciones climáticas (precipitación y temperatura) a nivel regional, de modo que el modelo ANN no solo trabaje con series históricas, sino que también evalúe el posible impacto del cambio climático en la disponibilidad hídrica futura.

Incorporar el modelo predictivo en los planes de gestión del recurso hídrico del distrito de San Pedro de Palco, utilizándolo como soporte para la toma de decisiones en la distribución del agua de riego. Esto incluye la programación de turnos de riego, la priorización de cultivos y la planificación de obras de almacenamiento.

Se recomienda realizar talleres de capacitación para que los encargados de la gestión hídrica y los agricultores del distrito de San Pedro de Palco puedan interpretar los resultados del modelo y tomar decisiones informadas sobre la planificación agrícola y la distribución del agua. Esto fomentará una gestión más sostenible y participativa del recurso hídrico.

REFERENCIAS BIBLIOGRÁFICAS

- Balairon, L. (2002). Gestión de recursos hídricos. Barcelona. Universidad Politécnica de Cataluña. España: Ediciones
- Bustamante, W., y Quizhpilema, I. (2020). Implementación de un modelo de predicción basado en redes neuronales artificiales para la clasificación de información académica y de investigación de la UNACH. Unach.edu.ec. <http://dspace.unach.edu.ec/handle/51000/6608>
- Cahuana Andía, A. (2009). Material de Apoyo Didáctico para la Enseñanza y Aprendizaje de la Asignatura de Hidrología. Cochabamba. Disponible en: <http://www.fcyt.umss.edu.bo/materias>
- Castillo, J. (2023). Evaluación de modelos de pronóstico para estimar el ingreso de caudales al embalse Mazar: aplicación con redes neuronales. Ucacue.edu.ec; Universidad Católica de Cuenca. <https://dspace.ucacue.edu.ec/handle/ucacue/13892>
- Corponariño (2009). Índice de escasez de agua superficial de la cuenca del río Pasto, p 21 y 22. Disponible en: <https://www.corponarino.gov.co/expedientes/descontaminacion/porhmirafloresp3.pdf>
- Díaz, J. (2017). Determinación de la disponibilidad hídrica superficial mediante balance hídrico en la Cuenca de Río Cumbaza-San Martín, 2016. Upeu.edu.pe. <http://repositorio.upeu.edu.pe/handle/20.500.12840/957>
- Haykin, S. (1999). Neural networks. A comprehensive foundation. Prentice Hall International Inc., New Jersey.
- Haykin, S., y Network, N. (2004). Fundamentos integrales. *Redes neuronales*, 2 (2004), 41.
- Hernández, R., Fernández, C., & Baptista, P. (2014). *Metodología de la Investigación* (6ª ed.). McGraw-Hill.
- Horton, R. E. (1945). Erosional development of streams and their drainage basins: Hydrophysical approach to Quantitative morphology. Bull. Geol. Soc. Am. Vol. 56,

pp. 275-370. Obtenido de
<https://pdodds.w3.uvm.edu/research/papers/others/1945/horton1945a.pdf>
 IDEAM (2004). Metodología para el cálculo del índice de escasez de agua superficial, Bogotá, Colombia, p 10.

Isasi Viñuela, P., y Galván León, I. M. (2004). Redes de neuronas artificiales: Un enfoque práctico.

Llamas, J (1993). Hidrología general: principios y aplicaciones. Quebec Canadá.

Lo, C y Yeung, A. (2007). Concepts and techniques of geographic information systems. 2ed. New Delhi. Prentice- Hall. 532 p.

López, F. (1998). Restauración Hidrológica Forestal de Cuencas y Control de la Erosión. Ingeniería Medioambiental, TRANGSATEC, Ministerio de Medio Ambiente. Editorial Mundi Prensa. España

Luna, L y Lavado, G. (2015). Revista Tecnológica ESPOL – RTE, Vol. 28, N. 3, 42-52.

MAIDMENT, DR (1992). Handbook of hidrology. McGraw Hill. New York.

Martí Pérez, PC. (2009). Aplicación de redes neuronales artificiales para predicción de variables en ingeniería del riego: evapotranspiración de referencia y pérdidas de carga localizadas en emisores integrados [Tesis doctoral no publicada]. Universidad Politécnica de València. <https://doi.org/10.4995/Thesis/10251/64909>

Montealegre Ruiz, L. J., y Javela Quiñonez, A. (2021). Predicción de caudales máximos diarios del Río Magdalena a la altura del municipio de Calamar (Bolívar), usando el método de redes neuronales artificiales (Rna).

Municipalidad Distrital de San Pedro de Palco. (2020). Proyecto: Mejoramiento del canal de riego del anexo de San José de Chalcas del distrito de San Pedro de Palco - provincia de Lucanas - departamento de Ayacucho: Memoria. Ana.gob.pe. <https://hdl.handle.net/20.500.12543/4734>

Olabe, X. B. (1998). Redes neuronales artificiales y sus aplicaciones. Publicaciones de la Escuela de Ingenieros.

- Olano, J., y Solano, L. (2019). Disponibilidad Hídrica de la Cuenca del Río Amojú Aplicando el Modelo Determinístico – Estocástico de Lutz Scholz. Unj.edu.pe. <http://repositorio.unj.edu.pe/handle/UNJ/242>
- Ordoñez, J. (2011). Ciclo Hidrológico, Global Water Partnership, Lima. Disponible en: https://www.gwp.org/globalassets/global/gwp-sam_files/publicaciones/varios/ciclo_hidrologico.pdf
- Ramirez, J. (2024). Modelo predictivo basado en redes neuronales artificiales para pronosticar el consumo de agua potable en la ciudad de Iquitos. 12.84.13. <https://hdl.handle.net/20.500.13084/8532>
- Rumelhart, D. E., y McClelland, J. L. (1986). On learning the past tenses of English verbs. Cambridge, MA: MIT Press.
- Suarez, DJ (2001). Erosión en ríos y corrientes de agua. En: Curso de control de erosión.
- Tarazona, N. (2005). Generación de descargas mensuales en subcuencas de la cuenca del río Santa utilizando el método Lutz Scholz (tesis de pregrado). Universidad Nacional Agraria la Molina, Lima, Perú
- Thornthwaite, C. W. (1948). An approach toward a rational classification of climate. Geographical review, 38(1), 55-94.
- Trujillo, A. R., Barroso, F. U., Y Escobar, Y. C. (2010). Guía básica para la caracterización morfométrica de cuencas hidrográficas (1st ed.). Universidad del Valle. <http://www.jstor.org/stable/j.ctt1rfsqf5>
- UNESCO. (1971) Scientific frametmrk of world water balance. Paris, UNESCO. 27p. (Technical papers in hydrology, NO. 7).
- Vásquez, (2000). Estimación de la precipitación promedio areal de la cueca de Saboya, Paraguay. UPB.
- Vera, E., y Vargas, G. (2023). Evaluación hidrológica con uso de redes neuronales artificiales para el cálculo de hidrogramas en la cuenca alta del Huallaga. Upc.edu.pe. <http://hdl.handle.net/10757/671144>

- Villenas, L. (2020). Predicción de caudales en la cuenca del río Chalpi Norte mediante la aplicación de redes neuronales. Epn.edu.ec. <http://bibdigital.epn.edu.ec/handle/15000/21066>
- Villón, M. (2002), Hidrología Estadística (Segunda edición). Lima: Ediciones Villón.
- Zárate, C. (2020). Modelamiento hidrológico de caudales medios mensuales en cuencas sin información hidrométrica aplicando el método Lutz Scholz y las redes neuronales artificiales, en la microcuenca Huajuri - Oropesa - Antabamba - Apurímac. Upc.edu.pe. <http://hdl.handle.net/10757/656781>

ANEXOS


ANEXO N°1: Matriz de consistencia

“DESARROLLO DE UN MODELO PREDICTIVO DE LA DISPONIBILIDAD HÍDRICA USANDO REDES NEURONALES ARTIFICIALES (ANN) EN LA CUENCA DEL RIO CHALCAS, DISTRITO SAN PEDRO DE PALCO, AYACUCHO”							
PROBLEMA	OBJETIVOS	HIPÓTESIS	VARIABLES	DIMENSIONES	INDICADORES	METODOLOGIA	POBLACIÓN Y MUESTRA
Problema General	Objetivo General	Hipótesis General	Variable Independiente: Modelo predictivo usando redes neuronales artificiales (ANN).	Arquitectura del Modelo ANN.	Número de capas y neuronas en la red.	El enfoque de esta investigación es cuantitativo.	La población de esta investigación está constituida por todos los datos históricos y actuales de variables meteorológicas y de caudales de agua que afectan en la cuenca del río Chalcas, distrito San Pedro de Palco.
¿Cómo desarrollar un modelo predictivo usando redes neuronales artificiales (ANN) para estimar la disponibilidad hídrica en la cuenca del río Chalcas, distrito San Pedro de Palco, Ayacucho?	Desarrollar un modelo predictivo usando redes neuronales artificiales (ANN) para estimar la disponibilidad hídrica en la cuenca del río Chalcas, distrito San Pedro de Palco, Ayacucho.	El desarrollo de un modelo predictivo usando redes neuronales artificiales (ANN) para estimar la disponibilidad hídrica en la cuenca del río Chalcas, ubicado en el distrito San Pedro de Palco, Ayacucho, mejorará significativamente la precisión y eficiencia en la gestión del recurso hídrico.		Entrenamiento del Modelo.	Tasa de aprendizaje.	El alcance de esta investigación es descriptivo y predictivo.	
Problema específico	Objetivos específicos	Hipótesis específico		Evaluación del Modelo.	Error cuadrático medio (MSE).	El diseño de investigación es no experimental y transversal.	
¿Cómo recopilar y analizar de manera efectiva los datos históricos y actuales de precipitación, caudales y otras variables meteorológicas relevantes en la cuenca del río Chalcas?	Recopilar y analizar datos históricos y actuales de precipitación, caudales y otras variables meteorológicas relevantes en la cuenca del río Chalcas.	La recopilación y análisis de datos históricos y actuales de precipitación, caudales y otras variables meteorológicas relevantes en la cuenca del río Chalcas proporcionará una base de datos confiable y detallada que es esencial para el desarrollo de un modelo preciso de predicción de la disponibilidad hídrica.	Variable Dependiente: Disponibilidad hídrica	Volumen de Agua Disponible.	Coeficiente de determinación (R²).		La muestra de la investigación se seleccionará a partir de la población descrita anteriormente y consistirá en un conjunto de datos históricos y actuales que cubran un período
					Volumen total mensual de agua.		

¿Cómo desarrollar un modelo de redes neuronales artificiales (ANN) para predecir la disponibilidad hídrica y cómo validar su precisión mediante técnicas estadísticas?	Desarrollar un modelo de redes neuronales artificiales (ANN) para predecir la disponibilidad hídrica, validando su precisión mediante técnicas estadísticas.	El desarrollo de un modelo de redes neuronales artificiales (ANN) para predecir la disponibilidad hídrica validado mediante técnicas estadísticas, permitirá obtener predicciones precisas y fiables sobre los patrones de flujo de agua, superando en precisión a los métodos tradicionales de predicción.		Variabilidad Temporal.	Fluctuación estacional de caudales.		representativo de tiempo para asegurar la robustez del modelo de predicción.
¿Cómo evaluar el impacto del modelo predictivo en la gestión del recurso hídrico y en la eficiencia del sistema de riego en el distrito de San Pedro de Palco?	Evaluar el impacto del modelo predictivo en la gestión del recurso hídrico y la eficiencia del sistema de riego en el distrito de San Pedro de Palco	El modelo predictivo mejorará la gestión del recurso hídrico y la eficiencia del sistema de riego en el distrito de San Pedro de Palco, permitiendo una distribución más efectiva del agua y aumentando la productividad agrícola.		Escasez Hídrica.	Número de días con caudal bajo crítico.		
				Eficiencia en la Distribución del Agua.	Pérdidas de agua		

Nota. Elaboración propia


ANEXO N°2: PLANO DE UBICACIÓN - LOCALIZACIÓN DE LA CUENCA DEL RIO CHALCAS




ANEXO N°3: PLANO DE UBICACIÓN - ESTACIONES METEOROLÓGICAS



MAPA DEPARTAMENTAL



MAPA PROVINCIAL



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

Plano: PLANO DE UBICACIÓN DE LAS ESTACIONES
METEOROLÓGICAS UTILIZADAS

Elaboración:
JHAC HAROLD TABOADA VALENZUELA

Código:

U-2

ANEXO N°4: MODELO DE RED NEURONAL (ANN)

```
from google.colab import files
import pandas as pd

# Subir archivo Excel
uploaded = files.upload()
file_name = list(uploaded.keys())[0]

# Leer hojas
data_precip = pd.read_excel(file_name, sheet_name="Precipitaciones mm")
data_disp = pd.read_excel(file_name, sheet_name="Disponibilidad m3")

# Convertir a formato largo (uno por mes)
months = ["Ene", "Feb", "Mar", "Abr", "May", "Jun", "Jul", "Ago", "Sep", "Oct", "Nov", "Dic"]
data_precip_long = data_precip.melt(id_vars=["Año"], value_vars=months,
var_name="Mes", value_name="Precipitación")
data_disp_long = data_disp.melt(id_vars=["Año"], value_vars=months,
var_name="Mes", value_name="Disponibilidad Hídrica")

# Unir precipitaciones y disponibilidad
data_full = pd.merge(data_precip_long, data_disp_long,
on=["Año", "Mes"])

# Añadir columnas constantes
data_full["Área"] = 164.41
data_full["Pendiente"] = 1.52
data_full["Densidad de Drenaje"] = 5.81

print(f"Datos cargados: {len(data_full)} filas (deben ser 276)")
data_full.head()

import numpy as np
import tensorflow as tf
from sklearn.preprocessing import MinMaxScaler
from sklearn.model_selection import train_test_split
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from tensorflow.keras.callbacks import EarlyStopping
from sklearn.metrics import r2_score

np.random.seed(42)
tf.random.set_seed(42)

# Preparar datos
X = data_full[["Precipitación", "Área", "Pendiente", "Densidad de Drenaje"]]
y = data_full["Disponibilidad Hídrica"]

# Normalización
scaler_X = MinMaxScaler()
X_scaled = scaler_X.fit_transform(X)

scaler_y = MinMaxScaler()
y_scaled = scaler_y.fit_transform(y.values.reshape(-1,1))
```

```

# División Train/Test (80%-20%)
X_train, X_test, y_train, y_test = train_test_split(X_scaled, y_scaled,
test_size=0.2, random_state=42, shuffle=False)

# Modelo ANN
model = Sequential([
    Dense(128, activation='relu', input_shape=(X_train.shape[1],)),
    Dense(64, activation='relu'),
    Dense(32, activation='relu'),
    Dense(1, activation='linear')
])

model.compile(optimizer=tf.keras.optimizers.Adam(0.001),
loss='mean_squared_error', metrics=['mae'])
early_stop = EarlyStopping(monitor='val_loss', patience=50,
restore_best_weights=True)

# Entrenamiento
history = model.fit(X_train, y_train, validation_split=0.2, epochs=1000,
batch_size=8, verbose=1, callbacks=[early_stop])

# Predicciones
y_pred_scaled = model.predict(X_scaled)
y_pred = scaler_y.inverse_transform(y_pred_scaled)
data_full["Predicción Disponibilidad Hídrica"] = y_pred.flatten()

# Métricas
loss, mae = model.evaluate(X_test, y_test, verbose=0)
r2 = r2_score(y, y_pred)
error_rel = np.mean(np.abs((y - y_pred.flatten()) / y))
precision = (1 - error_rel) * 100

print(f"MAE (Normalizado): {mae:.5f}")
print(f"R² del modelo: {r2:.3f}")
print(f"Precisión: {precision:.2f}%")

# Exportar Excel
data_full.to_excel("Prediccion_1_ANN.xlsx", index=False)
from google.colab import files
files.download("Prediccion_1_ANN.xlsx")

# --- Mostrar los primeros 23 registros para verificar ---
print(data_full.head(23))

```

ANEXO Nº5: SIMULACIÓN DEL CÓDIGO MODELO DE RED NEURONAL (ANN)

```
Epoch 1/1000
/usr/local/lib/python3.11/dist-packages/keras/src/layers/core/dense.py:93: UserWarning: Do not pass an `input_shape` / `input_dim` argument to a layer. When using
super().__init__(activity_regularizer=activity_regularizer, **kwargs)
22/22 2s 18ms/step - loss: 0.0605 - mae: 0.1732 - val_loss: 0.0084 - val_mae: 0.0905
Epoch 2/1000
22/22 0s 6ms/step - loss: 0.0073 - mae: 0.0762 - val_loss: 5.7273e-05 - val_mae: 0.0058
Epoch 3/1000
22/22 0s 6ms/step - loss: 2.1098e-04 - mae: 0.0120 - val_loss: 1.2216e-04 - val_mae: 0.0106
Epoch 4/1000
22/22 0s 8ms/step - loss: 6.7276e-05 - mae: 0.0065 - val_loss: 9.2534e-06 - val_mae: 0.0023
Epoch 5/1000
22/22 0s 10ms/step - loss: 1.6091e-05 - mae: 0.0031 - val_loss: 9.9534e-06 - val_mae: 0.0030
Epoch 6/1000
22/22 0s 10ms/step - loss: 8.2704e-06 - mae: 0.0023 - val_loss: 5.9397e-06 - val_mae: 0.0023
Epoch 7/1000
22/22 0s 12ms/step - loss: 4.9476e-06 - mae: 0.0018 - val_loss: 2.4882e-06 - val_mae: 0.0014
Epoch 8/1000
22/22 1s 10ms/step - loss: 2.7479e-06 - mae: 0.0013 - val_loss: 1.5163e-06 - val_mae: 0.0011
Epoch 9/1000
22/22 0s 10ms/step - loss: 2.0935e-06 - mae: 0.0011 - val_loss: 9.0850e-07 - val_mae: 8.3951e-04
Epoch 10/1000
22/22 0s 12ms/step - loss: 1.2540e-06 - mae: 8.7173e-04 - val_loss: 5.4484e-07 - val_mae: 6.3848e-04
Epoch 11/1000
22/22 0s 8ms/step - loss: 9.2868e-07 - mae: 7.3735e-04 - val_loss: 3.5438e-07 - val_mae: 5.1108e-04
Epoch 12/1000
22/22 0s 6ms/step - loss: 8.6304e-07 - mae: 7.0849e-04 - val_loss: 2.8084e-07 - val_mae: 4.5755e-04
Epoch 13/1000
22/22 0s 6ms/step - loss: 7.5195e-07 - mae: 6.8439e-04 - val_loss: 2.7027e-07 - val_mae: 4.3409e-04
Epoch 14/1000
22/22 0s 6ms/step - loss: 7.7796e-07 - mae: 7.1964e-04 - val_loss: 3.1412e-07 - val_mae: 4.1325e-04
```

Variables Terminal

```
Epoch 15/1000
22/22 0s 6ms/step - loss: 7.9891e-07 - mae: 7.4421e-04 - val_loss: 3.5679e-07 - val_mae: 4.1848e-04
Epoch 16/1000
22/22 0s 6ms/step - loss: 7.1584e-07 - mae: 7.1107e-04 - val_loss: 4.0370e-07 - val_mae: 4.7861e-04
Epoch 17/1000
22/22 1s 18ms/step - loss: 5.7304e-07 - mae: 6.3801e-04 - val_loss: 4.0715e-07 - val_mae: 4.9990e-04
Epoch 18/1000
22/22 0s 15ms/step - loss: 4.8695e-07 - mae: 5.8219e-04 - val_loss: 3.8175e-07 - val_mae: 4.9994e-04
Epoch 19/1000
22/22 0s 6ms/step - loss: 3.9823e-07 - mae: 5.1990e-04 - val_loss: 3.1536e-07 - val_mae: 4.5469e-04
Epoch 20/1000
22/22 0s 6ms/step - loss: 2.7792e-07 - mae: 4.2791e-04 - val_loss: 2.4770e-07 - val_mae: 3.9446e-04
Epoch 21/1000
22/22 0s 6ms/step - loss: 2.0180e-07 - mae: 3.6405e-04 - val_loss: 1.9254e-07 - val_mae: 3.4574e-04
Epoch 22/1000
22/22 0s 6ms/step - loss: 1.5010e-07 - mae: 3.1354e-04 - val_loss: 1.5341e-07 - val_mae: 3.0860e-04
Epoch 23/1000
22/22 0s 6ms/step - loss: 1.1919e-07 - mae: 2.8219e-04 - val_loss: 1.3491e-07 - val_mae: 2.9299e-04
Epoch 24/1000
22/22 0s 6ms/step - loss: 1.0036e-07 - mae: 2.5997e-04 - val_loss: 1.2172e-07 - val_mae: 2.8258e-04
Epoch 25/1000
22/22 0s 6ms/step - loss: 8.6669e-08 - mae: 2.4090e-04 - val_loss: 1.1641e-07 - val_mae: 2.8254e-04
Epoch 26/1000
22/22 0s 7ms/step - loss: 7.6535e-08 - mae: 2.2552e-04 - val_loss: 1.1895e-07 - val_mae: 2.9424e-04
Epoch 27/1000
22/22 0s 8ms/step - loss: 6.9032e-08 - mae: 2.1401e-04 - val_loss: 1.1634e-07 - val_mae: 2.9727e-04
Epoch 28/1000
22/22 0s 7ms/step - loss: 6.2611e-08 - mae: 2.0258e-04 - val_loss: 1.1546e-07 - val_mae: 3.0017e-04
Epoch 29/1000
22/22 0s 6ms/step - loss: 5.7473e-08 - mae: 1.9335e-04 - val_loss: 1.0798e-07 - val_mae: 2.9267e-04
```

Variables Terminal

```
22/22 0s 6ms/step - loss: 5.7473e-08 - mae: 1.9335e-04 - val_loss: 1.0798e-07 - val_mae: 2.9267e-04
Epoch 30/1000
22/22 0s 7ms/step - loss: 5.3101e-08 - mae: 1.8359e-04 - val_loss: 1.0420e-07 - val_mae: 2.8951e-04
Epoch 31/1000
22/22 0s 8ms/step - loss: 4.9769e-08 - mae: 1.7674e-04 - val_loss: 9.4843e-08 - val_mae: 2.7606e-04
Epoch 32/1000
22/22 0s 8ms/step - loss: 4.7074e-08 - mae: 1.7039e-04 - val_loss: 8.8805e-08 - val_mae: 2.6729e-04
Epoch 33/1000
22/22 0s 6ms/step - loss: 4.4760e-08 - mae: 1.6544e-04 - val_loss: 8.0389e-08 - val_mae: 2.5401e-04
Epoch 34/1000
22/22 0s 7ms/step - loss: 4.2711e-08 - mae: 1.6041e-04 - val_loss: 7.5288e-08 - val_mae: 2.4578e-04
Epoch 35/1000
22/22 0s 8ms/step - loss: 4.1236e-08 - mae: 1.5720e-04 - val_loss: 6.9677e-08 - val_mae: 2.3609e-04
Epoch 36/1000
22/22 0s 6ms/step - loss: 3.9918e-08 - mae: 1.5473e-04 - val_loss: 6.7709e-08 - val_mae: 2.3264e-04
Epoch 37/1000
22/22 0s 6ms/step - loss: 3.8273e-08 - mae: 1.5131e-04 - val_loss: 6.4756e-08 - val_mae: 2.2689e-04
Epoch 38/1000
22/22 0s 7ms/step - loss: 3.7315e-08 - mae: 1.4938e-04 - val_loss: 6.5492e-08 - val_mae: 2.2807e-04
Epoch 39/1000
22/22 0s 6ms/step - loss: 3.5593e-08 - mae: 1.4588e-04 - val_loss: 5.9134e-08 - val_mae: 2.1573e-04
Epoch 40/1000
22/22 0s 7ms/step - loss: 3.5543e-08 - mae: 1.4673e-04 - val_loss: 5.8277e-08 - val_mae: 2.1380e-04
Epoch 41/1000
22/22 0s 6ms/step - loss: 3.5004e-08 - mae: 1.4659e-04 - val_loss: 5.6458e-08 - val_mae: 2.0993e-04
Epoch 42/1000
22/22 0s 6ms/step - loss: 3.4217e-08 - mae: 1.4564e-04 - val_loss: 5.4623e-08 - val_mae: 2.0586e-04
Epoch 43/1000
22/22 0s 7ms/step - loss: 3.3967e-08 - mae: 1.4532e-04 - val_loss: 5.3435e-08 - val_mae: 2.0307e-04
Epoch 44/1000
```

Variables Terminal

Epoch 45/1000	
22/22	0s 8ms/step - loss: 3.327e-08 - mae: 1.4441e-04 - val_loss: 5.0828e-08 - val_mae: 1.9769e-04
Epoch 46/1000	
22/22	0s 7ms/step - loss: 3.3155e-08 - mae: 1.4365e-04 - val_loss: 4.9099e-08 - val_mae: 1.9390e-04
Epoch 47/1000	
22/22	0s 6ms/step - loss: 3.3779e-08 - mae: 1.4421e-04 - val_loss: 4.7031e-08 - val_mae: 1.8931e-04
Epoch 48/1000	
22/22	0s 6ms/step - loss: 3.4462e-08 - mae: 1.4514e-04 - val_loss: 4.5123e-08 - val_mae: 1.8522e-04
Epoch 49/1000	
22/22	0s 7ms/step - loss: 3.5009e-08 - mae: 1.4561e-04 - val_loss: 4.3604e-08 - val_mae: 1.8206e-04
Epoch 50/1000	
22/22	0s 6ms/step - loss: 3.5273e-08 - mae: 1.4567e-04 - val_loss: 4.1314e-08 - val_mae: 1.7725e-04
Epoch 51/1000	
22/22	0s 8ms/step - loss: 3.4932e-08 - mae: 1.4438e-04 - val_loss: 3.9269e-08 - val_mae: 1.7283e-04
Epoch 52/1000	
22/22	0s 7ms/step - loss: 3.3877e-08 - mae: 1.4229e-04 - val_loss: 3.8067e-08 - val_mae: 1.7017e-04
Epoch 53/1000	
22/22	0s 9ms/step - loss: 3.2601e-08 - mae: 1.3996e-04 - val_loss: 3.6473e-08 - val_mae: 1.6657e-04
Epoch 54/1000	
22/22	0s 11ms/step - loss: 3.1631e-08 - mae: 1.3830e-04 - val_loss: 3.5831e-08 - val_mae: 1.6495e-04
Epoch 55/1000	
22/22	0s 10ms/step - loss: 3.0614e-08 - mae: 1.3644e-04 - val_loss: 3.7016e-08 - val_mae: 1.6731e-04
Epoch 56/1000	
22/22	0s 10ms/step - loss: 2.9135e-08 - mae: 1.3323e-04 - val_loss: 3.5209e-08 - val_mae: 1.6308e-04
Epoch 57/1000	
22/22	0s 11ms/step - loss: 2.8849e-08 - mae: 1.3352e-04 - val_loss: 3.5251e-08 - val_mae: 1.6285e-04
Epoch 58/1000	
22/22	0s 10ms/step - loss: 2.8156e-08 - mae: 1.3206e-04 - val_loss: 3.5808e-08 - val_mae: 1.6380e-04
Epoch 59/1000	
22/22	0s 11ms/step - loss: 2.7677e-08 - mae: 1.3069e-04 - val_loss: 3.8086e-08 - val_mae: 1.6883e-04

Variables Terminal

Epoch 60/1000	
22/22	0s 10ms/step - loss: 2.6796e-08 - mae: 1.2779e-04 - val_loss: 3.6094e-08 - val_mae: 1.6410e-04
Epoch 61/1000	
22/22	0s 6ms/step - loss: 2.7196e-08 - mae: 1.2934e-04 - val_loss: 3.6492e-08 - val_mae: 1.6480e-04
Epoch 62/1000	
22/22	0s 6ms/step - loss: 2.6981e-08 - mae: 1.2871e-04 - val_loss: 3.6920e-08 - val_mae: 1.6552e-04
Epoch 63/1000	
22/22	0s 7ms/step - loss: 2.6926e-08 - mae: 1.2871e-04 - val_loss: 3.8433e-08 - val_mae: 1.6881e-04
Epoch 64/1000	
22/22	0s 8ms/step - loss: 2.6563e-08 - mae: 1.2760e-04 - val_loss: 3.6443e-08 - val_mae: 1.6421e-04
Epoch 65/1000	
22/22	0s 6ms/step - loss: 2.7483e-08 - mae: 1.3022e-04 - val_loss: 3.7222e-08 - val_mae: 1.6582e-04
Epoch 66/1000	
22/22	0s 7ms/step - loss: 2.7377e-08 - mae: 1.2985e-04 - val_loss: 3.6844e-08 - val_mae: 1.6477e-04
Epoch 67/1000	
22/22	0s 6ms/step - loss: 2.7877e-08 - mae: 1.3108e-04 - val_loss: 3.6776e-08 - val_mae: 1.6447e-04
Epoch 68/1000	
22/22	0s 7ms/step - loss: 2.8260e-08 - mae: 1.3204e-04 - val_loss: 3.6362e-08 - val_mae: 1.6337e-04
Epoch 69/1000	
22/22	0s 7ms/step - loss: 2.8863e-08 - mae: 1.3352e-04 - val_loss: 3.5965e-08 - val_mae: 1.6231e-04
Epoch 70/1000	
22/22	0s 8ms/step - loss: 2.9549e-08 - mae: 1.3506e-04 - val_loss: 3.5283e-08 - val_mae: 1.6059e-04
Epoch 71/1000	
22/22	0s 7ms/step - loss: 3.0722e-08 - mae: 1.3763e-04 - val_loss: 3.8756e-08 - val_mae: 1.6778e-04
Epoch 72/1000	
22/22	0s 8ms/step - loss: 2.9849e-08 - mae: 1.3499e-04 - val_loss: 3.5614e-08 - val_mae: 1.5898e-04
Epoch 73/1000	
22/22	0s 7ms/step - loss: 3.2015e-08 - mae: 1.4054e-04 - val_loss: 3.5600e-08 - val_mae: 1.5809e-04
Epoch 74/1000	
22/22	0s 7ms/step - loss: 3.3340e-08 - mae: 1.4311e-04 - val_loss: 3.4572e-08 - val_mae: 1.5482e-04

Variables Terminal

22/22

0s 7ms/step - loss: 3.4944e-08 - mae: 1.4838e-04 - val_loss: 2.0694e-08 - val_mae: 1.0807e-04

Epoch 127/1000

22/22

0s 6ms/step - loss: 3.0566e-08 - mae: 1.3887e-04 - val_loss: 1.9469e-08 - val_mae: 1.0385e-04

Epoch 128/1000

22/22

0s 7ms/step - loss: 2.8058e-08 - mae: 1.3464e-04 - val_loss: 1.9834e-08 - val_mae: 1.0557e-04

Epoch 129/1000

22/22

0s 7ms/step - loss: 2.6938e-08 - mae: 1.3228e-04 - val_loss: 2.0114e-08 - val_mae: 1.0700e-04

Epoch 130/1000

22/22

0s 8ms/step - loss: 2.6303e-08 - mae: 1.3104e-04 - val_loss: 2.0082e-08 - val_mae: 1.0730e-04

Epoch 131/1000

22/22

0s 6ms/step - loss: 2.5897e-08 - mae: 1.3043e-04 - val_loss: 2.0528e-08 - val_mae: 1.0916e-04

Epoch 132/1000

22/22

0s 6ms/step - loss: 2.5648e-08 - mae: 1.3004e-04 - val_loss: 2.0923e-08 - val_mae: 1.1076e-04

9/9

0s 10ms/step

MAE (Normalizado): 0.00014

R² del modelo: 1.000

Precisión: 98.96%

	Año	Mes	Precipitación	Disponibilidad Hídrica	Área	Pendiente \
0	1980	Ene	77.42	1.270150e+07	164.41	1.52
1	1981	Ene	93.32	1.531562e+07	164.41	1.52
2	1982	Ene	113.33	1.860547e+07	164.41	1.52
3	1983	Ene	75.09	1.231843e+07	164.41	1.52
4	1984	Ene	132.19	2.170624e+07	164.41	1.52
5	1985	Ene	88.25	1.448206e+07	164.41	1.52
6	1986	Ene	189.56	3.113844e+07	164.41	1.52
7	1987	Ene	149.04	2.447655e+07	164.41	1.52
8	1988	Ene	115.52	1.896553e+07	164.41	1.52
9	1989	Ene	240.09	3.944608e+07	164.41	1.52
10	1990	Ene	108.29	1.777684e+07	164.41	1.52

Variables Terminal

ANEXO N°6: MODELO DE PREDICCIÓN DE RED NEURONAL (ANN)

```
# Importar librerías
import pandas as pd
import numpy as np
import tensorflow as tf
from sklearn.preprocessing import MinMaxScaler
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from tensorflow.keras.callbacks import EarlyStopping
from google.colab import files

# Configuración de reproducibilidad
np.random.seed(42)
tf.random.set_seed(42)
tf.config.experimental.enable_op_determinism()

# Subir archivo Excel
uploaded = files.upload()
file_name = list(uploaded.keys())[0]

# --- Leer hojas del Excel ---
data_precip = pd.read_excel(file_name, sheet_name="Precipitaciones mm")
data_disp = pd.read_excel(file_name, sheet_name="Disponibilidad m3")
data_eto = pd.read_excel(file_name, sheet_name="ETo")
data_demanda = pd.read_excel(file_name, sheet_name="Demanda m3")

# Convertir a formato largo (meses en filas)
months = ["Ene", "Feb", "Mar", "Abr", "May", "Jun", "Jul", "Ago", "Sep", "Oct", "Nov", "Dic"]
meses_dict = {m:i+1 for i,m in enumerate(months)}

def melt_data(df, value_name):
    return df.melt(id_vars=["Año"], value_vars=months, var_name="Mes",
value_name=value_name)

precip_long = melt_data(data_precip, "Precipitación")
disp_long = melt_data(data_disp, "Disponibilidad_Hídrica")
eto_long = melt_data(data_eto, "ETo")
demanda_long = melt_data(data_demanda, "Demanda")

# Unir todas las variables
data_full = precip_long.merge(disp_long, on=["Año", "Mes"])
data_full = data_full.merge(eto_long, on=["Año", "Mes"])
data_full = data_full.merge(demanda_long, on=["Año", "Mes"])

# Columnas constantes
data_full["Área"] = 164.41
data_full["Pendiente"] = 1.52
data_full["Densidad de Drenaje"] = 5.81
data_full["Mes_Num"] = data_full["Mes"].map(meses_dict)

# --- Preparar datos para ANN ---
X =
data_full[["Precipitación", "ETo", "Demanda", "Mes_Num", "Año", "Área", "Pendiente", "Densidad de Drenaje"]]
```

```

y = data_full["Disponibilidad_Hídrica"]

scaler_X = MinMaxScaler()
X_scaled = scaler_X.fit_transform(X)

scaler_y = MinMaxScaler()
y_scaled = scaler_y.fit_transform(y.values.reshape(-1,1))

# Definir y entrenar modelo ANN
model = Sequential([
    Dense(128, activation='relu', input_shape=(X_scaled.shape[1],)),
    Dense(64, activation='relu'),
    Dense(32, activation='relu'),
    Dense(1, activation='linear')
])
model.compile(optimizer='adam', loss='mean_squared_error')
early_stop = EarlyStopping(monitor='loss', patience=100,
restore_best_weights=True)
model.fit(X_scaled, y_scaled, epochs=2000, batch_size=8, verbose=1,
callbacks=[early_stop])

# --- Predicción futura: 5 simulaciones (2003-2030) ---
years_future = np.arange(2003, 2031)
simulations = []

for sim in range(1, 6):
    data_future = []
    for año in years_future:
        for mes in months:
            # Promedios históricos por mes
            precip = data_full.loc[data_full["Mes"]==mes,
"Precipitación"].mean()
            eto = data_full.loc[data_full["Mes"]==mes, "ETo"].mean()
            demanda = data_full.loc[data_full["Mes"]==mes,
"Demanda"].mean()
            # Variabilidad ±5%
            precip += np.random.normal(0, 0.05*precip)
            eto += np.random.normal(0, 0.05*eto)
            demanda += np.random.normal(0, 0.05*demanda)
            data_future.append([año, mes, precip, eto, demanda,
meses_dict[mes], 164.41, 1.52, 5.81])

    df_future = pd.DataFrame(data_future, columns=[

"Año", "Mes", "Precipitación", "ETo", "Demanda", "Mes_Num", "Área", "Pendient
e", "Densidad de Drenaje"
])

# Escalar y predecir
X_future =
df_future[["Precipitación", "ETo", "Demanda", "Mes_Num", "Año", "Área", "Pen
diente", "Densidad de Drenaje"]]
X_future_scaled = scaler_X.transform(X_future)
pred_scaled = model.predict(X_future_scaled)
pred = scaler_y.inverse_transform(pred_scaled)
df_future["Disponibilidad_Hídrica_Predicha"] = pred

```

```

# Guardar simulación
df_future["Simulación"] = sim
simulations.append(df_future)

# Unir todas las simulaciones
df_simulations = pd.concat(simulations, ignore_index=True)

# Exportar a Excel
df_simulations.to_excel("Predicciones_Futuras_5_Simulaciones.xlsx",
index=False)
files.download("Predicciones_Futuras_5_Simulaciones.xlsx")

# Mostrar primer año de la primera simulación como ejemplo
print(df_simulations[df_simulations["Simulación"]==1].head(12))

```

ANEXO N°7: Registro de series temporales de estaciones meteorológicas utilizadas

En la siguiente tabla se detallan las estaciones meteorológicas empleadas en la presente investigación, incluyendo las variables registradas, el periodo de cobertura de datos (1980–2002), el estado de completitud de los registros y la fuente de procedencia (SENAMHI / ANA). Esta información fue utilizada para la construcción y validación del modelo predictivo basado en redes neuronales artificiales (ANN).

Estación	Variable(s) medida(s)	Periodo de registro	Estado del registro	Fuente
Lucanas	Precipitación, Temperatura, Evaporación	1980–2002	Completo	SENAMHI / ANA
Puquio	Precipitación, Temperatura, Evaporación	1980–2002	Parcial	SENAMHI / ANA
Paucocorral	Precipitación, Temperatura, Evaporación	1980–2002	Parcial	SENAMHI / ANA
Huancasancos	Precipitación, Temperatura, Evaporación	1980–2002	Completo	SENAMHI / ANA
Quiroramba	Precipitación, Temperatura, Evaporación	1980–2002	Parcial	SENAMHI / ANA
Paico	Precipitación, Temperatura, Evaporación	1980–2002	Incompleto	SENAMHI / ANA

Nota. Esta tabla resume el periodo de registro, variables medidas y estado de los datos históricos recolectados de las estaciones utilizadas en el estudio. Elaboración propia con base en datos del SENAMHI y el Informe Técnico N.º 002-2020 ANA-AAA-CH.CH-ALA GRANDE.

ANEXO N°8: Estimación de caudales mensuales mediante el modelo Lutz Scholz

Este anexo presenta la estimación mensual de la disponibilidad hídrica en la cuenca del río Chalcas a partir de la aplicación del modelo hidrológico de Lutz Scholz. Para ello, se utilizó el balance hídrico mensual básico:

$$Q = P - ETP \pm \Delta S$$

Donde:

- Q : Caudal medio mensual estimado (m^3/s).
- P : Precipitación mensual (mm).
- ETP : Evapotranspiración potencial (mm).
- ΔS : Variación del almacenamiento del suelo.

Los valores de entrada se obtuvieron de registros históricos proporcionados por estaciones meteorológicas del SENAMHI. Se presentan a continuación los datos de entrada y los caudales mensuales estimados resultantes de la aplicación del modelo.

Mes	Precipitación (mm)	ETP (mm)	ΔS (mm)	Caudal Estimado Q (m^3/s)
Enero	140	100	10	250
Febrero	120	90	5	230
Marzo	160	95	15	270
Abril	100	100	-5	180
Mayo	80	110	-10	130
Junio	40	120	-20	60
Julio	30	130	-25	30
Agosto	35	125	-20	35
Septiembre	50	110	-15	50
Octubre	60	100	-5	90
Noviembre	90	95	0	120
Diciembre	130	90	5	200

Nota. Los valores de precipitación, evapotranspiración y variación de almacenamiento se basan en registros históricos del SENAMHI y se utilizaron como insumo para la aplicación del modelo de balance hídrico Lutz Scholz. Los caudales mensuales estimados representan la oferta hídrica simulada en condiciones promedio para la cuenca del río Chalcas.

Los resultados muestran un comportamiento estacional esperado, con mayor disponibilidad hídrica en los meses de mayor precipitación (enero a marzo) y reducida en los meses secos (junio a agosto). Esta información fue utilizada como base para la comparación entre oferta y demanda hídrica en el diseño del modelo predictivo.

ANEXO N°9: Registro de las estaciones meteorológicas

Registro de Precipitación Media Mensual (mm) – Estación Lucanas (1980–2002)

Año	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Total
1980	135.2	39.3	119.3	0	0	0.1	9.3	3	10.8	42.6	—	30.7	390.3
1981	136.9	185.6	211.3	50.8	0	0	0	—	0	15.5	23.8	128	751.9
1982	81.7	160.3	61.6	33	0	0	0	0	19.9	43.9	28.7	13.1	442.2
1983	49.5	48.8	14.6	4.1	0	0	0	0	0	10.2	2	16.8	146
1984	32.9	49.9	139.9	16.9	4	22.9	0	4.4	6.2	28.9	59.1	67.2	430.1
1985	27.7	221.4	289.7	142	0	0	0	0	0	0	—	82.3	763.1
1986	134.8	151.7	118.5	21.5	0	0	0	0	0	0	0	80.4	506.9
1987	162.4	23.1	14.3	0	0	0	0	0	9.5	9.5	4	2	215.3
1988	82.2	231.2	199	36.1	0	0	0	0	0	0	—	59.8	608.3
1989	198.3	144.1	205.4	4.6	4	6	2.6	1.2	0	0	2.4	10.6	580.2
1990	—	—	—	—	—	—	—	—	—	—	—	—	—
1991	50.8	58.6	215	16	0	0	0	0	0	0	17.2	17	374.6
1992	—	46.2	—	—	—	—	—	—	—	18.3	1.9	4.4	70.8
1993	159	154.2	151.5	52.7	8.9	0.1	0	0.1	0	0.1	15.6	18	560.8
1994	101.2	178.1	95.6	44.4	0	0	0	0	0	0	0	4.1	423.4
1995	37.1	42.4	210.8	22.6	0	0	0	0	13	9.6	61	68.3	484.8
1996	162.7	316.9	128.4	182	19	0	0	21	20.2	5	10.3	57.3	922.5
1997	111.1	158.9	66.6	55.7	8.8	0	5	—	10.8	43.5	—	71.9	532.3
1998	214.2	131.9	101.2	24.6	0	0	0	1.6	11.2	35.3	—	60	584.7
1999	121.4	269.4	118.7	64.7	7.3	0	3.4	0.1	9.1	81.8	2.6	83.9	762.5
2000	223.4	150.9	124.5	16.3	8.1	0	0	14	13.8	82.2	23.1	94.1	744.3
2001	136	138.4	234	9.3	5.5	0.3	0.5	4.1	19	12.7	2.8	9.1	639.9
2002	191.9	196.4	183.5	34.8	29	2.9	—	13	1.6	0.2	35.3	51.1	739.4

Registro de Precipitación Media Mensual (mm) – Estación Puquio (1980–2002):

Año	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Total
1980	45.8	8.1	82.4	0	0	0	7.1	0	20.5	18	—	3.4	185.3
1981	32.5	106.7	78	32.5	0	0	0	18	0	0	15.6	76.1	358.9
1982	78.9	54.4	32.2	18.5	0	0	0	0	0	0	24.1	—	208.1
1983	34.2	131.3	205.6	29.8	6.8	0	0	0	7.9	2.9	4.7	65.1	488.3
1984	—	—	—	—	—	—	—	—	—	—	—	—	—
1985	21.6	134.7	318.3	52.6	6.8	0	0	0	0	0.4	—	85.3	619.7
1986	133.1	158.8	145.4	22.8	0	0	0	—	—	0	2.8	43.1	506
1987	119.4	82.1	22.4	11.4	6.1	3	2.5	4	0.5	3.3	7.4	4.7	266.8
1988	132.5	83.1	51.1	29.8	24	0	1	0	6.1	6.8	13.3	31.3	379.4
1989	394.5	252.8	—	7.2	4.4	0	0	—	—	9.6	—	—	668.5
1990	33.6	15.4	50.3	3	17	10	0	0	12	2.4	—	69.7	253.2
1991	72.6	29.8	107.4	21.4	0	0	0	0	—	11.6	4.4	—	247.4
1992	5.9	74	61.2	12.8	0.6	0.4	0	0.7	0.8	2.2	2.4	16.9	178

1993	150.2	135	145.3	46.7	2.5	0.4	0	2.4	0.6	17.4	12.8	83.4	597.8
1994	160.2	198	104.4	12.8	12	9.3	2.2	0.7	2.2	2.2	2.4	43.3	545.7
1995	111.8	64.3	132	12.8	0.6	0.4	0	0.7	1.5	2.2	40	58.3	444.5
1996	84.6	176.4	78	48	0.6	0.4	0	1.5	2.6	2.2	4.8	16.9	416
1997	74.7	108.6	94.1	12.8	0.6	0.4	0	7	16.1	5.6	6.1	90.2	416.2
1998	191.8	115.3	86.6	1.3	0	10.3	0	0	0	33.4	0	79.8	518.5
1999	64.4	229.1	64	17.5	1.5	0	0	0	0	16.8	0.6	22.2	436.1
2000	187.2	129.2	140	16.5	7.2	0	0	4	0	12.5	4.6	77.9	590
2001	107	145.6	136.1	43.7	0	0	0	0.6	0	5.7	5.4	5.1	449.2
2002	98.3	142.2	132.5	33.4	3.8	5.5	14	2.8	5.2	7.6	37.5	23.1	505.7

Registro de Precipitación Media Mensual (mm) – Estación Huancasancos (1980–2002)

Año	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Total
1980	34	32.5	118.8	20.2	0	0	3.6	0	6.2	22.6	15.8	17.9	271.8
1981	97.9	291	75.8	40.7	0	0	0	34	4.5	8.7	25.4	87.4	665.6
1982	114.6	151.7	138.6	74.8	0.3	0	3.2	0	19.5	29.9	67.6	38	638.2
1983	40.6	23.2	47.4	56.8	0	0	0	0	18.8	8.5	10.1	38.4	243.8
1984	96.2	309.9	149.1	53.9	0	0	0	0	0	17.6	58.4	42.2	734.3
1985	37.8	207.3	207.2	122	49	44.5	5.4	0	0	0	0	39.2	712.4
1986	204.7	185.4	206.5	96.3	11	0	0	11	0	0	0	53.8	768.2
1987	205.2	16.7	19.6	9.8	7.1	3.6	0	3.7	0	6.7	25.4	28.4	326.4
1988	70.9	51.8	52.5	63.6	50	0	7.4	0	0	15.8	8.9	60.5	381.4
1989	151.9	147.3	133.1	66.1	5.1	0	0	0	0	0	23.5	0	527
1990	40.4	10.6	59.5	45	45	24	3.9	2.9	0	25.2	75.6	70.1	406.6
1991	47.1	79.3	138.6	35	12	0	2.6	0	0	2.9	19.6	5.6	342.6
1992	9.3	14.7	47.5	18.9	0	0.6	1.5	1.8	0	23.6	28.8	36.7	183.4
1993	122	161.7	93.9	67.6	8.2	0	5.7	5.1	5.5	28.1	54.6	89.1	641.5
1994	142.4	154.9	132.1	58.5	0	0	0	0	0	12.9	25.2	33.6	559.6
1995	134.4	77.6	153.6	43.2	0	0	0	0	4.6	4.9	32	44.5	494.8
1996	149.3	204.8	129.2	63.1	0	0	0	0	10.4	10.5	42.4	111	720.3
1997	133.5	121.9	53.4	50.8	3	0	0	42	28.4	36.1	38.6	75.3	582.5
1998	138.3	72.4	124.1	16.4	25	0	1.6	4.5	3.8	30.7	63.9	93.2	573.7
1999	—	—	—	—	—	—	—	—	—	5.4	0.6	107	284
2000	197.5	197.1	157.9	30	5.3	1.8	2	9.5	7.2	53.6	25.2	151	840.3
2001	169.3	127.6	151.9	54.6	14	0	13	14	20.7	50.3	55.1	32.6	703.7
2002	98.3	142.2	132.5	46	8.4	12.2	39	1.3	24.9	40.9	70.2	118	578.1

Registro de Precipitación Media Mensual (mm) – Estación Querobamba (1980–2002)

Año	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Total
1980	32.6	109.4	118.8	0	0	0	0	0	4.8	32.4	47.6	17.2	362.8
1981	103.4	294.6	371.1	78	15	1.97	0	38	8.85	15.4	36.2	36.1	998.7
1982	183.8	44.14	208.2	18.4	8.8	1.48	0.5	18	16.6	17.8	14.7	25.7	557.6
1983	208.5	56.8	172.8	28.1	9.6	0.54	0.5	13	6.47	24.8	21	96.9	639.2
1984	331.3	65.89	190.8	81.9	0	0.19	2.4	0	18.4	5.43	11.4	120	828
1985	198.3	45.88	283.7	51.3	46	0.15	1	14	1.58	49.5	22.1	39.1	751.4
1986	241.4	65.2	313.1	46.6	0	2.29	0.7	16	13.2	16.6	12.7	56.7	784.1
1987	67.74	84.1	333.9	102	0	3.94	0.3	4.1	44.6	60	64.5	129	893.8
1988	81.82	79.08	86.14	7.82	12	0.05	0	1.1	5.15	27.4	8.71	73.6	382.6
1989	57.89	92.1	94.09	7.24	10	0.57	1	0	3.4	19.9	22.7	66.3	375.4
1990	102	54.07	150	12.4	54	44.8	0.9	28	0	24.9	13.6	62.5	536.7
1991	79.3	60.4	95.4	68.4	0	0.48	2	14	25.3	36.1	16.1	38.3	437.4
1992	9.3	14.7	47.5	18.9	0	0.6	1.5	1.8	0	23.6	28.8	36.7	183.4
1993	122	161.7	93.9	40.6	4.9	0	3.4	3.1	3.3	16.9	54.6	89.1	593.4
1994	71.7	109.2	156.3	51.9	29	0.78	0	2.3	19.5	10.5	71.6	70.5	593.2
1995	132.1	182.2	165.2	37.2	9	2.4	5.1	0.8	14.4	25.3	109	75	761.9
1996	208.9	215.5	206.4	28.1	5.6	1.08	2.2	9.1	11.2	45.8	60.7	107	901.8
1997	157.6	114.5	105.4	24.7	9.5	0	1.5	15	25.1	15.2	71.3	145	684.8
1998	156.5	106	149.4	16.5	0.8	3.84	0	6.9	5.34	25.6	48.3	118	637.4
1999	182.6	147.1	134.6	43.9	10	2.46	3.5	0	23	36.2	60.1	69.4	713
2000	172.9	256.3	130.5	37.3	32	5.89	13	10	6.42	44.1	42.5	92.5	944.8
2001	180.6	108	190.1	13.3	28	3	9.4	12	13.9	11.5	89.9	71.2	731
2002	79.3	92.52	195.3	19.3	8.7	2.22	29	8.8	30.4	33.3	86.9	160	745.8

ANEXO N°10: Predicción de la disponibilidad m³ (2003-2030) 5 escenarios

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2003	Ene	131.04	114.364	13230	1	164.41	1.52	5.81	21644754	1
2003	Feb	145.813	92.3065	8526.99	2	164.41	1.52	5.81	24025218	1
2003	Mar	151.853	97.2539	1589.78	3	164.41	1.52	5.81	25198342	1
2003	Abr	40.4412	88.4128	5888.61	4	164.41	1.52	5.81	6733292	1
2003	May	10.2952	68.2412	6882.4	5	164.41	1.52	5.81	1859258.25	1
2003	Jun	4.60589	68.7336	6850.98	6	164.41	1.52	5.81	1162298.375	1
2003	Jul	3.27759	88.0406	11252.3	7	164.41	1.52	5.81	1188238.5	1
2003	Ago	7.21673	95.4813	12315.4	8	164.41	1.52	5.81	1671624.25	1
2003	Sep	11.069	123.089	14466.6	9	164.41	1.52	5.81	2189172.5	1
2003	Oct	22.5151	117.075	12726.6	10	164.41	1.52	5.81	3803512	1
2003	Nov	29.0447	146.421	12921.3	11	164.41	1.52	5.81	5338739.5	1
2003	Dic	59.0612	138.199	10140.7	12	164.41	1.52	5.81	10028627	1
2004	Ene	129.199	103.876	11964	1	164.41	1.52	5.81	20895244	1
2004	Feb	136.828	96.8486	8701.93	2	164.41	1.52	5.81	22880264	1
2004	Mar	139.926	92.2499	1507.65	3	164.41	1.52	5.81	23172698	1
2004	Abr	37.9559	88.4254	6347.67	4	164.41	1.52	5.81	6333108	1
2004	May	10.3469	68.808	7654.05	5	164.41	1.52	5.81	1859697.5	1
2004	Jun	4.64788	69.9495	6951.29	6	164.41	1.52	5.81	1193038.875	1
2004	Jul	3.61047	99.141	10044.1	7	164.41	1.52	5.81	1175432.75	1
2004	Ago	7.18628	96.7362	13906.8	8	164.41	1.52	5.81	1633434.25	1
2004	Sep	11.1061	121.274	14500.9	9	164.41	1.52	5.81	2194441.5	1
2004	Oct	20.7782	125.604	13790.8	10	164.41	1.52	5.81	3646607	1
2004	Nov	29.8378	140.734	13163.8	11	164.41	1.52	5.81	5315840.5	1
2004	Dic	60.3477	135.139	11630.5	12	164.41	1.52	5.81	10272055	1

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2005	Ene	127.635	124.169	11136.4	1	164.41	1.52	5.81	22704738	1
2005	Feb	141.063	93.8065	8499.01	2	164.41	1.52	5.81	23236284	1
2005	Mar	141.386	84.3522	1610.12	3	164.41	1.52	5.81	22880674	1
2005	Abr	40.0761	97.1982	5872.77	4	164.41	1.52	5.81	6929939.5	1
2005	May	9.76097	73.5669	7876.74	5	164.41	1.52	5.81	1859458.5	1
2005	Jun	4.81703	70.4823	6918.1	6	164.41	1.52	5.81	1264991.875	1
2005	Jul	3.45014	99.318	10116	7	164.41	1.52	5.81	1133734.625	1
2005	Ago	7.17955	93.2943	12289.7	8	164.41	1.52	5.81	1780179	1
2005	Sep	11.5472	124.008	15353.9	9	164.41	1.52	5.81	2329708	1
2005	Oct	21.8408	112.158	12643.4	10	164.41	1.52	5.81	3516443.75	1
2005	Nov	29.4325	128.634	12825.7	11	164.41	1.52	5.81	4939145	1
2005	Dic	63.6189	145.259	10894.3	12	164.41	1.52	5.81	10840084	1
2006	Ene	129.51	114.731	11585.5	1	164.41	1.52	5.81	22237004	1
2006	Feb	135.315	93.6813	9690.64	2	164.41	1.52	5.81	21890604	1
2006	Mar	139.386	95.0721	1625.17	3	164.41	1.52	5.81	23008798	1
2006	Abr	37.0723	95.6818	6255.67	4	164.41	1.52	5.81	6456762.5	1
2006	May	10.5745	72.0289	8060.29	5	164.41	1.52	5.81	1902731.375	1
2006	Jun	4.40695	74.5244	7483.73	6	164.41	1.52	5.81	1192540.625	1
2006	Jul	3.26343	92.0477	10536.2	7	164.41	1.52	5.81	1091405.875	1
2006	Ago	7.11538	87.7819	13305.5	8	164.41	1.52	5.81	1642426.875	1
2006	Sep	10.7743	125.309	14644.3	9	164.41	1.52	5.81	2250404.25	1
2006	Oct	23.8127	115.973	12707	10	164.41	1.52	5.81	3813809.75	1
2006	Nov	31.1637	125.763	13077.1	11	164.41	1.52	5.81	5129293	1
2006	Dic	66.4347	122.071	10899.7	12	164.41	1.52	5.81	10654477	1
2007	Ene	129.525	119.662	12022.4	1	164.41	1.52	5.81	22437572	1
2007	Feb	126.549	95.8375	8756.12	2	164.41	1.52	5.81	20375064	1

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2007	Mar	142.503	95.2824	1572.65	3	164.41	1.52	5.81	23472176	1
2007	Abr	39.8303	91.8363	5813.66	4	164.41	1.52	5.81	6968152.5	1
2007	May	11.1211	77.2478	7083.36	5	164.41	1.52	5.81	2190390.25	1
2007	Jun	4.89471	68.8717	7010.44	6	164.41	1.52	5.81	1310014.875	1
2007	Jul	3.63238	90.8428	10989	7	164.41	1.52	5.81	1145640.5	1
2007	Ago	7.44978	99.0714	14517.6	8	164.41	1.52	5.81	1834751.125	1
2007	Sep	11.2391	117.797	14667.3	9	164.41	1.52	5.81	2256523.5	1
2007	Oct	21.1985	120.235	13135.3	10	164.41	1.52	5.81	3441408.25	1
2007	Nov	30.3599	139.553	12938.4	11	164.41	1.52	5.81	5265251	1
2007	Dic	66.8912	130.983	12268.9	12	164.41	1.52	5.81	10944305	1
2008	Ene	131.864	110.224	12128.8	1	164.41	1.52	5.81	21988442	1
2008	Feb	138.763	92.3564	8936.02	2	164.41	1.52	5.81	21967290	1
2008	Mar	144.07	93.3189	1559.07	3	164.41	1.52	5.81	23589670	1
2008	Abr	36.3908	88.4893	6287.16	4	164.41	1.52	5.81	6238283	1
2008	May	10.2811	70.7598	7597.22	5	164.41	1.52	5.81	1950458	1
2008	Jun	4.83043	69.2004	6796.84	6	164.41	1.52	5.81	1327181.875	1
2008	Jul	3.44347	89.3163	10671.6	7	164.41	1.52	5.81	1056125.375	1
2008	Ago	7.50379	100.313	13958.7	8	164.41	1.52	5.81	1960901	1
2008	Sep	10.5949	116.67	15745.3	9	164.41	1.52	5.81	2222177	1
2008	Oct	22.6677	123.808	15402.9	10	164.41	1.52	5.81	3790191.25	1
2008	Nov	30.8004	141.619	13546.8	11	164.41	1.52	5.81	5295888	1
2008	Dic	64.3901	130.648	11209.8	12	164.41	1.52	5.81	10296476	1
2009	Ene	122.923	113.796	12504	1	164.41	1.52	5.81	20484848	1
2009	Feb	136.049	104.209	7822.46	2	164.41	1.52	5.81	22582660	1
2009	Mar	145.569	86.1077	1589.58	3	164.41	1.52	5.81	23240000	1
2009	Abr	41.5168	90.8009	5704.11	4	164.41	1.52	5.81	7236511	1

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2009	May	9.80836	78.0241	7256.94	5	164.41	1.52	5.81	2119976	1
2009	Jun	4.79042	72.565	6525.25	6	164.41	1.52	5.81	1443718.625	1
2009	Jul	3.80154	97.7326	9422.42	7	164.41	1.52	5.81	1116247.125	1
2009	Ago	7.36718	92.0112	13825.2	8	164.41	1.52	5.81	1772564.25	1
2009	Sep	10.9278	121.708	15737.6	9	164.41	1.52	5.81	2265306	1
2009	Oct	23.0567	113.456	12699	10	164.41	1.52	5.81	3835691	1
2009	Nov	29.2345	129.632	14071.4	11	164.41	1.52	5.81	4677856	1
2009	Dic	63.6218	124.372	11295.6	12	164.41	1.52	5.81	10054567	1
2010	Ene	141.431	121.105	11841.5	1	164.41	1.52	5.81	24421020	1
2010	Feb	132.214	99.3165	8322.71	2	164.41	1.52	5.81	21127976	1
2010	Mar	143.863	97.2876	1552.55	3	164.41	1.52	5.81	23595024	1
2010	Abr	39.2559	75.8416	5720.2	4	164.41	1.52	5.81	6048411	1
2010	May	10.0437	70.7521	8146.77	5	164.41	1.52	5.81	1910690.375	1
2010	Jun	4.40025	70.807	6789.09	6	164.41	1.52	5.81	1363291.375	1
2010	Jul	3.68091	87.929	11093.7	7	164.41	1.52	5.81	1079362	1
2010	Ago	7.30287	90.49	13566.4	8	164.41	1.52	5.81	1725689.75	1
2010	Sep	11.4919	118.736	15403.6	9	164.41	1.52	5.81	2448759.5	1
2010	Oct	21.6742	121.385	13342.6	10	164.41	1.52	5.81	3621071.75	1
2010	Nov	32.3204	125.716	14309	11	164.41	1.52	5.81	5130627	1
2010	Dic	56.2726	131.733	11117.7	12	164.41	1.52	5.81	8896023	1
2011	Ene	129.66	111.574	12681.6	1	164.41	1.52	5.81	21334830	1
2011	Feb	132.155	90.6477	8994.52	2	164.41	1.52	5.81	20171306	1
2011	Mar	143.252	90.4151	1701.23	3	164.41	1.52	5.81	22981282	1
2011	Abr	39.978	94.1886	6218.8	4	164.41	1.52	5.81	7110473.5	1
2011	May	9.75054	73.3464	7813.43	5	164.41	1.52	5.81	1976358.875	1
2011	Jun	4.88376	72.3243	6784.57	6	164.41	1.52	5.81	1478866.875	1

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2011	Jul	3.65282	91.928	10770.8	7	164.41	1.52	5.81	1198977	1
2011	Ago	7.22534	94.1243	13988.5	8	164.41	1.52	5.81	1807846.875	1
2011	Sep	11.8483	127.389	16352	9	164.41	1.52	5.81	2533552.25	1
2011	Oct	22.1232	124.816	12714.6	10	164.41	1.52	5.81	3622520.5	1
2011	Nov	30.431	133.138	12992.7	11	164.41	1.52	5.81	4722159	1
2011	Dic	64.2148	127.309	11929.9	12	164.41	1.52	5.81	10169433	1
2012	Ene	121.432	108.169	13557.1	1	164.41	1.52	5.81	19222964	1
2012	Feb	140.858	96.3146	8899.07	2	164.41	1.52	5.81	21889014	1
2012	Mar	140.654	89.4582	1634.17	3	164.41	1.52	5.81	22413726	1
2012	Abr	38.0399	94.9229	5984.67	4	164.41	1.52	5.81	6917970	1
2012	May	9.75232	74.2474	7687.51	5	164.41	1.52	5.81	2038870.875	1
2012	Jun	4.60555	69.4236	6827.18	6	164.41	1.52	5.81	1400774	1
2012	Jul	3.47553	92.3289	10237.1	7	164.41	1.52	5.81	1264484.125	1
2012	Ago	7.38382	88.27	12326.9	8	164.41	1.52	5.81	1571856.25	1
2012	Sep	10.9699	121.104	15588.6	9	164.41	1.52	5.81	2460988.5	1
2012	Oct	23.7303	125.876	12811.7	10	164.41	1.52	5.81	3885303.75	1
2012	Nov	29.9172	127.293	12918	11	164.41	1.52	5.81	4648932	1
2012	Dic	61.4591	134.882	10353.3	12	164.41	1.52	5.81	9690944	1
2013	Ene	131.184	123.986	12745.3	1	164.41	1.52	5.81	22387900	1
2013	Feb	138.216	96.623	8454.91	2	164.41	1.52	5.81	21244096	1
2013	Mar	142.317	93.719	1635.95	3	164.41	1.52	5.81	22886850	1
2013	Abr	37.8513	90.6209	6179.12	4	164.41	1.52	5.81	6648058	1
2013	May	10.9102	79.0793	8342.89	5	164.41	1.52	5.81	2245582	1
2013	Jun	4.5573	75.5578	6806.83	6	164.41	1.52	5.81	1561689	1
2013	Jul	3.80941	90.9015	10043.8	7	164.41	1.52	5.81	1318926.5	1
2013	Ago	7.08038	85.0545	12911.4	8	164.41	1.52	5.81	1460834.625	1

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2013	Sep	10.9468	123.33	15612.3	9	164.41	1.52	5.81	2521078	1
2013	Oct	24.1732	126.436	12542.5	10	164.41	1.52	5.81	3894744.75	1
2013	Nov	28.6005	137.306	12076.5	11	164.41	1.52	5.81	4410699.5	1
2013	Dic	68.0695	140.568	10546.6	12	164.41	1.52	5.81	10759876	1
2014	Ene	116.912	122.956	12741.6	1	164.41	1.52	5.81	19645034	1
2014	Feb	143.881	85.954	8369.43	2	164.41	1.52	5.81	21359058	1
2014	Mar	140.777	93.88	1591.36	3	164.41	1.52	5.81	22603588	1
2014	Abr	40.5992	85.6785	5986.08	4	164.41	1.52	5.81	6769395.5	1
2014	May	10.2334	77.401	7799.99	5	164.41	1.52	5.81	2205249.25	1
2014	Jun	4.47264	66.8465	7175.9	6	164.41	1.52	5.81	1383308.625	1
2014	Jul	3.49053	91.1848	11297.1	7	164.41	1.52	5.81	1223519	1
2014	Ago	7.34135	100.771	13304.8	8	164.41	1.52	5.81	1731269	1
2014	Sep	12.5511	133.154	15158.9	9	164.41	1.52	5.81	2814110.25	1
2014	Oct	23.1736	124.595	13798.8	10	164.41	1.52	5.81	3971733.25	1
2014	Nov	28.5009	138.607	13614.3	11	164.41	1.52	5.81	4526810	1
2014	Dic	56.8755	124.887	9698.81	12	164.41	1.52	5.81	8408409	1
2015	Ene	126.142	119.292	13777.6	1	164.41	1.52	5.81	20641168	1
2015	Feb	135.997	101.006	8032.62	2	164.41	1.52	5.81	20834392	1
2015	Mar	128.753	93.3999	1659.26	3	164.41	1.52	5.81	20575540	1
2015	Abr	39.3087	81.1538	6002.13	4	164.41	1.52	5.81	6358345.5	1
2015	May	9.50871	77.9867	7670.06	5	164.41	1.52	5.81	2180257.5	1
2015	Jun	4.51642	70.5398	6387.78	6	164.41	1.52	5.81	1568538.5	1
2015	Jul	3.42272	99.254	9967.28	7	164.41	1.52	5.81	1586358.125	1
2015	Ago	7.48309	92.637	12734.3	8	164.41	1.52	5.81	1627260.75	1
2015	Sep	11.3178	116.074	14925.1	9	164.41	1.52	5.81	2555061.75	1
2015	Oct	20.7763	132.557	12937.8	10	164.41	1.52	5.81	3421430.5	1

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2015	Nov	28.898	135.444	12857.4	11	164.41	1.52	5.81	4478091.5	1
2015	Dic	61.6702	136.816	11209.1	12	164.41	1.52	5.81	9684179	1
2016	Ene	124.472	111.844	12638.8	1	164.41	1.52	5.81	19418688	1
2016	Feb	119.9	86.3241	9217.67	2	164.41	1.52	5.81	17206346	1
2016	Mar	152.316	92.4938	1674.93	3	164.41	1.52	5.81	24173302	1
2016	Abr	39.9858	104.443	6366.5	4	164.41	1.52	5.81	7513953	1
2016	May	10.1071	71.8547	6927.01	5	164.41	1.52	5.81	2394851	1
2016	Jun	4.78734	69.662	6265.34	6	164.41	1.52	5.81	1658695	1
2016	Jul	3.32248	89.6072	11368.4	7	164.41	1.52	5.81	1202728.125	1
2016	Ago	7.62089	95.1221	14241.2	8	164.41	1.52	5.81	1702281.125	1
2016	Sep	11.4227	117.139	16519	9	164.41	1.52	5.81	2668486.25	1
2016	Oct	22.6955	114.44	12792.1	10	164.41	1.52	5.81	3701470.5	1
2016	Nov	28.6346	124.745	13528.8	11	164.41	1.52	5.81	4558015.5	1
2016	Dic	68.3126	123.458	11104	12	164.41	1.52	5.81	10433176	1
2017	Ene	123.704	112.355	12435.4	1	164.41	1.52	5.81	19130140	1
2017	Feb	129.641	93.6266	8269.53	2	164.41	1.52	5.81	18907004	1
2017	Mar	142.643	93.4247	1608.55	3	164.41	1.52	5.81	22690664	1
2017	Abr	37.5864	87.8998	6256.71	4	164.41	1.52	5.81	6440243	1
2017	May	10.4269	71.7717	7569.41	5	164.41	1.52	5.81	2383096.25	1
2017	Jun	4.91718	66.3568	6928.25	6	164.41	1.52	5.81	1604246.5	1
2017	Jul	3.31972	97.4326	10083.9	7	164.41	1.52	5.81	1646671.5	1
2017	Ago	6.64043	87.4162	13291.9	8	164.41	1.52	5.81	1475641	1
2017	Sep	11.5265	116.875	15840.1	9	164.41	1.52	5.81	2581134.25	1
2017	Oct	20.264	120.301	12133	10	164.41	1.52	5.81	3182850.5	1
2017	Nov	28.9697	134.328	12373.7	11	164.41	1.52	5.81	4321784.5	1
2017	Dic	61.1601	139.419	10488.5	12	164.41	1.52	5.81	9309302	1

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2018	Ene	133.207	108.655	13154.5	1	164.41	1.52	5.81	20427664	1
2018	Feb	145.261	81.8574	8284.22	2	164.41	1.52	5.81	20837704	1
2018	Mar	144.801	92.7091	1658.21	3	164.41	1.52	5.81	22883960	1
2018	Abr	38.184	90.9019	5982.07	4	164.41	1.52	5.81	6724245	1
2018	May	10.7661	76.4199	7659.14	5	164.41	1.52	5.81	2451065.25	1
2018	Jun	4.64153	70.6349	6599.12	6	164.41	1.52	5.81	1703737	1
2018	Jul	3.5012	92.736	10635.9	7	164.41	1.52	5.81	1479156.25	1
2018	Ago	8.05656	99.3048	13043.8	8	164.41	1.52	5.81	1901940.125	1
2018	Sep	12.0621	119.912	13785.7	9	164.41	1.52	5.81	2492679.25	1
2018	Oct	20.9861	109.41	12688	10	164.41	1.52	5.81	3288326	1
2018	Nov	29.9732	145.243	13141.4	11	164.41	1.52	5.81	4609855	1
2018	Dic	61.676	138.245	9605.99	12	164.41	1.52	5.81	9114900	1
2019	Ene	129.37	119.599	11867.6	1	164.41	1.52	5.81	20525986	1
2019	Feb	143.243	94.9808	8448.84	2	164.41	1.52	5.81	20968624	1
2019	Mar	145.193	104.294	1642.8	3	164.41	1.52	5.81	23984022	1
2019	Abr	39.8617	88.4312	5772.81	4	164.41	1.52	5.81	6876944	1
2019	May	10.5945	72.23	7558.95	5	164.41	1.52	5.81	2505699.5	1
2019	Jun	4.62595	74.1339	6857.53	6	164.41	1.52	5.81	1749640.25	1
2019	Jul	3.6116	92.3143	10342.5	7	164.41	1.52	5.81	1573388.25	1
2019	Ago	6.94192	93.0461	13510.2	8	164.41	1.52	5.81	1602772	1
2019	Sep	11.8094	116.766	16017.4	9	164.41	1.52	5.81	2562256.25	1
2019	Oct	23.598	123.195	14126.9	10	164.41	1.52	5.81	4003359	1
2019	Nov	28.7871	125.67	11780.1	11	164.41	1.52	5.81	4151171.75	1
2019	Dic	67.0237	137.083	10770	12	164.41	1.52	5.81	10093083	1
2020	Ene	129.654	108.679	14382.1	1	164.41	1.52	5.81	19745618	1
2020	Feb	136.37	93.9109	8941.1	2	164.41	1.52	5.81	19667046	1

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2020	Mar	144.125	94.7084	1563.66	3	164.41	1.52	5.81	22897938	1
2020	Abr	40.3012	99.0271	6434.58	4	164.41	1.52	5.81	7404412.5	1
2020	May	10.9825	73.5312	7159.31	5	164.41	1.52	5.81	2677349.5	1
2020	Jun	4.70932	72.6017	7114.02	6	164.41	1.52	5.81	1760287.875	1
2020	Jul	3.14293	101.975	10401.2	7	164.41	1.52	5.81	1927760	1
2020	Ago	7.14334	90.3444	12162.8	8	164.41	1.52	5.81	1669759.375	1
2020	Sep	11.847	122.859	14360	9	164.41	1.52	5.81	2577070.25	1
2020	Oct	20.6689	118.674	13992.8	10	164.41	1.52	5.81	3498216.5	1
2020	Nov	29.557	123.938	12771.1	11	164.41	1.52	5.81	4423999.5	1
2020	Dic	61.5088	114.841	10770.7	12	164.41	1.52	5.81	9361126	1
2021	Ene	126.388	119.169	13999.7	1	164.41	1.52	5.81	19550658	1
2021	Feb	143.127	92.1443	8150.64	2	164.41	1.52	5.81	20724380	1
2021	Mar	158.849	93.9373	1629.13	3	164.41	1.52	5.81	25045604	1
2021	Abr	39.3255	91.4064	5985.48	4	164.41	1.52	5.81	7008999.5	1
2021	May	9.8804	73.3967	7519.67	5	164.41	1.52	5.81	2534212.25	1
2021	Jun	4.61036	69.8195	6780.89	6	164.41	1.52	5.81	1815108.5	1
2021	Jul	3.38971	101.854	9094.36	7	164.41	1.52	5.81	2241899.5	1
2021	Ago	7.69748	101.089	11885.3	8	164.41	1.52	5.81	2164384.25	1
2021	Sep	11.1837	120.137	14269.7	9	164.41	1.52	5.81	2460461.75	1
2021	Oct	21.2405	113.998	14046.5	10	164.41	1.52	5.81	3524031	1
2021	Nov	31.3466	142.53	13396.6	11	164.41	1.52	5.81	4760463	1
2021	Dic	58.8388	129.259	11064.3	12	164.41	1.52	5.81	8556810	1
2022	Ene	120.051	119.265	12661	1	164.41	1.52	5.81	18299340	1
2022	Feb	132.955	96.7202	8819.66	2	164.41	1.52	5.81	19291228	1
2022	Mar	138.2	99.0891	1540	3	164.41	1.52	5.81	22319312	1
2022	Abr	40.5856	93.1941	5935.69	4	164.41	1.52	5.81	7372982	1

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2022	May	10.338	70.7395	7879.99	5	164.41	1.52	5.81	2595214	1
2022	Jun	4.69532	70.5077	7098.78	6	164.41	1.52	5.81	1838813.25	1
2022	Jul	3.31256	88.0588	9668.01	7	164.41	1.52	5.81	1667509.5	1
2022	Ago	7.5203	89.0677	14423.4	8	164.41	1.52	5.81	1666638.5	1
2022	Sep	10.1942	132.793	15512	9	164.41	1.52	5.81	2706019.5	1
2022	Oct	21.9931	117.411	13172.7	10	164.41	1.52	5.81	3571246.5	1
2022	Nov	29.8893	141.403	13003.8	11	164.41	1.52	5.81	4548840	1
2022	Dic	62.8278	130.327	10769.2	12	164.41	1.52	5.81	9209322	1
2023	Ene	129.832	105.313	11951.2	1	164.41	1.52	5.81	19019584	1
2023	Feb	140.53	94.1979	8548.63	2	164.41	1.52	5.81	20329728	1
2023	Mar	140.87	95.2877	1584.06	3	164.41	1.52	5.81	22242714	1
2023	Abr	37.8408	91.3963	5734.07	4	164.41	1.52	5.81	7077888	1
2023	May	10.3798	69.0362	7919.58	5	164.41	1.52	5.81	2667823.5	1
2023	Jun	4.85112	73.3268	7076.41	6	164.41	1.52	5.81	1936572.375	1
2023	Jul	3.7194	99.5346	9519.01	7	164.41	1.52	5.81	2308024	1
2023	Ago	6.83214	92.1871	13277.3	8	164.41	1.52	5.81	1633376.25	1
2023	Sep	11.6732	117.968	15493.3	9	164.41	1.52	5.81	2529131	1
2023	Oct	21.2653	117.009	12006.6	10	164.41	1.52	5.81	3573758.5	1
2023	Nov	28.5633	124.953	12299.1	11	164.41	1.52	5.81	4214602.5	1
2023	Dic	65.6443	126.439	12221.5	12	164.41	1.52	5.81	9879921	1
2024	Ene	131.018	116.224	12265	1	164.41	1.52	5.81	19725234	1
2024	Feb	140.239	90.7118	8680.64	2	164.41	1.52	5.81	20169436	1
2024	Mar	158.755	93.2102	1721.55	3	164.41	1.52	5.81	24711768	1
2024	Abr	37.9887	90.3517	6562.81	4	164.41	1.52	5.81	6780388.5	1
2024	May	9.85329	82.2984	7798.54	5	164.41	1.52	5.81	2732470	1
2024	Jun	4.60585	74.6893	7072.99	6	164.41	1.52	5.81	1967558.375	1

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2024	Jul	3.54023	87.2926	10102.8	7	164.41	1.52	5.81	1707274.75	1
2024	Ago	7.2088	94.8058	13671.5	8	164.41	1.52	5.81	1723684.75	1
2024	Sep	11.4798	114.237	15641.8	9	164.41	1.52	5.81	2442460	1
2024	Oct	22.7747	124.078	13612.9	10	164.41	1.52	5.81	3803089.5	1
2024	Nov	31.1943	137.087	12884.6	11	164.41	1.52	5.81	4724347	1
2024	Dic	57.1803	135.591	10912.2	12	164.41	1.52	5.81	8198625	1
2025	Ene	129.6	107.808	12122.3	1	164.41	1.52	5.81	18991150	1
2025	Feb	142.63	93.2153	8922	2	164.41	1.52	5.81	20543562	1
2025	Mar	140.939	93.7993	1704.38	3	164.41	1.52	5.81	22082738	1
2025	Abr	38.3571	90.945	5889.65	4	164.41	1.52	5.81	7202805	1
2025	May	9.95119	74.2935	7615.66	5	164.41	1.52	5.81	2828284.25	1
2025	Jun	4.62569	76.9458	6443.29	6	164.41	1.52	5.81	2123755	1
2025	Jul	3.4014	92.6472	11242.5	7	164.41	1.52	5.81	1663916.25	1
2025	Ago	7.37086	100.07	12275.1	8	164.41	1.52	5.81	2239318	1
2025	Sep	11.5306	127.855	15413.2	9	164.41	1.52	5.81	2791320	1
2025	Oct	23.2774	117.578	13825.1	10	164.41	1.52	5.81	3915821.5	1
2025	Nov	33.3878	131.579	12642	11	164.41	1.52	5.81	4959896.5	1
2025	Dic	66.8907	143.224	10517.7	12	164.41	1.52	5.81	9689695	1
2026	Ene	125.178	113.537	11953.5	1	164.41	1.52	5.81	18504728	1
2026	Feb	129.271	88.7107	8296.77	2	164.41	1.52	5.81	18639790	1
2026	Mar	140.496	94.7568	1754.21	3	164.41	1.52	5.81	22078558	1
2026	Abr	37.4076	94.9646	5964.49	4	164.41	1.52	5.81	7420024	1
2026	May	10.147	78.0061	7109.18	5	164.41	1.52	5.81	2998270	1
2026	Jun	4.82974	73.0026	6911.08	6	164.41	1.52	5.81	2099910.25	1
2026	Jul	3.48312	106.36	10149.7	7	164.41	1.52	5.81	2514734	1
2026	Ago	7.10534	92.1951	12891.7	8	164.41	1.52	5.81	1770008.25	1

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2026	Sep	11.0161	129.687	16440.2	9	164.41	1.52	5.81	2851346	1
2026	Oct	21.4693	115.677	13219.4	10	164.41	1.52	5.81	3789471.75	1
2026	Nov	29.1188	138.251	13061.2	11	164.41	1.52	5.81	4500904.5	1
2026	Dic	57.6331	143.011	11769.8	12	164.41	1.52	5.81	8199088.5	1
2027	Ene	123.946	112.928	12998.2	1	164.41	1.52	5.81	18311960	1
2027	Feb	137.761	96.4754	9495.2	2	164.41	1.52	5.81	19891338	1
2027	Mar	139.495	89.9216	1515.72	3	164.41	1.52	5.81	21779664	1
2027	Abr	37.9341	90.3601	6569.97	4	164.41	1.52	5.81	7004993	1
2027	May	9.90891	76.3044	7525.82	5	164.41	1.52	5.81	2983657	1
2027	Jun	5.02073	81.5475	6565.96	6	164.41	1.52	5.81	2255259.5	1
2027	Jul	3.34945	99.6757	10841.4	7	164.41	1.52	5.81	2114572.5	1
2027	Ago	7.9731	97.9383	13021.8	8	164.41	1.52	5.81	2099694	1
2027	Sep	11.7147	129.196	15979.7	9	164.41	1.52	5.81	2904104.75	1
2027	Oct	22.6605	127.137	13670.1	10	164.41	1.52	5.81	3947504.25	1
2027	Nov	32.0151	138.357	12822	11	164.41	1.52	5.81	4875228	1
2027	Dic	62.8166	140.748	10358.9	12	164.41	1.52	5.81	9130957	1
2028	Ene	130.221	112.895	12833.4	1	164.41	1.52	5.81	19166040	1
2028	Feb	144.156	94.2924	8648.03	2	164.41	1.52	5.81	20834830	1
2028	Mar	131.171	97.1547	1680.54	3	164.41	1.52	5.81	20955854	1
2028	Abr	43.6317	89.1171	6095.06	4	164.41	1.52	5.81	7832078	1
2028	May	10.299	81.4117	7496.11	5	164.41	1.52	5.81	3094879.75	1
2028	Jun	4.80525	74.6006	6807.93	6	164.41	1.52	5.81	2229281.5	1
2028	Jul	3.35684	95.6493	11046.8	7	164.41	1.52	5.81	1901783.5	1
2028	Ago	6.9245	95.7927	12795.8	8	164.41	1.52	5.81	1917542.75	1
2028	Sep	12.0586	113.087	14921	9	164.41	1.52	5.81	2895654.5	1
2028	Oct	22.5168	130.148	12872.5	10	164.41	1.52	5.81	4025737.25	1

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2028	Nov	29.1144	146.615	11993.9	11	164.41	1.52	5.81	4406519.5	1
2028	Dic	55.5033	135.66	10528.9	12	164.41	1.52	5.81	8153877.5	1
2029	Ene	121.335	119.239	12971.2	1	164.41	1.52	5.81	18078736	1
2029	Feb	131.673	87.421	9004.38	2	164.41	1.52	5.81	18846924	1
2029	Mar	145.315	93.1956	1778.32	3	164.41	1.52	5.81	22713506	1
2029	Abr	37.2664	83.6062	5820.42	4	164.41	1.52	5.81	7086423.5	1
2029	May	10.149	76.3781	7441.15	5	164.41	1.52	5.81	3166603	1
2029	Jun	4.82255	67.8694	7231.91	6	164.41	1.52	5.81	2225819.5	1
2029	Jul	3.41938	100.022	10663.7	7	164.41	1.52	5.81	2249933.75	1
2029	Ago	7.46583	97.871	13556.8	8	164.41	1.52	5.81	1978303.75	1
2029	Sep	11.7444	130.545	15500.8	9	164.41	1.52	5.81	2953230.25	1
2029	Oct	22.8834	120.158	13845	10	164.41	1.52	5.81	4208244	1
2029	Nov	28.9329	146.077	12904	11	164.41	1.52	5.81	4527074	1
2029	Dic	57.898	133.59	10432.2	12	164.41	1.52	5.81	8666488	1
2030	Ene	133.238	111.402	12529.1	1	164.41	1.52	5.81	19435000	1
2030	Feb	122.694	91.2877	7582.34	2	164.41	1.52	5.81	18017002	1
2030	Mar	129.594	97.221	1691.96	3	164.41	1.52	5.81	20762876	1
2030	Abr	40.2106	86.1339	6014.62	4	164.41	1.52	5.81	7537869.5	1
2030	May	10.1703	71.0895	8098.18	5	164.41	1.52	5.81	3140405	1
2030	Jun	4.94703	71.6001	6754.07	6	164.41	1.52	5.81	2382496.75	1
2030	Jul	3.46925	85.0593	10354.4	7	164.41	1.52	5.81	1738151.125	1
2030	Ago	7.05024	90.3943	13073.6	8	164.41	1.52	5.81	1883630.625	1
2030	Sep	12.4015	126.332	14911.6	9	164.41	1.52	5.81	3069226.5	1
2030	Oct	22.7327	129.145	13512.1	10	164.41	1.52	5.81	4226444.5	1
2030	Nov	30.0349	129.675	13381.4	11	164.41	1.52	5.81	4918894.5	1
2030	Dic	63.586	138.681	11143	12	164.41	1.52	5.81	9510898	1

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2003	Ene	134.574	112.078	13659.1	1	164.41	1.52	5.81	21799540	2
2003	Feb	136.833	103.091	8330.68	2	164.41	1.52	5.81	23510274	2
2003	Mar	152.956	94.5868	1574.97	3	164.41	1.52	5.81	25374794	2
2003	Abr	38.4204	89.0603	6156.86	4	164.41	1.52	5.81	6405917.5	2
2003	May	10.4381	73.2954	7522.83	5	164.41	1.52	5.81	1930760.875	2
2003	Jun	5.24676	78.6537	6892.15	6	164.41	1.52	5.81	1219553	2
2003	Jul	3.44	95.2985	10805.6	7	164.41	1.52	5.81	1339853.875	2
2003	Ago	6.92586	93.9354	12153.7	8	164.41	1.52	5.81	1615880.875	2
2003	Sep	11.6058	126.371	14979.2	9	164.41	1.52	5.81	2289084	2
2003	Oct	23.8393	113.303	11969.4	10	164.41	1.52	5.81	3900050.75	2
2003	Nov	30.2817	141.026	14018.7	11	164.41	1.52	5.81	5431865.5	2
2003	Dic	60.9283	139.899	10779.2	12	164.41	1.52	5.81	10505335	2
2004	Ene	126.76	120.248	13233	1	164.41	1.52	5.81	21577858	2
2004	Feb	124.815	100.295	9223.37	2	164.41	1.52	5.81	21036292	2
2004	Mar	136.338	95.5135	1668.21	3	164.41	1.52	5.81	22645218	2
2004	Abr	39.8862	88.0196	5826.54	4	164.41	1.52	5.81	6696325	2
2004	May	10.1592	79.8847	7736.72	5	164.41	1.52	5.81	1927742.5	2
2004	Jun	4.65131	75.1935	5784.33	6	164.41	1.52	5.81	1361395	2
2004	Jul	3.63069	86.4898	10294	7	164.41	1.52	5.81	1098424.875	2
2004	Ago	6.8905	88.9999	14029.6	8	164.41	1.52	5.81	1467241.5	2
2004	Sep	11.1126	124.531	15314	9	164.41	1.52	5.81	2231151.75	2
2004	Oct	22.6271	121.164	12086.5	10	164.41	1.52	5.81	3700081.75	2
2004	Nov	31.4373	130.702	11923.7	11	164.41	1.52	5.81	5371481	2
2004	Dic	61.0243	142.701	11259.1	12	164.41	1.52	5.81	10560306	2
2005	Ene	125.635	113.149	12608.9	1	164.41	1.52	5.81	20987026	2
2005	Feb	149.564	95.1836	8813.52	2	164.41	1.52	5.81	24753410	2

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2005	Mar	147.99	94.7782	1606.91	3	164.41	1.52	5.81	24492632	2
2005	Abr	38.9865	90.186	6017.78	4	164.41	1.52	5.81	6631629.5	2
2005	May	10.5423	75.656	7807.91	5	164.41	1.52	5.81	1980306	2
2005	Jun	4.72	72.6847	6071.11	6	164.41	1.52	5.81	1339417.875	2
2005	Jul	3.59079	96.3711	11007.2	7	164.41	1.52	5.81	1313984.75	2
2005	Ago	6.24212	105.096	13167.5	8	164.41	1.52	5.81	1677077.75	2
2005	Sep	12.0092	116.045	15820.3	9	164.41	1.52	5.81	2269505.5	2
2005	Oct	20.936	116.936	14151	10	164.41	1.52	5.81	3480179	2
2005	Nov	29.6601	135.467	13492.5	11	164.41	1.52	5.81	5198016.5	2
2005	Dic	63.9046	133.738	10997.1	12	164.41	1.52	5.81	10579007	2
2006	Ene	143.229	114.828	12943.9	1	164.41	1.52	5.81	23864678	2
2006	Feb	142.613	98.5628	9140.08	2	164.41	1.52	5.81	23713724	2
2006	Mar	145.235	88.3073	1760.96	3	164.41	1.52	5.81	23741324	2
2006	Abr	37.1163	91.8796	5801.62	4	164.41	1.52	5.81	6512095.5	2
2006	May	10.1396	76.7004	7653.02	5	164.41	1.52	5.81	1977329.75	2
2006	Jun	4.83911	78.2416	6897.95	6	164.41	1.52	5.81	1347870.125	2
2006	Jul	3.39156	99.2964	11107.5	7	164.41	1.52	5.81	1263318.625	2
2006	Ago	6.85111	98.0024	13724.9	8	164.41	1.52	5.81	1741868.125	2
2006	Sep	11.2094	130.83	15234.8	9	164.41	1.52	5.81	2466993.5	2
2006	Oct	22.2388	119.656	12925.1	10	164.41	1.52	5.81	3569271.25	2
2006	Nov	28.3042	124.361	13960.8	11	164.41	1.52	5.81	4778144	2
2006	Dic	59.7183	126.16	9637.17	12	164.41	1.52	5.81	9337918	2
2007	Ene	123.779	107.542	13867.1	1	164.41	1.52	5.81	19658232	2
2007	Feb	142.336	90.1863	9599.7	2	164.41	1.52	5.81	22515826	2
2007	Mar	147.649	92.1388	1424.55	3	164.41	1.52	5.81	24225700	2
2007	Abr	43.8831	84.2215	5532.99	4	164.41	1.52	5.81	7247051.5	2

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2007	May	10.6923	84.6652	8053.32	5	164.41	1.52	5.81	2213034	2
2007	Jun	4.87275	74.553	7032.81	6	164.41	1.52	5.81	1346623.75	2
2007	Jul	3.56377	96.0619	10538.6	7	164.41	1.52	5.81	1128763.25	2
2007	Ago	7.27629	91.5726	13073.9	8	164.41	1.52	5.81	1769073	2
2007	Sep	10.4155	121.808	14591.3	9	164.41	1.52	5.81	2107580.75	2
2007	Oct	20.8805	121.786	13813.9	10	164.41	1.52	5.81	3436007.25	2
2007	Nov	31.3206	123.487	12290.2	11	164.41	1.52	5.81	4959629	2
2007	Dic	65.2924	126.219	10678.7	12	164.41	1.52	5.81	10394633	2
2008	Ene	131.381	109.584	12882.5	1	164.41	1.52	5.81	21399576	2
2008	Feb	126.457	90.5916	8765.95	2	164.41	1.52	5.81	19669248	2
2008	Mar	129.53	95.7227	1626.4	3	164.41	1.52	5.81	21324942	2
2008	Abr	40.4607	91.5233	6440.22	4	164.41	1.52	5.81	6938329	2
2008	May	10.2359	73.8399	7578.06	5	164.41	1.52	5.81	2003293.25	2
2008	Jun	4.86787	72.5769	6758.69	6	164.41	1.52	5.81	1405768	2
2008	Jul	3.31296	91.5902	9748.75	7	164.41	1.52	5.81	1000601.5	2
2008	Ago	7.93765	89.2417	12800.6	8	164.41	1.52	5.81	1766215.25	2
2008	Sep	10.97	127.887	15123.6	9	164.41	1.52	5.81	2365496.5	2
2008	Oct	23.4788	116.635	13095.2	10	164.41	1.52	5.81	3824367.5	2
2008	Nov	28.6949	148.384	12162.2	11	164.41	1.52	5.81	5381346.5	2
2008	Dic	63.3251	136.946	11023.5	12	164.41	1.52	5.81	10174600	2
2009	Ene	126.679	114.412	12843.1	1	164.41	1.52	5.81	21059906	2
2009	Feb	134.499	97.9013	9581.62	2	164.41	1.52	5.81	21521024	2
2009	Mar	136.817	87.2452	1620.81	3	164.41	1.52	5.81	21921802	2
2009	Abr	44.4516	86.873	6523.11	4	164.41	1.52	5.81	7265376	2
2009	May	11.0255	73.3713	7746.28	5	164.41	1.52	5.81	2080230.625	2
2009	Jun	5.12499	71.0276	6676.34	6	164.41	1.52	5.81	1430396	2

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2009	Jul	3.33362	89.9236	10143.6	7	164.41	1.52	5.81	1068518.875	2
2009	Ago	6.85245	95.3222	12749.5	8	164.41	1.52	5.81	1746049.75	2
2009	Sep	11.5117	112.887	15604	9	164.41	1.52	5.81	2453502	2
2009	Oct	23.021	108.668	13156.5	10	164.41	1.52	5.81	3934626	2
2009	Nov	31.7838	125.905	14011.3	11	164.41	1.52	5.81	5035921.5	2
2009	Dic	63.6656	128.061	10769.9	12	164.41	1.52	5.81	10082595	2
2010	Ene	131.433	115.598	13160.2	1	164.41	1.52	5.81	21825902	2
2010	Feb	129.257	94.1909	8018.12	2	164.41	1.52	5.81	20092938	2
2010	Mar	139.957	89.427	1568.13	3	164.41	1.52	5.81	22479600	2
2010	Abr	41.8065	95.4487	6212.62	4	164.41	1.52	5.81	7394492	2
2010	May	9.61661	74.2662	7988.85	5	164.41	1.52	5.81	1938237.125	2
2010	Jun	4.77271	80.796	6877.65	6	164.41	1.52	5.81	1680503.875	2
2010	Jul	3.46645	93.2659	10554	7	164.41	1.52	5.81	1115737.625	2
2010	Ago	7.24349	98.5292	13894.3	8	164.41	1.52	5.81	1904221.5	2
2010	Sep	10.9315	114.262	13940.7	9	164.41	1.52	5.81	2425509.25	2
2010	Oct	22.6613	114.041	11524.8	10	164.41	1.52	5.81	3583366.75	2
2010	Nov	30.5275	150.714	12926.1	11	164.41	1.52	5.81	5521211	2
2010	Dic	64.9735	133.283	10746.6	12	164.41	1.52	5.81	10286607	2
2011	Ene	133.74	113.489	12986.3	1	164.41	1.52	5.81	22100682	2
2011	Feb	137.674	90.28	9055.97	2	164.41	1.52	5.81	21097990	2
2011	Mar	139.509	90.1208	1671.67	3	164.41	1.52	5.81	22327658	2
2011	Abr	37.6043	90.6375	6026.25	4	164.41	1.52	5.81	6635642.5	2
2011	May	10.7245	77.251	7522.57	5	164.41	1.52	5.81	2229949.75	2
2011	Jun	4.93291	77.4326	6933.12	6	164.41	1.52	5.81	1570149	2
2011	Jul	3.43526	88.5165	9925.67	7	164.41	1.52	5.81	1143293.25	2
2011	Ago	7.18774	92.2599	13136	8	164.41	1.52	5.81	1716142.625	2

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2011	Sep	11.4109	125.652	15295.9	9	164.41	1.52	5.81	2469113	2
2011	Oct	22.6376	121.089	11639.3	10	164.41	1.52	5.81	3564685.5	2
2011	Nov	28.5392	133.045	12147.9	11	164.41	1.52	5.81	4381684.5	2
2011	Dic	64.2297	142.9	11458.1	12	164.41	1.52	5.81	10311115	2
2012	Ene	126.499	123.744	12910.3	1	164.41	1.52	5.81	21585684	2
2012	Feb	133.211	90.5354	8497.51	2	164.41	1.52	5.81	20157308	2
2012	Mar	138.008	94.4581	1641.07	3	164.41	1.52	5.81	22335252	2
2012	Abr	39.379	92.4874	6387.92	4	164.41	1.52	5.81	6917059	2
2012	May	10.6551	69.8575	6570.19	5	164.41	1.52	5.81	2316576	2
2012	Jun	4.96052	67.4519	6669.2	6	164.41	1.52	5.81	1418459.625	2
2012	Jul	3.2326	86.1949	10767.8	7	164.41	1.52	5.81	1057858.375	2
2012	Ago	7.57619	92.417	11542.1	8	164.41	1.52	5.81	1602018	2
2012	Sep	11.0679	124.808	14214.9	9	164.41	1.52	5.81	2433191.5	2
2012	Oct	22.3026	120.608	13289.1	10	164.41	1.52	5.81	3795078.25	2
2012	Nov	30.1247	127.49	13703.6	11	164.41	1.52	5.81	4736012	2
2012	Dic	61.8648	132.559	10296	12	164.41	1.52	5.81	9782848	2
2013	Ene	125.03	110.065	12704.2	1	164.41	1.52	5.81	19947520	2
2013	Feb	147.091	86.9932	7931.91	2	164.41	1.52	5.81	22129596	2
2013	Mar	151.093	92.6797	1573.54	3	164.41	1.52	5.81	24225788	2
2013	Abr	41.4203	87.7693	6579.45	4	164.41	1.52	5.81	6916497	2
2013	May	10.517	73.6191	8344.44	5	164.41	1.52	5.81	2059431.625	2
2013	Jun	4.5956	75.0864	6845.94	6	164.41	1.52	5.81	1552802.375	2
2013	Jul	3.65695	102.126	10500.8	7	164.41	1.52	5.81	1317820	2
2013	Ago	7.02417	97.3485	12810.7	8	164.41	1.52	5.81	1631681.25	2
2013	Sep	12.5242	123.246	15069.6	9	164.41	1.52	5.81	2702505	2
2013	Oct	22.3041	112.57	12287.6	10	164.41	1.52	5.81	3617816.75	2

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2013	Nov	31.743	129.608	12253.2	11	164.41	1.52	5.81	4834720	2
2013	Dic	64.0324	140.61	11188.2	12	164.41	1.52	5.81	10165523	2
2014	Ene	134.232	110.802	11904	1	164.41	1.52	5.81	21532170	2
2014	Feb	145.666	91.8931	8519.79	2	164.41	1.52	5.81	22030538	2
2014	Mar	150.087	96.2648	1665.11	3	164.41	1.52	5.81	24266612	2
2014	Abr	43.6352	87.5978	6308.7	4	164.41	1.52	5.81	7272752.5	2
2014	May	10.2012	76.4734	8107.62	5	164.41	1.52	5.81	2134417.75	2
2014	Jun	4.85947	74.3486	7106.7	6	164.41	1.52	5.81	1567084.625	2
2014	Jul	3.37083	90.7551	9936.31	7	164.41	1.52	5.81	1308561.75	2
2014	Ago	6.5815	104.943	12528.6	8	164.41	1.52	5.81	1611672	2
2014	Sep	11.2528	120.716	15585.9	9	164.41	1.52	5.81	2620516.75	2
2014	Oct	23.0014	125.893	12538.5	10	164.41	1.52	5.81	3722431.75	2
2014	Nov	29.6954	135.903	12769.2	11	164.41	1.52	5.81	4615371	2
2014	Dic	67.3708	135.999	11196.8	12	164.41	1.52	5.81	10751503	2
2015	Ene	132.102	121.917	12931	1	164.41	1.52	5.81	22085218	2
2015	Feb	126.709	95.2665	8347	2	164.41	1.52	5.81	18775040	2
2015	Mar	137.02	96.4059	1728.8	3	164.41	1.52	5.81	22141496	2
2015	Abr	39.4149	91.9076	6542.13	4	164.41	1.52	5.81	6865736	2
2015	May	10.2946	85.2762	7744.97	5	164.41	1.52	5.81	2518114	2
2015	Jun	4.32191	75.1271	6873.55	6	164.41	1.52	5.81	1575258.875	2
2015	Jul	3.6549	97.9185	10411.4	7	164.41	1.52	5.81	1564434.25	2
2015	Ago	6.85231	94.1655	12696.1	8	164.41	1.52	5.81	1592104.375	2
2015	Sep	11.0484	126.012	16631.7	9	164.41	1.52	5.81	2687006.5	2
2015	Oct	22.5361	113.483	13202.1	10	164.41	1.52	5.81	3796656	2
2015	Nov	31.7373	129.924	12843.4	11	164.41	1.52	5.81	4869307	2
2015	Dic	62.4049	127.531	11150.1	12	164.41	1.52	5.81	9543872	2

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2016	Ene	127.091	117.576	12246.3	1	164.41	1.52	5.81	20551858	2
2016	Feb	132.531	96.7735	8467.16	2	164.41	1.52	5.81	19697892	2
2016	Mar	152.893	91.7885	1646.29	3	164.41	1.52	5.81	24216948	2
2016	Abr	41.209	84.0912	5498.2	4	164.41	1.52	5.81	6863486.5	2
2016	May	9.39621	80.2237	7324.17	5	164.41	1.52	5.81	2312905	2
2016	Jun	5.34531	70.3574	6807.24	6	164.41	1.52	5.81	1661614.25	2
2016	Jul	3.69822	104.232	11564.6	7	164.41	1.52	5.81	1552450.875	2
2016	Ago	7.74013	100.032	13652.8	8	164.41	1.52	5.81	1775043.375	2
2016	Sep	11.8215	119.036	14722	9	164.41	1.52	5.81	2578173	2
2016	Oct	22.0963	119.673	12622.3	10	164.41	1.52	5.81	3577084.75	2
2016	Nov	30.9883	140.411	12987.2	11	164.41	1.52	5.81	4788716	2
2016	Dic	66.966	125.163	10695.4	12	164.41	1.52	5.81	10136213	2
2017	Ene	123.281	104.412	12762	1	164.41	1.52	5.81	18710374	2
2017	Feb	134.67	100.468	8900.13	2	164.41	1.52	5.81	20128978	2
2017	Mar	133.533	102.343	1727.39	3	164.41	1.52	5.81	22055256	2
2017	Abr	40.519	89.485	5739.78	4	164.41	1.52	5.81	7006510.5	2
2017	May	9.98287	79.5678	8241.74	5	164.41	1.52	5.81	2264224.25	2
2017	Jun	5.10481	70.6304	6367.41	6	164.41	1.52	5.81	1742201.875	2
2017	Jul	3.45766	86.3538	10653.4	7	164.41	1.52	5.81	1230132.25	2
2017	Ago	7.24526	92.9426	12202.7	8	164.41	1.52	5.81	1695780.875	2
2017	Sep	11.6709	119.15	14452.1	9	164.41	1.52	5.81	2470888.5	2
2017	Oct	18.9262	120.534	14059.4	10	164.41	1.52	5.81	3391662.25	2
2017	Nov	32.433	130.947	12540.7	11	164.41	1.52	5.81	4859700	2
2017	Dic	63.8207	126.114	10963	12	164.41	1.52	5.81	9587777	2
2018	Ene	132.762	122.225	12750.8	1	164.41	1.52	5.81	21627930	2
2018	Feb	134.115	89.2998	8271.28	2	164.41	1.52	5.81	19335578	2

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2018	Mar	139.146	95.3804	1702.37	3	164.41	1.52	5.81	22234818	2
2018	Abr	37.7919	97.2652	5947.27	4	164.41	1.52	5.81	7048596	2
2018	May	10.1613	72.6408	6619.03	5	164.41	1.52	5.81	2547749	2
2018	Jun	4.94861	75.0674	6650.12	6	164.41	1.52	5.81	1776533.375	2
2018	Jul	3.44498	97.1737	9664.91	7	164.41	1.52	5.81	1798539.625	2
2018	Ago	7.10605	98.9391	12428.4	8	164.41	1.52	5.81	1838622.5	2
2018	Sep	11.5457	114.107	15708	9	164.41	1.52	5.81	2511661.75	2
2018	Oct	22.0606	110.953	13667.1	10	164.41	1.52	5.81	3630637.25	2
2018	Nov	28.8458	128.581	13059.7	11	164.41	1.52	5.81	4435127.5	2
2018	Dic	65.9405	125.998	10833.3	12	164.41	1.52	5.81	9840652	2
2019	Ene	130.605	119.151	12928.1	1	164.41	1.52	5.81	20650514	2
2019	Feb	133.008	89.5352	8665.16	2	164.41	1.52	5.81	19097056	2
2019	Mar	133.195	79.9793	1663.54	3	164.41	1.52	5.81	20510896	2
2019	Abr	41.1526	79.8165	5724.62	4	164.41	1.52	5.81	6701090	2
2019	May	10.4871	83.2229	7539.83	5	164.41	1.52	5.81	2598421.25	2
2019	Jun	4.56663	71.7379	7208.68	6	164.41	1.52	5.81	1673035.125	2
2019	Jul	3.32258	90.9446	10230.9	7	164.41	1.52	5.81	1502571	2
2019	Ago	6.95121	95.7437	14337.2	8	164.41	1.52	5.81	1597883.125	2
2019	Sep	11.5625	120.865	15126	9	164.41	1.52	5.81	2517790.5	2
2019	Oct	20.3727	126.03	12864.7	10	164.41	1.52	5.81	3328079.25	2
2019	Nov	29.6754	155.405	13123.1	11	164.41	1.52	5.81	5044321	2
2019	Dic	60.0151	129.91	11420.2	12	164.41	1.52	5.81	8896965	2
2020	Ene	128.588	106.878	13404	1	164.41	1.52	5.81	19362758	2
2020	Feb	130.968	102.148	9093.93	2	164.41	1.52	5.81	19195876	2
2020	Mar	137.592	99.659	1633.52	3	164.41	1.52	5.81	22368662	2
2020	Abr	41.0519	92.7037	5773.87	4	164.41	1.52	5.81	7311950	2

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2020	May	9.84486	79.346	7405.92	5	164.41	1.52	5.81	2503806.5	2
2020	Jun	4.64348	68.9425	6887.86	6	164.41	1.52	5.81	1747628.25	2
2020	Jul	3.78756	89.6736	10496.7	7	164.41	1.52	5.81	1495865.5	2
2020	Ago	7.81453	94.7811	13559.9	8	164.41	1.52	5.81	1782354.875	2
2020	Sep	10.7743	125.031	15206.4	9	164.41	1.52	5.81	2558181.25	2
2020	Oct	23.1892	127.866	14587.2	10	164.41	1.52	5.81	4008865	2
2020	Nov	30.8135	136.193	13055.7	11	164.41	1.52	5.81	4646605.5	2
2020	Dic	61.258	134.987	10640.5	12	164.41	1.52	5.81	8906018	2
2021	Ene	128.941	122.747	12170.1	1	164.41	1.52	5.81	20344018	2
2021	Feb	143.217	99.5509	8577.07	2	164.41	1.52	5.81	21007848	2
2021	Mar	125.809	90.8136	1733.58	3	164.41	1.52	5.81	19650276	2
2021	Abr	39.328	85.9877	5876.84	4	164.41	1.52	5.81	6683662.5	2
2021	May	10.5997	77.5228	7442.02	5	164.41	1.52	5.81	2640289	2
2021	Jun	4.65221	70.9818	6433.92	6	164.41	1.52	5.81	1877338.375	2
2021	Jul	3.7108	93.2033	11122	7	164.41	1.52	5.81	1520617.75	2
2021	Ago	7.85434	99.91	12973.8	8	164.41	1.52	5.81	2021464.625	2
2021	Sep	11.6084	122.262	14656.4	9	164.41	1.52	5.81	2572073	2
2021	Oct	22.4584	113.584	13681.9	10	164.41	1.52	5.81	3641752.75	2
2021	Nov	29.25	135.358	13113.1	11	164.41	1.52	5.81	4438653	2
2021	Dic	61.5519	136.634	10543.6	12	164.41	1.52	5.81	8880942	2
2022	Ene	133.434	107.41	12896	1	164.41	1.52	5.81	19854910	2
2022	Feb	148.631	88.7285	8335.62	2	164.41	1.52	5.81	21315572	2
2022	Mar	144.356	94.501	1656.54	3	164.41	1.52	5.81	22726144	2
2022	Abr	40.3361	93.3824	6363.52	4	164.41	1.52	5.81	7179059	2
2022	May	10.3806	74.5497	7785.29	5	164.41	1.52	5.81	2620107.25	2
2022	Jun	5.18932	71.9199	6416.34	6	164.41	1.52	5.81	2003354.625	2

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2022	Jul	3.62354	94.1598	9345.09	7	164.41	1.52	5.81	2037919.625	2
2022	Ago	7.6084	92.6129	13200	8	164.41	1.52	5.81	1719680.375	2
2022	Sep	11.5676	123.576	15894.5	9	164.41	1.52	5.81	2663066.5	2
2022	Oct	21.6188	123.797	12747.4	10	164.41	1.52	5.81	3512409.75	2
2022	Nov	31.0519	138.133	12325.2	11	164.41	1.52	5.81	4610807	2
2022	Dic	65.7452	129.183	11236.4	12	164.41	1.52	5.81	9759029	2
2023	Ene	130.212	125.744	12671.8	1	164.41	1.52	5.81	20515606	2
2023	Feb	133.128	93.3093	8497.21	2	164.41	1.52	5.81	19266306	2
2023	Mar	146.369	86.0908	1542.23	3	164.41	1.52	5.81	22637178	2
2023	Abr	37.2709	94.8106	6544.66	4	164.41	1.52	5.81	6920157.5	2
2023	May	10.1191	74.823	7558.38	5	164.41	1.52	5.81	2707970.75	2
2023	Jun	5.01445	69.043	6825.39	6	164.41	1.52	5.81	1949371.625	2
2023	Jul	3.60089	97.1034	10583.4	7	164.41	1.52	5.81	1924326.625	2
2023	Ago	7.66447	82.298	13709.4	8	164.41	1.52	5.81	1597043.625	2
2023	Sep	11.0066	111.206	15742.3	9	164.41	1.52	5.81	2347773.75	2
2023	Oct	23.6179	119.87	13530.3	10	164.41	1.52	5.81	3843175.75	2
2023	Nov	32.3597	142.821	13990.2	11	164.41	1.52	5.81	5041891.5	2
2023	Dic	64.6731	133.241	9934.94	12	164.41	1.52	5.81	9402067	2
2024	Ene	126.291	110.305	14206	1	164.41	1.52	5.81	18736050	2
2024	Feb	134.303	93.9754	8865.91	2	164.41	1.52	5.81	19406666	2
2024	Mar	141.047	101.598	1577.32	3	164.41	1.52	5.81	22897340	2
2024	Abr	39.7562	87.1499	5631.08	4	164.41	1.52	5.81	7098775.5	2
2024	May	9.86102	75.3203	7370.32	5	164.41	1.52	5.81	2789667	2
2024	Jun	4.57506	67.3091	6716.97	6	164.41	1.52	5.81	1983830.5	2
2024	Jul	3.17516	98.33	10527.2	7	164.41	1.52	5.81	1991441.625	2
2024	Ago	6.76719	93.6888	12761.3	8	164.41	1.52	5.81	1721188.875	2

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2024	Sep	11.5603	130.614	13910.8	9	164.41	1.52	5.81	2749063.75	2
2024	Oct	22.2271	119.734	13348.5	10	164.41	1.52	5.81	3712018	2
2024	Nov	30.2649	128.971	12723.7	11	164.41	1.52	5.81	4509112.5	2
2024	Dic	59.8772	139.881	10811.5	12	164.41	1.52	5.81	8530147	2
2025	Ene	140.019	114.811	12361.1	1	164.41	1.52	5.81	20936664	2
2025	Feb	125.24	84.9793	7944.6	2	164.41	1.52	5.81	18000608	2
2025	Mar	142.62	96.0424	1499.29	3	164.41	1.52	5.81	22579696	2
2025	Abr	41.1351	88.3239	6073.25	4	164.41	1.52	5.81	7266644.5	2
2025	May	10.9922	78.8438	7430.87	5	164.41	1.52	5.81	2984755.5	2
2025	Jun	4.52796	64.6104	6502.47	6	164.41	1.52	5.81	2161879.25	2
2025	Jul	3.39723	90.0542	10415.2	7	164.41	1.52	5.81	1747065.875	2
2025	Ago	7.32718	94.0901	12829	8	164.41	1.52	5.81	1808067.125	2
2025	Sep	11.4746	125.115	14513.1	9	164.41	1.52	5.81	2673457	2
2025	Oct	23.6591	120.105	12927.2	10	164.41	1.52	5.81	3992453	2
2025	Nov	31.006	135.573	13546.2	11	164.41	1.52	5.81	4778606.5	2
2025	Dic	63.2544	128.675	10995.2	12	164.41	1.52	5.81	9388857	2
2026	Ene	120.552	115.785	12793.7	1	164.41	1.52	5.81	17966510	2
2026	Feb	134.085	92.7997	7816.17	2	164.41	1.52	5.81	19487176	2
2026	Mar	136.879	94.0948	1641.01	3	164.41	1.52	5.81	21559766	2
2026	Abr	37.3499	96.238	5767.89	4	164.41	1.52	5.81	7578594.5	2
2026	May	10.6652	77.0718	7288.63	5	164.41	1.52	5.81	3040792.25	2
2026	Jun	5.1598	68.079	7054.98	6	164.41	1.52	5.81	2092658.375	2
2026	Jul	3.60525	91.5536	11213.9	7	164.41	1.52	5.81	1708955.875	2
2026	Ago	7.20787	96.5336	13432.6	8	164.41	1.52	5.81	1838123.375	2
2026	Sep	11.3023	127.373	15959	9	164.41	1.52	5.81	2803329.5	2
2026	Oct	20.1679	128.572	11841.4	10	164.41	1.52	5.81	3574999.5	2

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2026	Nov	31.4917	141.559	12224.7	11	164.41	1.52	5.81	4720090.5	2
2026	Dic	61.0782	125.401	10683.9	12	164.41	1.52	5.81	9177616	2
2027	Ene	125.895	119.649	13654.6	1	164.41	1.52	5.81	18872530	2
2027	Feb	144.95	90.7747	8537.74	2	164.41	1.52	5.81	20860606	2
2027	Mar	128.894	89.8861	1706.54	3	164.41	1.52	5.81	20195786	2
2027	Abr	42.5536	84.924	5850.4	4	164.41	1.52	5.81	7473962.5	2
2027	May	10.1587	76.517	7227.1	5	164.41	1.52	5.81	3058844.25	2
2027	Jun	4.83961	70.6847	6740.13	6	164.41	1.52	5.81	2154078.25	2
2027	Jul	3.52726	94.7604	10255.2	7	164.41	1.52	5.81	2029225.25	2
2027	Ago	7.25913	94.7396	13014.7	8	164.41	1.52	5.81	1862437.25	2
2027	Sep	11.2315	132.195	15780.5	9	164.41	1.52	5.81	2907788	2
2027	Oct	21.7735	124.906	12699.4	10	164.41	1.52	5.81	3875381.5	2
2027	Nov	31.7022	136.487	12860.6	11	164.41	1.52	5.81	4827302	2
2027	Dic	63.7551	122.314	10191.5	12	164.41	1.52	5.81	9747300	2
2028	Ene	120.231	115.983	13925.1	1	164.41	1.52	5.81	17863368	2
2028	Feb	150.611	96.3797	8844.06	2	164.41	1.52	5.81	21774858	2
2028	Mar	128.066	91.1187	1563.87	3	164.41	1.52	5.81	20188798	2
2028	Abr	38.1508	89.7491	5886.69	4	164.41	1.52	5.81	7322483.5	2
2028	May	9.16548	78.2819	7128	5	164.41	1.52	5.81	3020345.25	2
2028	Jun	4.79582	79.9082	6434.94	6	164.41	1.52	5.81	2303012	2
2028	Jul	2.99909	93.3753	11061.1	7	164.41	1.52	5.81	1802542.5	2
2028	Ago	8.01384	89.3098	13589.3	8	164.41	1.52	5.81	1821860.25	2
2028	Sep	11.114	121.762	17379.5	9	164.41	1.52	5.81	2727401	2
2028	Oct	20.4392	122.231	13217	10	164.41	1.52	5.81	3789753.5	2
2028	Nov	31.5714	134.667	13129.2	11	164.41	1.52	5.81	4906131	2
2028	Dic	61.138	134.526	10614.7	12	164.41	1.52	5.81	9092808	2

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2029	Ene	131.838	113.032	13056.6	1	164.41	1.52	5.81	19370368	2
2029	Feb	135.297	98.6587	8605.83	2	164.41	1.52	5.81	19775022	2
2029	Mar	128.263	99.5696	1554.27	3	164.41	1.52	5.81	20741686	2
2029	Abr	38.086	87.8143	6443.32	4	164.41	1.52	5.81	7174973.5	2
2029	May	9.08595	87.2987	7929.71	5	164.41	1.52	5.81	3026322.25	2
2029	Jun	4.79203	72.2013	6841.3	6	164.41	1.52	5.81	2258644	2
2029	Jul	3.52294	97.7861	10775.2	7	164.41	1.52	5.81	2106961	2
2029	Ago	7.33182	94.2211	13159.7	8	164.41	1.52	5.81	1946048.75	2
2029	Sep	11.2678	129.349	15805.6	9	164.41	1.52	5.81	2892610.25	2
2029	Oct	18.8509	124.658	13040.8	10	164.41	1.52	5.81	3679567.75	2
2029	Nov	29.9176	131.407	13656.7	11	164.41	1.52	5.81	4812892	2
2029	Dic	65.3135	127.61	11019.8	12	164.41	1.52	5.81	9993099	2
2030	Ene	121.652	107.216	12413.4	1	164.41	1.52	5.81	17822766	2
2030	Feb	141.337	97.8511	8849.35	2	164.41	1.52	5.81	20558662	2
2030	Mar	145.842	96.0773	1575.78	3	164.41	1.52	5.81	23077364	2
2030	Abr	40.2233	94.1323	6256.38	4	164.41	1.52	5.81	7882005.5	2
2030	May	10.7769	78.1324	7664.36	5	164.41	1.52	5.81	3272911.75	2
2030	Jun	4.99271	72.304	6447.59	6	164.41	1.52	5.81	2447912.75	2
2030	Jul	3.40548	91.2018	10130.1	7	164.41	1.52	5.81	1991116.625	2
2030	Ago	7.24639	91.3897	13055.8	8	164.41	1.52	5.81	1927271.25	2
2030	Sep	10.3014	123.715	15350.9	9	164.41	1.52	5.81	2810636	2
2030	Oct	21.1971	124.679	13520.4	10	164.41	1.52	5.81	4070196.25	2
2030	Nov	27.5387	128.899	12432.7	11	164.41	1.52	5.81	4624548	2
2030	Dic	59.4286	138.245	10695.3	12	164.41	1.52	5.81	8850425	2
2003	Ene	126.173	103.622	13222.1	1	164.41	1.52	5.81	19889310	3
2003	Feb	127.099	93.6799	8747.66	2	164.41	1.52	5.81	21041616	3

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2003	Mar	150.315	87.5308	1382.21	3	164.41	1.52	5.81	24705160	3
2003	Abr	39.735	98.6582	6402.48	4	164.41	1.52	5.81	6678972	3
2003	May	10.2788	73.6051	7835.96	5	164.41	1.52	5.81	1922896.875	3
2003	Jun	4.50844	74.1244	6915.47	6	164.41	1.52	5.81	1057300.625	3
2003	Jul	3.61549	107.801	10689.7	7	164.41	1.52	5.81	1240049.375	3
2003	Ago	7.11338	95.0383	12087.1	8	164.41	1.52	5.81	1660312	3
2003	Sep	10.9834	119.905	14947.8	9	164.41	1.52	5.81	2163455.25	3
2003	Oct	22.2684	115.737	13638.9	10	164.41	1.52	5.81	3874347.5	3
2003	Nov	29.946	133.948	12718	11	164.41	1.52	5.81	5369131	3
2003	Dic	62.843	138.216	10331.7	12	164.41	1.52	5.81	10706723	3
2004	Ene	123.656	113.411	11952.6	1	164.41	1.52	5.81	21016534	3
2004	Feb	129.945	91.176	9005.21	2	164.41	1.52	5.81	21132260	3
2004	Mar	142.588	94.5666	1697.26	3	164.41	1.52	5.81	23638948	3
2004	Abr	39.1026	92.277	5997.88	4	164.41	1.52	5.81	6640420.5	3
2004	May	10.3071	73.2613	6613.54	5	164.41	1.52	5.81	1954849.375	3
2004	Jun	4.70731	77.5503	7057.37	6	164.41	1.52	5.81	1163093.75	3
2004	Jul	3.59921	100.585	10530.5	7	164.41	1.52	5.81	1260186.25	3
2004	Ago	7.37114	92.2212	13050.4	8	164.41	1.52	5.81	1661569.375	3
2004	Sep	11.729	129.778	15243	9	164.41	1.52	5.81	2358783.75	3
2004	Oct	21.6025	120.703	13303.2	10	164.41	1.52	5.81	3636169.25	3
2004	Nov	27.7838	118.624	12574.1	11	164.41	1.52	5.81	4717078.5	3
2004	Dic	58.553	129.367	10720.2	12	164.41	1.52	5.81	9676356	3
2005	Ene	124.966	123.523	13024.4	1	164.41	1.52	5.81	21575134	3
2005	Feb	137.53	96.3057	8136.71	2	164.41	1.52	5.81	22808398	3
2005	Mar	148.052	93.3052	1682.58	3	164.41	1.52	5.81	24461656	3
2005	Abr	37.2629	83.4785	6275.55	4	164.41	1.52	5.81	6016600	3

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2005	May	10.3636	72.0566	7204.48	5	164.41	1.52	5.81	1915238.75	3
2005	Jun	5.00581	68.0943	7298.99	6	164.41	1.52	5.81	1261844	3
2005	Jul	3.27887	97.7537	10311.7	7	164.41	1.52	5.81	1154984.5	3
2005	Ago	7.51927	92.5711	13152.1	8	164.41	1.52	5.81	1740342.5	3
2005	Sep	11.402	116.276	15918.6	9	164.41	1.52	5.81	2195739.75	3
2005	Oct	21.5329	119.32	12272.9	10	164.41	1.52	5.81	3478818.25	3
2005	Nov	26.1091	132.73	14489.8	11	164.41	1.52	5.81	4674655.5	3
2005	Dic	64.8055	132.612	10658	12	164.41	1.52	5.81	10628753	3
2006	Ene	128.008	118.31	12058.4	1	164.41	1.52	5.81	22079942	3
2006	Feb	143.044	96.7408	8937.83	2	164.41	1.52	5.81	23620364	3
2006	Mar	143.826	93.7519	1682.77	3	164.41	1.52	5.81	23694110	3
2006	Abr	40.5381	88.9078	5856.09	4	164.41	1.52	5.81	6927437.5	3
2006	May	10.224	81.3045	7065.35	5	164.41	1.52	5.81	2153219	3
2006	Jun	4.39139	72.9964	6762.16	6	164.41	1.52	5.81	1278798.5	3
2006	Jul	3.46324	95.8855	10367	7	164.41	1.52	5.81	1129420.375	3
2006	Ago	7.84287	87.5429	12710.7	8	164.41	1.52	5.81	1737549.125	3
2006	Sep	11.32	112.353	15215	9	164.41	1.52	5.81	2197211.25	3
2006	Oct	23.9359	120.826	13064	10	164.41	1.52	5.81	3849452	3
2006	Nov	28.0588	129.88	12687.4	11	164.41	1.52	5.81	4659898.5	3
2006	Dic	61.3685	141.246	11101.2	12	164.41	1.52	5.81	10231453	3
2007	Ene	120.758	116.579	13134.2	1	164.41	1.52	5.81	20335200	3
2007	Feb	143.219	100.781	8190.09	2	164.41	1.52	5.81	23843452	3
2007	Mar	135.034	87.7708	1608.95	3	164.41	1.52	5.81	21866792	3
2007	Abr	40.2911	94.9782	6006.1	4	164.41	1.52	5.81	7037976	3
2007	May	10.0095	76.0326	7217.49	5	164.41	1.52	5.81	2029270.25	3
2007	Jun	5.23426	66.5803	6807.3	6	164.41	1.52	5.81	1312269.875	3

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2007	Jul	3.78088	94.7622	10384.4	7	164.41	1.52	5.81	1115023.625	3
2007	Ago	7.16868	94.3017	14170.2	8	164.41	1.52	5.81	1752314.375	3
2007	Sep	10.1203	131.795	14257.1	9	164.41	1.52	5.81	2397928.25	3
2007	Oct	21.8053	118.11	13295.1	10	164.41	1.52	5.81	3553761	3
2007	Nov	27.5528	137.107	14238.7	11	164.41	1.52	5.81	4764453.5	3
2007	Dic	58.1088	133.999	10442.5	12	164.41	1.52	5.81	9292250	3
2008	Ene	130.587	115.27	12404	1	164.41	1.52	5.81	22045500	3
2008	Feb	138.8	101.826	8545.64	2	164.41	1.52	5.81	23009762	3
2008	Mar	145.805	87.6036	1550.15	3	164.41	1.52	5.81	23513966	3
2008	Abr	40.303	97.2264	6136.2	4	164.41	1.52	5.81	7107461.5	3
2008	May	10.0129	75.4573	7061.1	5	164.41	1.52	5.81	2058003.375	3
2008	Jun	4.88237	75.594	6592.53	6	164.41	1.52	5.81	1451492	3
2008	Jul	3.35278	95.9893	10255.1	7	164.41	1.52	5.81	1007136.438	3
2008	Ago	7.27499	105.15	13096.2	8	164.41	1.52	5.81	1969463.875	3
2008	Sep	11.1748	118.447	15921.2	9	164.41	1.52	5.81	2279841.75	3
2008	Oct	21.8997	116.781	13768.2	10	164.41	1.52	5.81	3651835.5	3
2008	Nov	32.0712	129.987	11723.3	11	164.41	1.52	5.81	5103694.5	3
2008	Dic	65.5005	128.196	11226.9	12	164.41	1.52	5.81	10450854	3
2009	Ene	115.269	120.3	12038.9	1	164.41	1.52	5.81	19818506	3
2009	Feb	140.446	93.4667	8216.47	2	164.41	1.52	5.81	22223864	3
2009	Mar	137.876	96.874	1636.62	3	164.41	1.52	5.81	22663486	3
2009	Abr	40.5235	99.4544	5557.46	4	164.41	1.52	5.81	7301106	3
2009	May	10.9947	75.8537	7193.52	5	164.41	1.52	5.81	2192087.5	3
2009	Jun	4.4239	71.7154	7055.83	6	164.41	1.52	5.81	1340315.125	3
2009	Jul	3.41158	101.888	9723.29	7	164.41	1.52	5.81	1055008.75	3
2009	Ago	7.29472	89.2011	13501.1	8	164.41	1.52	5.81	1691291.375	3

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2009	Sep	11.8833	119.835	13351.3	9	164.41	1.52	5.81	2376517.5	3
2009	Oct	22.3198	123.336	13176.1	10	164.41	1.52	5.81	3647647	3
2009	Nov	31.796	126.833	13369.8	11	164.41	1.52	5.81	5010709.5	3
2009	Dic	66.0773	120.936	10972.6	12	164.41	1.52	5.81	10440385	3
2010	Ene	124.641	114.691	13037.8	1	164.41	1.52	5.81	20620896	3
2010	Feb	132.194	90.2444	8642.73	2	164.41	1.52	5.81	20313612	3
2010	Mar	133.089	88.5751	1683.3	3	164.41	1.52	5.81	21268298	3
2010	Abr	37.1115	93.5254	6168.45	4	164.41	1.52	5.81	6663952.5	3
2010	May	9.29441	72.9035	7981.7	5	164.41	1.52	5.81	1865744.75	3
2010	Jun	4.50664	70.7189	6900.83	6	164.41	1.52	5.81	1363617.75	3
2010	Jul	3.56797	93.5386	10170.8	7	164.41	1.52	5.81	1130302.375	3
2010	Ago	7.81823	103.434	13909	8	164.41	1.52	5.81	2038635	3
2010	Sep	11.4272	117.463	14712.6	9	164.41	1.52	5.81	2461798.25	3
2010	Oct	22.6774	123.225	13820.1	10	164.41	1.52	5.81	3772524.75	3
2010	Nov	30.9196	123.939	13610.1	11	164.41	1.52	5.81	4892598.5	3
2010	Dic	59.2472	130.192	10935.1	12	164.41	1.52	5.81	9375881	3
2011	Ene	140.623	133.067	13203.8	1	164.41	1.52	5.81	24752500	3
2011	Feb	134.254	95.8961	9010.93	2	164.41	1.52	5.81	20855112	3
2011	Mar	138.483	102.067	1646.73	3	164.41	1.52	5.81	22823342	3
2011	Abr	40.3529	93.5236	6156.09	4	164.41	1.52	5.81	7144263.5	3
2011	May	10.5989	73.1311	7321.74	5	164.41	1.52	5.81	2155846	3
2011	Jun	4.47844	73.991	7007.7	6	164.41	1.52	5.81	1448684.625	3
2011	Jul	3.51207	102.661	10481.1	7	164.41	1.52	5.81	1191277.125	3
2011	Ago	7.54319	89.9657	13003.4	8	164.41	1.52	5.81	1717125.875	3
2011	Sep	11.7744	127.607	15124.4	9	164.41	1.52	5.81	2525322	3
2011	Oct	22.0209	111.54	12684.4	10	164.41	1.52	5.81	3748896.25	3

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2011	Nov	31.2788	137.864	13253.7	11	164.41	1.52	5.81	4986169.5	3
2011	Dic	62.5143	132.787	10443.4	12	164.41	1.52	5.81	9872769	3
2012	Ene	132.332	117.584	13130.3	1	164.41	1.52	5.81	22059360	3
2012	Feb	131.931	83.3439	9101.31	2	164.41	1.52	5.81	19655522	3
2012	Mar	137.37	89.6196	1684.45	3	164.41	1.52	5.81	21881664	3
2012	Abr	38.6013	95.3067	6215	4	164.41	1.52	5.81	6971850	3
2012	May	10.5198	70.3062	7988.42	5	164.41	1.52	5.81	2087823.25	3
2012	Jun	4.80104	71.0632	6793.36	6	164.41	1.52	5.81	1464522.75	3
2012	Jul	3.12855	96.6656	9944.4	7	164.41	1.52	5.81	1233853.375	3
2012	Ago	6.80546	87.9166	13997.7	8	164.41	1.52	5.81	1608101.375	3
2012	Sep	11.0207	131.797	14938.8	9	164.41	1.52	5.81	2520674.75	3
2012	Oct	20.2134	113.962	13713	10	164.41	1.52	5.81	3669466.5	3
2012	Nov	29.7122	130.336	13033.5	11	164.41	1.52	5.81	4618009.5	3
2012	Dic	63.9237	140.156	11582.2	12	164.41	1.52	5.81	10216764	3
2013	Ene	125.564	107.525	12550.1	1	164.41	1.52	5.81	19775350	3
2013	Feb	137.258	88.8992	8215.09	2	164.41	1.52	5.81	20563630	3
2013	Mar	143.159	93.4322	1630.67	3	164.41	1.52	5.81	23001924	3
2013	Abr	37.8798	89.4673	5750.39	4	164.41	1.52	5.81	6637446	3
2013	May	10.6249	79.366	6836.73	5	164.41	1.52	5.81	2368205.5	3
2013	Jun	4.51888	66.9826	6525.78	6	164.41	1.52	5.81	1418786.625	3
2013	Jul	3.41915	87.8638	10000.8	7	164.41	1.52	5.81	1189636.75	3
2013	Ago	6.93273	96.1462	13306	8	164.41	1.52	5.81	1664190.875	3
2013	Sep	10.9681	123.492	14930.4	9	164.41	1.52	5.81	2504542.25	3
2013	Oct	21.7998	130.799	13780.6	10	164.41	1.52	5.81	3695758.5	3
2013	Nov	27.9998	139.57	13454.6	11	164.41	1.52	5.81	4449448	3
2013	Dic	58.7789	138.174	11630.5	12	164.41	1.52	5.81	9328673	3

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2014	Ene	120.687	109.877	13467.1	1	164.41	1.52	5.81	19076104	3
2014	Feb	137.334	95.9754	8774.93	2	164.41	1.52	5.81	20858574	3
2014	Mar	143.489	87.4481	1713.25	3	164.41	1.52	5.81	22581660	3
2014	Abr	41.6756	89.4719	6015.89	4	164.41	1.52	5.81	7136480	3
2014	May	9.39344	77.4003	7747.44	5	164.41	1.52	5.81	2118028.5	3
2014	Jun	4.72439	76.4702	6632.33	6	164.41	1.52	5.81	1642041.25	3
2014	Jul	3.53041	89.9004	10471.7	7	164.41	1.52	5.81	1262856.75	3
2014	Ago	7.2355	96.232	13015	8	164.41	1.52	5.81	1627101.25	3
2014	Sep	11.3039	127.466	15014.8	9	164.41	1.52	5.81	2619390.5	3
2014	Oct	20.3247	131.259	13807.1	10	164.41	1.52	5.81	3524462.5	3
2014	Nov	28.0108	138.631	12604.8	11	164.41	1.52	5.81	4361922	3
2014	Dic	63.1807	134.693	10673.4	12	164.41	1.52	5.81	9927251	3
2015	Ene	122.853	111.184	12228	1	164.41	1.52	5.81	19276540	3
2015	Feb	129.859	93.0863	8319.22	2	164.41	1.52	5.81	19188476	3
2015	Mar	145.54	100.625	1580.78	3	164.41	1.52	5.81	23835388	3
2015	Abr	39.8443	92.7713	6171.29	4	164.41	1.52	5.81	7031591	3
2015	May	10.2108	78.2621	7713.61	5	164.41	1.52	5.81	2263034	3
2015	Jun	4.44586	75.5463	7044.24	6	164.41	1.52	5.81	1578814.75	3
2015	Jul	3.30244	94.9097	10842.2	7	164.41	1.52	5.81	1387453.125	3
2015	Ago	7.22274	100.265	14827.2	8	164.41	1.52	5.81	1829741	3
2015	Sep	10.9315	113.957	15583.2	9	164.41	1.52	5.81	2539247	3
2015	Oct	22.8973	119.307	13853.4	10	164.41	1.52	5.81	3967881.25	3
2015	Nov	27.9414	138.653	12538.3	11	164.41	1.52	5.81	4292236.5	3
2015	Dic	67.7201	145.964	10386	12	164.41	1.52	5.81	10626790	3
2016	Ene	124.35	120.11	12566.9	1	164.41	1.52	5.81	20324210	3
2016	Feb	135.187	93.5186	7799.85	2	164.41	1.52	5.81	19983338	3

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2016	Mar	140.643	90.43	1587.86	3	164.41	1.52	5.81	22193896	3
2016	Abr	42.2151	84.8237	6274.14	4	164.41	1.52	5.81	6901517	3
2016	May	10.0303	74.4045	7829.65	5	164.41	1.52	5.81	2222463.75	3
2016	Jun	4.81971	74.4656	7071.52	6	164.41	1.52	5.81	1622649.625	3
2016	Jul	3.3766	91.8301	9915.16	7	164.41	1.52	5.81	1450568.5	3
2016	Ago	6.99789	109.192	14085.2	8	164.41	1.52	5.81	1827300.5	3
2016	Sep	10.61	114.316	15719.8	9	164.41	1.52	5.81	2465640.75	3
2016	Oct	22.7047	124.013	12750.4	10	164.41	1.52	5.81	3683560.25	3
2016	Nov	29.7578	136.207	12985.5	11	164.41	1.52	5.81	4595001.5	3
2016	Dic	55.4394	131.215	10340.2	12	164.41	1.52	5.81	8156666	3
2017	Ene	128.984	132.349	13050.5	1	164.41	1.52	5.81	22159324	3
2017	Feb	133.371	97.7048	8836.23	2	164.41	1.52	5.81	19735008	3
2017	Mar	143.696	96.5019	1795.4	3	164.41	1.52	5.81	23076132	3
2017	Abr	37.1467	92.6534	5749.74	4	164.41	1.52	5.81	6703232.5	3
2017	May	10.4547	71.9938	7374.82	5	164.41	1.52	5.81	2421754.5	3
2017	Jun	4.66921	75.9325	7054.75	6	164.41	1.52	5.81	1663660.75	3
2017	Jul	3.21962	94.9902	10112	7	164.41	1.52	5.81	1549570.25	3
2017	Ago	6.83983	94.1274	13055.5	8	164.41	1.52	5.81	1592746.75	3
2017	Sep	12.7593	125.06	14292.7	9	164.41	1.52	5.81	2628739.25	3
2017	Oct	21.4759	126.864	14263.6	10	164.41	1.52	5.81	3779138.5	3
2017	Nov	27.571	121.414	14139.6	11	164.41	1.52	5.81	4509342.5	3
2017	Dic	63.5739	126.977	11088.7	12	164.41	1.52	5.81	9573135	3
2018	Ene	111.013	115.179	13025.1	1	164.41	1.52	5.81	17177978	3
2018	Feb	141.756	88.6651	8664.97	2	164.41	1.52	5.81	20487078	3
2018	Mar	134.228	94.856	1555.12	3	164.41	1.52	5.81	21461178	3
2018	Abr	38.5696	86.0034	6225.29	4	164.41	1.52	5.81	6493772	3

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2018	May	10.6088	74.5748	7546.4	5	164.41	1.52	5.81	2455051.5	3
2018	Jun	4.39588	71.3152	6728.07	6	164.41	1.52	5.81	1662957.875	3
2018	Jul	3.8834	89.4632	11251.5	7	164.41	1.52	5.81	1319671.25	3
2018	Ago	7.66294	96.4953	14426	8	164.41	1.52	5.81	1679104.125	3
2018	Sep	11.5904	124.792	15309.2	9	164.41	1.52	5.81	2632348.25	3
2018	Oct	23.452	127.317	12511	10	164.41	1.52	5.81	3706288.5	3
2018	Nov	27.9704	132.65	12412.8	11	164.41	1.52	5.81	4157739	3
2018	Dic	62.1611	140.953	10553.1	12	164.41	1.52	5.81	9439450	3
2019	Ene	127.59	115.494	13358.6	1	164.41	1.52	5.81	19758606	3
2019	Feb	120.273	90.5667	8719.15	2	164.41	1.52	5.81	17336222	3
2019	Mar	149.185	91.3564	1475.25	3	164.41	1.52	5.81	23508754	3
2019	Abr	40.593	87.6347	5670.37	4	164.41	1.52	5.81	6955608.5	3
2019	May	9.85463	74.7638	7304.25	5	164.41	1.52	5.81	2460310.25	3
2019	Jun	4.21651	75.6474	7174.95	6	164.41	1.52	5.81	1654459.5	3
2019	Jul	3.54533	89.3414	10378.4	7	164.41	1.52	5.81	1425558.375	3
2019	Ago	7.29675	98.0091	13703.1	8	164.41	1.52	5.81	1748265	3
2019	Sep	10.961	122.912	15701	9	164.41	1.52	5.81	2531043.75	3
2019	Oct	23.7087	124.952	13424.5	10	164.41	1.52	5.81	3866421	3
2019	Nov	30.0712	143.461	13194.9	11	164.41	1.52	5.81	4599186.5	3
2019	Dic	59.6743	142.054	11176.9	12	164.41	1.52	5.81	9028740	3
2020	Ene	125.031	112.399	13005	1	164.41	1.52	5.81	18986596	3
2020	Feb	138.633	94.3214	8762.3	2	164.41	1.52	5.81	20062654	3
2020	Mar	152.703	98.678	1643.52	3	164.41	1.52	5.81	24615268	3
2020	Abr	41.2262	85.8373	6148.96	4	164.41	1.52	5.81	6872879	3
2020	May	11.0924	74.6373	7212.78	5	164.41	1.52	5.81	2683337.5	3
2020	Jun	4.58461	68.4555	6480.34	6	164.41	1.52	5.81	1789956.25	3

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2020	Jul	3.36987	88.0725	10492.2	7	164.41	1.52	5.81	1441989.875	3
2020	Ago	7.62842	90.8409	14267.3	8	164.41	1.52	5.81	1672646.125	3
2020	Sep	11.6693	128.718	14845.1	9	164.41	1.52	5.81	2682007	3
2020	Oct	23.0443	114.11	13489.9	10	164.41	1.52	5.81	3707505	3
2020	Nov	30.2029	137.717	12170	11	164.41	1.52	5.81	4411627	3
2020	Dic	59.5683	136.704	10287.9	12	164.41	1.52	5.81	8594270	3
2021	Ene	130.825	107.288	13358.5	1	164.41	1.52	5.81	19609800	3
2021	Feb	127.145	95.9792	8897.9	2	164.41	1.52	5.81	18427366	3
2021	Mar	135.837	96.3856	1649.2	3	164.41	1.52	5.81	21646686	3
2021	Abr	38.3123	85.9458	5437.37	4	164.41	1.52	5.81	6680257.5	3
2021	May	10.35	69.556	7567.91	5	164.41	1.52	5.81	2582160.75	3
2021	Jun	4.6767	74.8585	6643.14	6	164.41	1.52	5.81	1889242.125	3
2021	Jul	3.37692	98.1965	10659.6	7	164.41	1.52	5.81	1856880.5	3
2021	Ago	7.41451	97.3928	12241.9	8	164.41	1.52	5.81	1974870.5	3
2021	Sep	11.8093	126.159	14569.7	9	164.41	1.52	5.81	2675916.5	3
2021	Oct	21.8303	120.463	12828.1	10	164.41	1.52	5.81	3525161.75	3
2021	Nov	30.4455	143.601	13629.4	11	164.41	1.52	5.81	4667371	3
2021	Dic	58.2677	136.869	11517.6	12	164.41	1.52	5.81	8496642	3
2022	Ene	130.337	121.442	14104.4	1	164.41	1.52	5.81	20163042	3
2022	Feb	142.43	94.5643	9078.85	2	164.41	1.52	5.81	20520990	3
2022	Mar	141.76	93.7719	1599.39	3	164.41	1.52	5.81	22267460	3
2022	Abr	42.4509	86.8062	6490.93	4	164.41	1.52	5.81	7060525	3
2022	May	10.4264	70.1804	7670.46	5	164.41	1.52	5.81	2645740.25	3
2022	Jun	4.24152	74.6643	7043.54	6	164.41	1.52	5.81	1826453.5	3
2022	Jul	3.33179	95.3152	11508.4	7	164.41	1.52	5.81	1532935.375	3
2022	Ago	7.11455	90.1217	14242.3	8	164.41	1.52	5.81	1628062	3

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2022	Sep	12.4953	122.433	16126.3	9	164.41	1.52	5.81	2736995.5	3
2022	Oct	23.5823	116.219	12601.6	10	164.41	1.52	5.81	3803255	3
2022	Nov	31.7886	145.3	13293.9	11	164.41	1.52	5.81	4849972	3
2022	Dic	59.6159	145.928	10513.3	12	164.41	1.52	5.81	8695137	3
2023	Ene	125.721	117.131	13810.8	1	164.41	1.52	5.81	19014594	3
2023	Feb	141.28	95.3374	8827.86	2	164.41	1.52	5.81	20432658	3
2023	Mar	141.046	96.2738	1422.09	3	164.41	1.52	5.81	22451484	3
2023	Abr	38.7891	91.6021	5682.03	4	164.41	1.52	5.81	7219525.5	3
2023	May	10.3687	74.6885	8193.11	5	164.41	1.52	5.81	2616545.75	3
2023	Jun	5.11187	70.7138	6694.13	6	164.41	1.52	5.81	1994559.375	3
2023	Jul	3.42078	92.5907	10586.2	7	164.41	1.52	5.81	1688663.875	3
2023	Ago	7.02239	89.7805	13672.9	8	164.41	1.52	5.81	1625775.5	3
2023	Sep	11.7369	117.487	16037.2	9	164.41	1.52	5.81	2543355.75	3
2023	Oct	21.4021	122.228	13444.7	10	164.41	1.52	5.81	3568055.5	3
2023	Nov	29.8953	137.057	12596.1	11	164.41	1.52	5.81	4495733.5	3
2023	Dic	61.7466	131.374	10396.8	12	164.41	1.52	5.81	8990880	3
2024	Ene	126.734	106.243	12500.3	1	164.41	1.52	5.81	18579114	3
2024	Feb	133.565	92.2036	8523.82	2	164.41	1.52	5.81	19299776	3
2024	Mar	140.305	95.9052	1699.19	3	164.41	1.52	5.81	22146576	3
2024	Abr	38.0939	85.0649	5714.88	4	164.41	1.52	5.81	6739610.5	3
2024	May	9.92438	74.1322	7242.02	5	164.41	1.52	5.81	2814648.5	3
2024	Jun	4.43201	70.7488	6806.19	6	164.41	1.52	5.81	1945759	3
2024	Jul	3.53563	92.0898	10267.5	7	164.41	1.52	5.81	1796060.5	3
2024	Ago	6.96093	95.0104	12697.5	8	164.41	1.52	5.81	1826015.125	3
2024	Sep	11.7048	111.48	15074	9	164.41	1.52	5.81	2423691.75	3
2024	Oct	22.4327	121.809	14654	10	164.41	1.52	5.81	3835978	3

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2024	Nov	30.4694	127.282	12868.3	11	164.41	1.52	5.81	4542686.5	3
2024	Dic	56.8209	132.205	10350.1	12	164.41	1.52	5.81	8226824.5	3
2025	Ene	133.716	111.996	12740.2	1	164.41	1.52	5.81	19812018	3
2025	Feb	131.189	101.52	8489.42	2	164.41	1.52	5.81	19284920	3
2025	Mar	153.636	97.4727	1667.24	3	164.41	1.52	5.81	24334870	3
2025	Abr	40.099	92.2921	5447.9	4	164.41	1.52	5.81	7653515.5	3
2025	May	10.0303	78.6488	7513.59	5	164.41	1.52	5.81	2855058.5	3
2025	Jun	4.40616	72.2103	7319.71	6	164.41	1.52	5.81	1937220.25	3
2025	Jul	3.64754	94.4363	10982.7	7	164.41	1.52	5.81	1782553	3
2025	Ago	7.16537	87.053	12647.1	8	164.41	1.52	5.81	1688135	3
2025	Sep	12.2679	120.733	15163.2	9	164.41	1.52	5.81	2686949.25	3
2025	Oct	21.7687	132.191	13965	10	164.41	1.52	5.81	3788178.5	3
2025	Nov	33.2678	132.944	13121.1	11	164.41	1.52	5.81	5014405	3
2025	Dic	57.6303	142.542	10169.4	12	164.41	1.52	5.81	8131501	3
2026	Ene	129.25	108.842	12437.7	1	164.41	1.52	5.81	18954414	3
2026	Feb	129.823	90.5612	8395.42	2	164.41	1.52	5.81	18766438	3
2026	Mar	136.882	97.5625	1538.06	3	164.41	1.52	5.81	21829174	3
2026	Abr	39.8072	96.0219	5874.3	4	164.41	1.52	5.81	7805291	3
2026	May	9.80703	74.5902	7976.28	5	164.41	1.52	5.81	2818007.75	3
2026	Jun	4.78513	70.477	6908.19	6	164.41	1.52	5.81	2070923.375	3
2026	Jul	3.24424	97.9573	10698.2	7	164.41	1.52	5.81	2020666.25	3
2026	Ago	7.18679	91.17	12672.1	8	164.41	1.52	5.81	1791467.25	3
2026	Sep	11.683	129.932	14860.9	9	164.41	1.52	5.81	2833543	3
2026	Oct	22.6065	108.105	12537.5	10	164.41	1.52	5.81	4068685	3
2026	Nov	29.8991	127.915	12324.5	11	164.41	1.52	5.81	4614770.5	3
2026	Dic	60.277	134.679	10698.8	12	164.41	1.52	5.81	8837459	3

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2027	Ene	113.554	102.949	12426.2	1	164.41	1.52	5.81	16501937	3
2027	Feb	138.595	80.5692	8412.42	2	164.41	1.52	5.81	19776532	3
2027	Mar	137.037	100.162	1596.66	3	164.41	1.52	5.81	22015208	3
2027	Abr	40.127	91.1493	5386.74	4	164.41	1.52	5.81	7747619.5	3
2027	May	10.5629	76.2727	7723.41	5	164.41	1.52	5.81	3031030.75	3
2027	Jun	5.66948	64.8555	7326.65	6	164.41	1.52	5.81	2232412.5	3
2027	Jul	3.38413	96.0909	10460.1	7	164.41	1.52	5.81	2033517.375	3
2027	Ago	7.1443	92.4487	13478.5	8	164.41	1.52	5.81	1757724.625	3
2027	Sep	10.5155	127.004	15030.6	9	164.41	1.52	5.81	2676292	3
2027	Oct	20.8513	117.984	13726.8	10	164.41	1.52	5.81	3747158.25	3
2027	Nov	29.1441	136.412	12457.4	11	164.41	1.52	5.81	4473527	3
2027	Dic	64.7223	137.29	11798.2	12	164.41	1.52	5.81	9546489	3
2028	Ene	126.741	119.01	12877.8	1	164.41	1.52	5.81	18902542	3
2028	Feb	144.274	90.0431	8949.4	2	164.41	1.52	5.81	20700950	3
2028	Mar	139.37	93.3594	1635.47	3	164.41	1.52	5.81	21907522	3
2028	Abr	39.8696	89.984	6093.73	4	164.41	1.52	5.81	7464510.5	3
2028	May	10.9748	79.1781	7859.32	5	164.41	1.52	5.81	3122809.5	3
2028	Jun	4.63119	69.1809	7067.18	6	164.41	1.52	5.81	2138898	3
2028	Jul	3.58387	101.705	10167.4	7	164.41	1.52	5.81	2443820.25	3
2028	Ago	7.21536	87.3593	12999.8	8	164.41	1.52	5.81	1771265	3
2028	Sep	11.9457	119.555	15841.6	9	164.41	1.52	5.81	2733811.25	3
2028	Oct	21.8895	122.656	12173.9	10	164.41	1.52	5.81	4068007.25	3
2028	Nov	30.0732	113.968	12809.2	11	164.41	1.52	5.81	4872324	3
2028	Dic	57.2754	140.744	11219.8	12	164.41	1.52	5.81	8310010.5	3
2029	Ene	130.847	123.918	12207	1	164.41	1.52	5.81	19756168	3
2029	Feb	147.333	97.7533	8525.95	2	164.41	1.52	5.81	21406456	3

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2029	Mar	148.731	88.4792	1560.88	3	164.41	1.52	5.81	23110070	3
2029	Abr	38.1749	88.1161	5710.5	4	164.41	1.52	5.81	7366189	3
2029	May	10.7942	74.4833	7664.75	5	164.41	1.52	5.81	3212725.75	3
2029	Jun	4.60398	65.8094	6836.08	6	164.41	1.52	5.81	2342177	3
2029	Jul	3.10519	94.4049	9766.73	7	164.41	1.52	5.81	2127803.75	3
2029	Ago	8.0244	99.4963	13330.1	8	164.41	1.52	5.81	2167223.25	3
2029	Sep	12.0977	117.23	15767.1	9	164.41	1.52	5.81	2852103.25	3
2029	Oct	22.3208	122.293	13736.6	10	164.41	1.52	5.81	4114380.5	3
2029	Nov	31.0424	135.945	11860.1	11	164.41	1.52	5.81	4921629	3
2029	Dic	59.3657	131.926	10850.4	12	164.41	1.52	5.81	8953706	3
2030	Ene	120.638	129.046	13786.6	1	164.41	1.52	5.81	18332536	3
2030	Feb	139.574	93.7364	8536.45	2	164.41	1.52	5.81	20245870	3
2030	Mar	134.041	94.0228	1648.98	3	164.41	1.52	5.81	21212050	3
2030	Abr	36.9284	92.0223	5982.2	4	164.41	1.52	5.81	7467237.5	3
2030	May	9.20185	72.2138	7376.24	5	164.41	1.52	5.81	3146214.5	3
2030	Jun	5.18643	74.4147	6294.61	6	164.41	1.52	5.81	2466253.75	3
2030	Jul	3.51692	87.4012	11051.5	7	164.41	1.52	5.81	1735630.625	3
2030	Ago	7.12719	94.7145	14139	8	164.41	1.52	5.81	1851953.375	3
2030	Sep	10.6464	113.859	14902.1	9	164.41	1.52	5.81	2876723.25	3
2030	Oct	23.2474	111.531	11086.1	10	164.41	1.52	5.81	4705862	3
2030	Nov	29.2701	137.707	13706	11	164.41	1.52	5.81	4726729	3
2030	Dic	60.915	130.009	11423.1	12	164.41	1.52	5.81	9300763	3
2003	Ene	115.91	112.923	12937	1	164.41	1.52	5.81	19344650	4
2003	Feb	138.538	91.0192	8642.86	2	164.41	1.52	5.81	22707986	4
2003	Mar	123.23	90.5774	1664.92	3	164.41	1.52	5.81	20444336	4
2003	Abr	37.4392	90.7769	6163.71	4	164.41	1.52	5.81	6290714.5	4

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2003	May	9.99795	76.1032	7169.43	5	164.41	1.52	5.81	1874616.125	4
2003	Jun	4.69017	74.609	6797.94	6	164.41	1.52	5.81	1097254.625	4
2003	Jul	3.33279	95.792	10858.6	7	164.41	1.52	5.81	1328752.875	4
2003	Ago	6.55099	100.675	13037.1	8	164.41	1.52	5.81	1563755.375	4
2003	Sep	11.6208	129.738	14297.2	9	164.41	1.52	5.81	2329782.25	4
2003	Oct	21.3161	118.959	12408.9	10	164.41	1.52	5.81	3586921.5	4
2003	Nov	32.5433	128.269	12570.8	11	164.41	1.52	5.81	5732267	4
2003	Dic	62.9964	124.761	10586.3	12	164.41	1.52	5.81	10343095	4
2004	Ene	129.893	113.243	12755.2	1	164.41	1.52	5.81	21600494	4
2004	Feb	131.909	86.3274	8766.74	2	164.41	1.52	5.81	20910768	4
2004	Mar	153.089	93.7462	1646.34	3	164.41	1.52	5.81	25341388	4
2004	Abr	40.7368	84.7656	6542.22	4	164.41	1.52	5.81	6538375	4
2004	May	10.2751	81.617	7255.94	5	164.41	1.52	5.81	2050468.25	4
2004	Jun	5.16993	75.2061	6931.51	6	164.41	1.52	5.81	1193893.75	4
2004	Jul	3.47365	93.5528	11113.3	7	164.41	1.52	5.81	1335609.625	4
2004	Ago	7.35036	85.8007	12519.3	8	164.41	1.52	5.81	1608987.625	4
2004	Sep	11.273	124.307	15306.6	9	164.41	1.52	5.81	2250204.5	4
2004	Oct	23.447	108.925	13007.7	10	164.41	1.52	5.81	3942089.75	4
2004	Nov	27.2236	139.1	12868.9	11	164.41	1.52	5.81	4836680.5	4
2004	Dic	63.6675	127.006	11490.9	12	164.41	1.52	5.81	10522815	4
2005	Ene	134.524	118.52	12732	1	164.41	1.52	5.81	22876660	4
2005	Feb	139.423	90.0988	8997.09	2	164.41	1.52	5.81	22516702	4
2005	Mar	152.347	98.6737	1568.61	3	164.41	1.52	5.81	25277008	4
2005	Abr	40.0845	84.6579	6201.55	4	164.41	1.52	5.81	6510301.5	4
2005	May	10.4014	68.4052	7094.47	5	164.41	1.52	5.81	1914337.375	4
2005	Jun	4.67204	71.3109	6337.1	6	164.41	1.52	5.81	1285118.5	4

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2005	Jul	3.50026	95.9211	10382.2	7	164.41	1.52	5.81	1192753.75	4
2005	Ago	7.0233	100.15	14357.5	8	164.41	1.52	5.81	1673745.5	4
2005	Sep	11.1036	118.663	15727	9	164.41	1.52	5.81	2168372	4
2005	Oct	21.7044	119.859	13392.6	10	164.41	1.52	5.81	3571208	4
2005	Nov	27.0868	142.843	12977	11	164.41	1.52	5.81	4822970	4
2005	Dic	61.0761	132.148	10779.7	12	164.41	1.52	5.81	10047248	4
2006	Ene	116.796	123.768	12841.5	1	164.41	1.52	5.81	20291770	4
2006	Feb	138.496	97.8437	8187.47	2	164.41	1.52	5.81	22954848	4
2006	Mar	144.072	92.4066	1696.93	3	164.41	1.52	5.81	23703342	4
2006	Abr	35.1853	90.0615	5847.28	4	164.41	1.52	5.81	6181814.5	4
2006	May	10.392	77.2335	7265.51	5	164.41	1.52	5.81	2055215.625	4
2006	Jun	4.57038	71.9994	6442.61	6	164.41	1.52	5.81	1316346	4
2006	Jul	3.57802	92.9813	8960.16	7	164.41	1.52	5.81	925609.6875	4
2006	Ago	7.16234	90.2186	12178.5	8	164.41	1.52	5.81	1702925.375	4
2006	Sep	10.6747	123.08	16369.7	9	164.41	1.52	5.81	2190383	4
2006	Oct	22.4461	117.04	13209.4	10	164.41	1.52	5.81	3614271.5	4
2006	Nov	29.2583	129.356	12183.7	11	164.41	1.52	5.81	4838505.5	4
2006	Dic	56.897	130.152	10885.3	12	164.41	1.52	5.81	9195887	4
2007	Ene	127.246	112.765	12209	1	164.41	1.52	5.81	21384584	4
2007	Feb	139.615	87.249	8962.78	2	164.41	1.52	5.81	21892244	4
2007	Mar	133.687	90.1363	1508.6	3	164.41	1.52	5.81	21808670	4
2007	Abr	38.386	94.9238	6184.44	4	164.41	1.52	5.81	6718267.5	4
2007	May	10.6698	77.43	7116.36	5	164.41	1.52	5.81	2141657.25	4
2007	Jun	4.66075	69.5757	7193.74	6	164.41	1.52	5.81	1292141.75	4
2007	Jul	3.22802	98.963	10952.1	7	164.41	1.52	5.81	1168289.375	4
2007	Ago	7.96686	93.2107	13732.3	8	164.41	1.52	5.81	1882092.875	4

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2007	Sep	12.6768	118.63	14171.9	9	164.41	1.52	5.81	2428943	4
2007	Oct	20.0226	125.001	11699	10	164.41	1.52	5.81	3223940.75	4
2007	Nov	29.3882	136.94	13049.7	11	164.41	1.52	5.81	5033524	4
2007	Dic	63.6856	134.215	11490.6	12	164.41	1.52	5.81	10368698	4
2008	Ene	121.776	111.262	12319.9	1	164.41	1.52	5.81	20195958	4
2008	Feb	141.119	97.6049	8822.66	2	164.41	1.52	5.81	22961208	4
2008	Mar	149.068	88.1432	1763.71	3	164.41	1.52	5.81	24083900	4
2008	Abr	42.3718	93.8391	6566.12	4	164.41	1.52	5.81	7254198.5	4
2008	May	9.3296	73.4813	7255.08	5	164.41	1.52	5.81	1918681.375	4
2008	Jun	4.91009	68.5985	7000.47	6	164.41	1.52	5.81	1314026	4
2008	Jul	3.66876	98.0228	10632.7	7	164.41	1.52	5.81	1128361	4
2008	Ago	6.9386	91.1307	14088.5	8	164.41	1.52	5.81	1714220.875	4
2008	Sep	11.8221	122.171	15029.3	9	164.41	1.52	5.81	2335501.5	4
2008	Oct	19.8615	114.237	14149.3	10	164.41	1.52	5.81	3412424.75	4
2008	Nov	28.0284	135.28	13581.3	11	164.41	1.52	5.81	4665003	4
2008	Dic	58.4463	133.966	11306.5	12	164.41	1.52	5.81	9375649	4
2009	Ene	127.944	131.676	11745.8	1	164.41	1.52	5.81	22845764	4
2009	Feb	142.667	92.593	8961.01	2	164.41	1.52	5.81	22469388	4
2009	Mar	143.845	90.2266	1646.64	3	164.41	1.52	5.81	23276004	4
2009	Abr	35.7155	93.24	6118.88	4	164.41	1.52	5.81	6430034	4
2009	May	10.497	79.4523	7670.45	5	164.41	1.52	5.81	2184579	4
2009	Jun	4.77422	69.2105	6504.8	6	164.41	1.52	5.81	1362173.625	4
2009	Jul	3.63721	101.533	10359.2	7	164.41	1.52	5.81	1145624.75	4
2009	Ago	7.31592	90.8558	14037.5	8	164.41	1.52	5.81	1739925.625	4
2009	Sep	11.7573	134.291	14675.9	9	164.41	1.52	5.81	2673519.25	4
2009	Oct	21.6823	122.097	13332.5	10	164.41	1.52	5.81	3581928.75	4

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2009	Nov	29.6227	128.161	13499.8	11	164.41	1.52	5.81	4690304.5	4
2009	Dic	64.6076	126.659	11531.9	12	164.41	1.52	5.81	10249976	4
2010	Ene	135.345	115.933	12866	1	164.41	1.52	5.81	22659082	4
2010	Feb	139.248	89.3758	8640.96	2	164.41	1.52	5.81	21466490	4
2010	Mar	125.594	97.7644	1500.89	3	164.41	1.52	5.81	20714236	4
2010	Abr	42.3328	89.016	5965.19	4	164.41	1.52	5.81	7230147.5	4
2010	May	9.8529	74.3732	8066.22	5	164.41	1.52	5.81	1957930.125	4
2010	Jun	4.14963	77.0226	6859	6	164.41	1.52	5.81	1447167.625	4
2010	Jul	3.22626	89.6368	11362.8	7	164.41	1.52	5.81	1057758.25	4
2010	Ago	6.95406	89.6724	14014	8	164.41	1.52	5.81	1665373.25	4
2010	Sep	11.5713	116.669	15516.3	9	164.41	1.52	5.81	2485793.25	4
2010	Oct	20.9665	127.343	13600.4	10	164.41	1.52	5.81	3468686.25	4
2010	Nov	30.7422	136.433	14068.6	11	164.41	1.52	5.81	4931959	4
2010	Dic	62.3582	124.896	11042.7	12	164.41	1.52	5.81	9856327	4
2011	Ene	141.2	109.317	12583.4	1	164.41	1.52	5.81	23261690	4
2011	Feb	138.316	93.1483	8204.23	2	164.41	1.52	5.81	21378604	4
2011	Mar	148.635	104.525	1643.97	3	164.41	1.52	5.81	24532284	4
2011	Abr	37.5932	83.5002	6106.77	4	164.41	1.52	5.81	6188693	4
2011	May	10.7336	77.2528	7531.09	5	164.41	1.52	5.81	2230500.5	4
2011	Jun	4.5995	68.4464	7026.52	6	164.41	1.52	5.81	1334260.5	4
2011	Jul	3.59035	87.4087	11317.4	7	164.41	1.52	5.81	1051073.5	4
2011	Ago	7.50864	101.819	12370.2	8	164.41	1.52	5.81	1779105.625	4
2011	Sep	10.6016	121.498	15735.9	9	164.41	1.52	5.81	2345108	4
2011	Oct	24.085	124.961	12758.3	10	164.41	1.52	5.81	3907472	4
2011	Nov	28.4089	142.252	12306.3	11	164.41	1.52	5.81	4736808	4
2011	Dic	67.4366	130.853	11658.9	12	164.41	1.52	5.81	10724425	4

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2012	Ene	132.204	114.371	12482.2	1	164.41	1.52	5.81	21998536	4
2012	Feb	133.185	95.4002	8661.29	2	164.41	1.52	5.81	20459356	4
2012	Mar	136.561	92.8843	1634.4	3	164.41	1.52	5.81	21969710	4
2012	Abr	35.1823	92.5834	5733.66	4	164.41	1.52	5.81	6440198	4
2012	May	9.58558	69.0936	6856.42	5	164.41	1.52	5.81	2143524.25	4
2012	Jun	4.41795	69.8333	7403.74	6	164.41	1.52	5.81	1343609	4
2012	Jul	3.3432	95.5719	10693.9	7	164.41	1.52	5.81	1213940.375	4
2012	Ago	7.34696	94.7915	12467.5	8	164.41	1.52	5.81	1648466.25	4
2012	Sep	12.2042	133.471	14058.6	9	164.41	1.52	5.81	2633677.5	4
2012	Oct	20.9684	119.011	12292.1	10	164.41	1.52	5.81	3444910	4
2012	Nov	30.7032	129.13	14329.7	11	164.41	1.52	5.81	4863027.5	4
2012	Dic	66.0712	134.151	11354.6	12	164.41	1.52	5.81	10523372	4
2013	Ene	134.934	111.913	12292	1	164.41	1.52	5.81	21977382	4
2013	Feb	136.024	97.4238	8687.99	2	164.41	1.52	5.81	20916546	4
2013	Mar	129.643	89.9004	1621.98	3	164.41	1.52	5.81	20585612	4
2013	Abr	39.2241	99.4367	5611.19	4	164.41	1.52	5.81	7335934	4
2013	May	10.4293	81.0784	8387.43	5	164.41	1.52	5.81	2240820.5	4
2013	Jun	4.64331	74.179	6937.15	6	164.41	1.52	5.81	1531253.375	4
2013	Jul	3.46704	94.2618	10712.5	7	164.41	1.52	5.81	1319326.625	4
2013	Ago	6.37497	98.4053	13343.7	8	164.41	1.52	5.81	1616807.625	4
2013	Sep	11.2521	134.938	14832	9	164.41	1.52	5.81	2620857.75	4
2013	Oct	21.6546	132.719	12377.7	10	164.41	1.52	5.81	3491988.25	4
2013	Nov	29.122	133.025	13473.5	11	164.41	1.52	5.81	4587928.5	4
2013	Dic	63.007	124.161	10512.6	12	164.41	1.52	5.81	9665258	4
2014	Ene	123.981	114.715	13087.9	1	164.41	1.52	5.81	20022220	4
2014	Feb	138.328	85.106	9086.98	2	164.41	1.52	5.81	20429706	4

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2014	Mar	142.517	100.144	1664.16	3	164.41	1.52	5.81	23348656	4
2014	Abr	41.5412	92.6214	6434.82	4	164.41	1.52	5.81	7230345	4
2014	May	10.4378	75.0906	8387.8	5	164.41	1.52	5.81	2089744.875	4
2014	Jun	4.94979	74.477	6314.57	6	164.41	1.52	5.81	1655623	4
2014	Jul	3.21231	96.1164	10560.3	7	164.41	1.52	5.81	1389265.75	4
2014	Ago	7.075	95.8308	14313.3	8	164.41	1.52	5.81	1752257.25	4
2014	Sep	11.7743	115.426	15264.4	9	164.41	1.52	5.81	2685058.25	4
2014	Oct	21.2105	118.36	12647.9	10	164.41	1.52	5.81	3508590.25	4
2014	Nov	29.2305	125.6	12847.5	11	164.41	1.52	5.81	4534136.5	4
2014	Dic	60.6112	113.297	11908.6	12	164.41	1.52	5.81	9418923	4
2015	Ene	134.825	112.993	12827.1	1	164.41	1.52	5.81	21556542	4
2015	Feb	127.557	101.319	9446.49	2	164.41	1.52	5.81	19340744	4
2015	Mar	141.843	98.4532	1642.27	3	164.41	1.52	5.81	23100582	4
2015	Abr	36.7415	88.6463	6068.77	4	164.41	1.52	5.81	6380358	4
2015	May	9.94099	74.635	7497.58	5	164.41	1.52	5.81	2227864.25	4
2015	Jun	4.71997	72.5892	6387.31	6	164.41	1.52	5.81	1612927.25	4
2015	Jul	3.31039	88.6456	10996.6	7	164.41	1.52	5.81	1193169.875	4
2015	Ago	6.53066	100.649	14179.1	8	164.41	1.52	5.81	1677960.75	4
2015	Sep	11.2068	106.477	15072.7	9	164.41	1.52	5.81	2452703.5	4
2015	Oct	22.0291	114.601	12582.3	10	164.41	1.52	5.81	3590872.25	4
2015	Nov	32.2368	138.465	12332.3	11	164.41	1.52	5.81	4883516	4
2015	Dic	57.3779	130.57	10684.7	12	164.41	1.52	5.81	8629066	4
2016	Ene	131.036	112.078	13142.7	1	164.41	1.52	5.81	20573442	4
2016	Feb	148.605	97.2084	8607.25	2	164.41	1.52	5.81	22502952	4
2016	Mar	139.451	91.9897	1724.1	3	164.41	1.52	5.81	22057794	4
2016	Abr	38.1381	90.7147	6044.43	4	164.41	1.52	5.81	6686267.5	4

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2016	May	9.91696	70.2817	7653.63	5	164.41	1.52	5.81	2256449.25	4
2016	Jun	4.72468	74.2109	6565.04	6	164.41	1.52	5.81	1658607.125	4
2016	Jul	3.64306	90.5772	11381.5	7	164.41	1.52	5.81	1273051.75	4
2016	Ago	6.66132	97.2286	13575.2	8	164.41	1.52	5.81	1586622.25	4
2016	Sep	10.9261	125.008	16332	9	164.41	1.52	5.81	2722725.5	4
2016	Oct	19.6504	123.734	11305	10	164.41	1.52	5.81	2988541	4
2016	Nov	28.4998	144.926	12553.9	11	164.41	1.52	5.81	4495412.5	4
2016	Dic	58.699	131.426	11916.7	12	164.41	1.52	5.81	9005456	4
2017	Ene	116.154	109.107	13774.5	1	164.41	1.52	5.81	17970312	4
2017	Feb	148.08	92.917	8093.47	2	164.41	1.52	5.81	21948828	4
2017	Mar	155.488	101.127	1683.27	3	164.41	1.52	5.81	25330220	4
2017	Abr	37.7737	90.2881	5980.66	4	164.41	1.52	5.81	6631323	4
2017	May	10.3404	80.9346	7863.19	5	164.41	1.52	5.81	2401127.75	4
2017	Jun	4.48384	77.3829	6850.6	6	164.41	1.52	5.81	1693561.125	4
2017	Jul	3.55143	101.676	9901.31	7	164.41	1.52	5.81	1815198.75	4
2017	Ago	7.28606	92.6313	12220.5	8	164.41	1.52	5.81	1691987.5	4
2017	Sep	11.576	137.782	13937.7	9	164.41	1.52	5.81	2693116.25	4
2017	Oct	22.0643	124.566	12994.5	10	164.41	1.52	5.81	3615588.75	4
2017	Nov	29.7763	125.305	13080.5	11	164.41	1.52	5.81	4603745.5	4
2017	Dic	59.9996	118.205	11445.1	12	164.41	1.52	5.81	9062881	4
2018	Ene	133.991	115.457	12961.8	1	164.41	1.52	5.81	21054036	4
2018	Feb	142.773	94.4477	9017.99	2	164.41	1.52	5.81	20994880	4
2018	Mar	138.647	99.804	1654.11	3	164.41	1.52	5.81	22628592	4
2018	Abr	39.7551	84.7623	6115.5	4	164.41	1.52	5.81	6611096.5	4
2018	May	9.74903	73.0518	7224.93	5	164.41	1.52	5.81	2405229.25	4
2018	Jun	4.48648	80.0917	7193.99	6	164.41	1.52	5.81	1738225	4

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2018	Jul	3.76316	88.9378	10521.4	7	164.41	1.52	5.81	1360193.5	4
2018	Ago	6.82706	91.8499	12651.3	8	164.41	1.52	5.81	1606945.125	4
2018	Sep	12.0839	119.985	16170	9	164.41	1.52	5.81	2669253.25	4
2018	Oct	22.7676	134.602	11959.6	10	164.41	1.52	5.81	3563385.75	4
2018	Nov	31.8311	141.692	12300.7	11	164.41	1.52	5.81	4726120.5	4
2018	Dic	65.4993	134.971	10677.2	12	164.41	1.52	5.81	9848519	4
2019	Ene	122.596	111.019	14128.4	1	164.41	1.52	5.81	18859720	4
2019	Feb	135.499	97.0525	8286.81	2	164.41	1.52	5.81	19839710	4
2019	Mar	135.252	98.7269	1518.14	3	164.41	1.52	5.81	22007132	4
2019	Abr	38.5556	90.664	6062.57	4	164.41	1.52	5.81	6756334.5	4
2019	May	10.0811	76.9534	7792.93	5	164.41	1.52	5.81	2390819.5	4
2019	Jun	4.91321	68.8314	6649.17	6	164.41	1.52	5.81	1762305.5	4
2019	Jul	3.63859	98.9675	9764.35	7	164.41	1.52	5.81	1932257.375	4
2019	Ago	7.42741	85.7476	13291.1	8	164.41	1.52	5.81	1593392.125	4
2019	Sep	12.4584	116.608	14709.7	9	164.41	1.52	5.81	2545031.25	4
2019	Oct	22.9443	111.389	12506.4	10	164.41	1.52	5.81	3566112.5	4
2019	Nov	30.8387	129.76	12777.4	11	164.41	1.52	5.81	4635248.5	4
2019	Dic	64.6795	135.538	10944.1	12	164.41	1.52	5.81	9628914	4
2020	Ene	125.696	117.291	12735.7	1	164.41	1.52	5.81	19327384	4
2020	Feb	138.596	91.0793	8549.24	2	164.41	1.52	5.81	19939608	4
2020	Mar	133.774	93.4961	1561.98	3	164.41	1.52	5.81	21100572	4
2020	Abr	37.1799	91.6806	6093.13	4	164.41	1.52	5.81	6658973.5	4
2020	May	10.5704	73.8334	7685.67	5	164.41	1.52	5.81	2530050.5	4
2020	Jun	4.86965	74.0101	6466.55	6	164.41	1.52	5.81	1879283	4
2020	Jul	3.45912	96.4548	10487.8	7	164.41	1.52	5.81	1770653.625	4
2020	Ago	6.53766	95.9236	14726.9	8	164.41	1.52	5.81	1568858.375	4

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2020	Sep	11.1739	117.954	15636.5	9	164.41	1.52	5.81	2440677	4
2020	Oct	22.4452	127.898	12102.7	10	164.41	1.52	5.81	3524358.75	4
2020	Nov	31.0407	137.966	12838.1	11	164.41	1.52	5.81	4623029.5	4
2020	Dic	63.4151	139.573	11271.1	12	164.41	1.52	5.81	9486553	4
2021	Ene	120.556	119.882	12773.6	1	164.41	1.52	5.81	18501996	4
2021	Feb	135.988	93.7418	8563.19	2	164.41	1.52	5.81	19662364	4
2021	Mar	149.126	93.2679	1536.87	3	164.41	1.52	5.81	23501580	4
2021	Abr	38.5983	91.3187	6399.55	4	164.41	1.52	5.81	6755599.5	4
2021	May	10.4789	72.2509	8467.92	5	164.41	1.52	5.81	2424449	4
2021	Jun	4.80187	77.0169	6693.83	6	164.41	1.52	5.81	1900655.5	4
2021	Jul	3.52504	98.7061	11122.6	7	164.41	1.52	5.81	1817178.5	4
2021	Ago	7.68502	99.3099	13051.1	8	164.41	1.52	5.81	1971007	4
2021	Sep	11.0534	124.446	16066.2	9	164.41	1.52	5.81	2620800	4
2021	Oct	21.8539	127.128	13853	10	164.41	1.52	5.81	3677630	4
2021	Nov	28.5737	128.402	12839.2	11	164.41	1.52	5.81	4290671.5	4
2021	Dic	63.3183	129.258	11530.2	12	164.41	1.52	5.81	9349547	4
2022	Ene	130.575	115.387	11894.9	1	164.41	1.52	5.81	19781786	4
2022	Feb	126.58	94.7123	7708	2	164.41	1.52	5.81	18492186	4
2022	Mar	147.866	92.9194	1891.99	3	164.41	1.52	5.81	23014120	4
2022	Abr	43.9165	89.6889	5996.94	4	164.41	1.52	5.81	7481979.5	4
2022	May	10.6785	81.8861	6915.12	5	164.41	1.52	5.81	2807355.5	4
2022	Jun	4.31584	70.1482	6941.53	6	164.41	1.52	5.81	1809826	4
2022	Jul	3.51878	99.797	9855.12	7	164.41	1.52	5.81	2158570	4
2022	Ago	6.45384	99.2424	12710.9	8	164.41	1.52	5.81	1904286.625	4
2022	Sep	10.2303	123.298	15958.8	9	164.41	1.52	5.81	2520009.75	4
2022	Oct	21.9651	117.937	12812.1	10	164.41	1.52	5.81	3567072.25	4

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2022	Nov	29.3908	124.977	12468	11	164.41	1.52	5.81	4323190	4
2022	Dic	63.9845	134.875	10890.8	12	164.41	1.52	5.81	9307198	4
2023	Ene	121.502	114.115	11420	1	164.41	1.52	5.81	18227992	4
2023	Feb	136.704	100.073	7992.06	2	164.41	1.52	5.81	20166990	4
2023	Mar	136.617	95.2012	1729.98	3	164.41	1.52	5.81	21537922	4
2023	Abr	38.4906	87.3772	5435.47	4	164.41	1.52	5.81	6961972	4
2023	May	10.2248	83.1648	7636.45	5	164.41	1.52	5.81	2738485.5	4
2023	Jun	4.73385	73.5659	6741.26	6	164.41	1.52	5.81	1969006	4
2023	Jul	3.2939	98.6295	10602.3	7	164.41	1.52	5.81	1954957	4
2023	Ago	7.30556	90.5192	14124.2	8	164.41	1.52	5.81	1665987.75	4
2023	Sep	11.7569	119.026	16118.9	9	164.41	1.52	5.81	2587331.5	4
2023	Oct	21.5502	115.981	12424.4	10	164.41	1.52	5.81	3599336.75	4
2023	Nov	27.2939	137.17	11746.2	11	164.41	1.52	5.81	4027419.5	4
2023	Dic	58.5289	118.964	10753.5	12	164.41	1.52	5.81	8757242	4
2024	Ene	126.903	113.279	12147	1	164.41	1.52	5.81	18905770	4
2024	Feb	127.553	95.5686	8390.49	2	164.41	1.52	5.81	18569042	4
2024	Mar	142.966	89.5144	1642.74	3	164.41	1.52	5.81	22189414	4
2024	Abr	41.9387	93.1627	5904.68	4	164.41	1.52	5.81	7693140.5	4
2024	May	10.303	74.552	7534.97	5	164.41	1.52	5.81	2810410	4
2024	Jun	4.66197	71.8051	6816.53	6	164.41	1.52	5.81	1982551.25	4
2024	Jul	3.26294	89.9183	9756.13	7	164.41	1.52	5.81	1785595.625	4
2024	Ago	6.7151	89.3682	13365.7	8	164.41	1.52	5.81	1591473.25	4
2024	Sep	10.8708	125.554	15376.6	9	164.41	1.52	5.81	2657020	4
2024	Oct	19.9248	124.653	13438.6	10	164.41	1.52	5.81	3422101.25	4
2024	Nov	28.4576	136.825	12376.3	11	164.41	1.52	5.81	4283568	4
2024	Dic	62.6637	124.348	9831.72	12	164.41	1.52	5.81	9338112	4

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2025	Ene	125.416	114.448	12560.2	1	164.41	1.52	5.81	18675856	4
2025	Feb	127.473	91.5325	8744.17	2	164.41	1.52	5.81	18413726	4
2025	Mar	140.424	94.5147	1573.45	3	164.41	1.52	5.81	22108844	4
2025	Abr	41.6797	85.1872	6175.98	4	164.41	1.52	5.81	7115283.5	4
2025	May	10.7733	77.2745	7455.73	5	164.41	1.52	5.81	2957561.25	4
2025	Jun	4.61395	76.1506	6265.1	6	164.41	1.52	5.81	2135932.25	4
2025	Jul	3.26693	92.847	11132.8	7	164.41	1.52	5.81	1673496.625	4
2025	Ago	7.43773	90.554	13054.3	8	164.41	1.52	5.81	1719844.125	4
2025	Sep	11.0292	118.066	16101.3	9	164.41	1.52	5.81	2517966.5	4
2025	Oct	20.5842	130.409	13449.8	10	164.41	1.52	5.81	3571787.25	4
2025	Nov	31.579	130.908	12833.1	11	164.41	1.52	5.81	4730175	4
2025	Dic	57.8906	129.258	11066.6	12	164.41	1.52	5.81	8519657	4
2026	Ene	136.15	108.785	12580.8	1	164.41	1.52	5.81	19948384	4
2026	Feb	134.47	86.8817	8883.11	2	164.41	1.52	5.81	19207942	4
2026	Mar	135.645	92.745	1591.21	3	164.41	1.52	5.81	21313806	4
2026	Abr	37.8191	90.4781	5964	4	164.41	1.52	5.81	7157685.5	4
2026	May	9.98304	72.7115	7652.33	5	164.41	1.52	5.81	2900310.5	4
2026	Jun	5.13097	72.9064	7080.94	6	164.41	1.52	5.81	2113325	4
2026	Jul	3.19481	95.4772	9908.76	7	164.41	1.52	5.81	2095102.875	4
2026	Ago	6.76012	91.6421	14050.2	8	164.41	1.52	5.81	1647046.875	4
2026	Sep	11.9192	123.897	14173.7	9	164.41	1.52	5.81	2684925.5	4
2026	Oct	21.8831	122.521	13028.4	10	164.41	1.52	5.81	3813381.25	4
2026	Nov	27.185	128.044	12888.6	11	164.41	1.52	5.81	4237739.5	4
2026	Dic	64.0313	118.164	10712.5	12	164.41	1.52	5.81	9759084	4
2027	Ene	128.778	120.052	13258.9	1	164.41	1.52	5.81	19337634	4
2027	Feb	139.442	89.6643	7804.89	2	164.41	1.52	5.81	20201286	4

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2027	Mar	137.974	98.3506	1741.43	3	164.41	1.52	5.81	21972882	4
2027	Abr	40.7719	92.453	6143.44	4	164.41	1.52	5.81	7648638	4
2027	May	9.88933	74.9693	8160.57	5	164.41	1.52	5.81	2870515.5	4
2027	Jun	4.51579	78.2455	6636.4	6	164.41	1.52	5.81	2184132.75	4
2027	Jul	3.66102	88.0666	10791.1	7	164.41	1.52	5.81	1724341.875	4
2027	Ago	7.03024	88.4262	13404.9	8	164.41	1.52	5.81	1672715.75	4
2027	Sep	11.953	117.239	14199.5	9	164.41	1.52	5.81	2853717.5	4
2027	Oct	21.9985	120.172	13269.1	10	164.41	1.52	5.81	3909754.5	4
2027	Nov	31.3675	133.612	14129.6	11	164.41	1.52	5.81	4904801	4
2027	Dic	63.0583	130.441	9929.75	12	164.41	1.52	5.81	9445665	4
2028	Ene	126.185	113.223	13430.3	1	164.41	1.52	5.81	18613228	4
2028	Feb	138.628	87.8923	8702.31	2	164.41	1.52	5.81	19885294	4
2028	Mar	145.466	100.816	1700.24	3	164.41	1.52	5.81	23248240	4
2028	Abr	40.8709	90.7819	6146.06	4	164.41	1.52	5.81	7618935	4
2028	May	10.8077	70.4314	7400.4	5	164.41	1.52	5.81	3200453.5	4
2028	Jun	4.55607	73.7725	7159.89	6	164.41	1.52	5.81	2148267.75	4
2028	Jul	3.33099	83.4083	10267.9	7	164.41	1.52	5.81	1632412	4
2028	Ago	7.63251	97.718	13543.9	8	164.41	1.52	5.81	1958756.5	4
2028	Sep	11.2194	114.582	15745.5	9	164.41	1.52	5.81	2642768	4
2028	Oct	21.1781	133.881	13283.4	10	164.41	1.52	5.81	3798705.75	4
2028	Nov	29.0763	129.913	12869.9	11	164.41	1.52	5.81	4654581.5	4
2028	Dic	61.6124	140.152	10900.7	12	164.41	1.52	5.81	9021485	4
2029	Ene	123.186	126.045	12846.6	1	164.41	1.52	5.81	18685640	4
2029	Feb	140.703	90.5596	8784.65	2	164.41	1.52	5.81	20255296	4
2029	Mar	142.929	84.8108	1792.04	3	164.41	1.52	5.81	22068692	4
2029	Abr	41.9139	88.7125	5696.72	4	164.41	1.52	5.81	7820760.5	4

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2029	May	10.3489	75.7871	7665.94	5	164.41	1.52	5.81	3155682.75	4
2029	Jun	4.78453	74.2326	7233.1	6	164.41	1.52	5.81	2236469.5	4
2029	Jul	3.53101	89.7583	11198.3	7	164.41	1.52	5.81	1764796.875	4
2029	Ago	7.89788	110.157	12515.1	8	164.41	1.52	5.81	2872729.25	4
2029	Sep	11.5169	109.667	15774.5	9	164.41	1.52	5.81	2688547.75	4
2029	Oct	21.4942	132.308	12414.8	10	164.41	1.52	5.81	3995443.75	4
2029	Nov	27.4165	130.852	11652.8	11	164.41	1.52	5.81	4522280.5	4
2029	Dic	64.701	119.034	10815.4	12	164.41	1.52	5.81	9960352	4
2030	Ene	114.58	113.316	13868	1	164.41	1.52	5.81	16881318	4
2030	Feb	137.938	89.3675	8614.54	2	164.41	1.52	5.81	19899012	4
2030	Mar	140.867	95.8733	1516.74	3	164.41	1.52	5.81	22370744	4
2030	Abr	40.5396	78.2713	5839.12	4	164.41	1.52	5.81	7482127	4
2030	May	9.92383	77.8495	7540.52	5	164.41	1.52	5.81	3190102.25	4
2030	Jun	4.40607	68.8343	6812	6	164.41	1.52	5.81	2357448.75	4
2030	Jul	3.4199	91.987	10231.9	7	164.41	1.52	5.81	2009450.875	4
2030	Ago	7.5532	92.6968	13201.6	8	164.41	1.52	5.81	1962814.125	4
2030	Sep	12.6132	113.696	13928.7	9	164.41	1.52	5.81	3280149.75	4
2030	Oct	22.9659	116.604	12709.5	10	164.41	1.52	5.81	4482493	4
2030	Nov	28.776	132.269	13963.5	11	164.41	1.52	5.81	4716784.5	4
2030	Dic	64.8601	138.463	10035.2	12	164.41	1.52	5.81	9715804	4
2003	Ene	120.504	98.8126	12296.4	1	164.41	1.52	5.81	18859004	5
2003	Feb	141.976	95.8141	8532.44	2	164.41	1.52	5.81	23655146	5
2003	Mar	140.583	90.4339	1644.67	3	164.41	1.52	5.81	23333652	5
2003	Abr	40.8808	83.1973	6119.33	4	164.41	1.52	5.81	6569763	5
2003	May	10.6464	73.8938	7795.88	5	164.41	1.52	5.81	1961852	5
2003	Jun	5.40608	72.0223	6877.64	6	164.41	1.52	5.81	1209421.5	5

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2003	Jul	3.30677	95.5885	10725.3	7	164.41	1.52	5.81	1308139.875	5
2003	Ago	7.37024	90.3083	13396.8	8	164.41	1.52	5.81	1543884.125	5
2003	Sep	12.2106	125.156	16088.3	9	164.41	1.52	5.81	2322674.75	5
2003	Oct	21.8381	125.226	13095.3	10	164.41	1.52	5.81	3836837.25	5
2003	Nov	28.5219	136.144	12288.9	11	164.41	1.52	5.81	5093713	5
2003	Dic	60.3858	133.997	10960.5	12	164.41	1.52	5.81	10252711	5
2004	Ene	120.261	121.229	13181.5	1	164.41	1.52	5.81	20669294	5
2004	Feb	130.72	86.2195	8565.49	2	164.41	1.52	5.81	20780376	5
2004	Mar	137.602	94.1898	1598.44	3	164.41	1.52	5.81	22820954	5
2004	Abr	35.4211	88.7525	5936.87	4	164.41	1.52	5.81	6026637	5
2004	May	10.4945	72.8257	8164.19	5	164.41	1.52	5.81	1913791.625	5
2004	Jun	4.28615	77.1464	6669.35	6	164.41	1.52	5.81	1150862	5
2004	Jul	3.58105	95.108	11081.4	7	164.41	1.52	5.81	1363307.25	5
2004	Ago	7.15776	89.9328	14201.8	8	164.41	1.52	5.81	1500610	5
2004	Sep	11.3141	123.766	16297.7	9	164.41	1.52	5.81	2189988	5
2004	Oct	20.9597	124.294	12534.1	10	164.41	1.52	5.81	3506641.75	5
2004	Nov	29.7478	134.494	11960.1	11	164.41	1.52	5.81	5142202	5
2004	Dic	59.9308	141.707	11278.5	12	164.41	1.52	5.81	10340490	5
2005	Ene	127.463	116.56	12626.5	1	164.41	1.52	5.81	21610230	5
2005	Feb	144.685	92.4644	8728.02	2	164.41	1.52	5.81	23748812	5
2005	Mar	148.805	90.0196	1754.89	3	164.41	1.52	5.81	24520270	5
2005	Abr	36.3601	97.8849	5916.66	4	164.41	1.52	5.81	6376570.5	5
2005	May	10.0487	68.329	7360.72	5	164.41	1.52	5.81	1852073	5
2005	Jun	4.49274	70.2003	6698.69	6	164.41	1.52	5.81	1241400.125	5
2005	Jul	3.59791	95.7133	10645.3	7	164.41	1.52	5.81	1254883.375	5
2005	Ago	6.89931	90.9694	14452.6	8	164.41	1.52	5.81	1520451.125	5

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2005	Sep	10.9604	132.547	15163.5	9	164.41	1.52	5.81	2451607.5	5
2005	Oct	22.1025	127.16	13736.3	10	164.41	1.52	5.81	3772192.25	5
2005	Nov	29.7797	131.409	12893.8	11	164.41	1.52	5.81	5071169.5	5
2005	Dic	63.4129	138.656	10802.3	12	164.41	1.52	5.81	10598831	5
2006	Ene	131.821	124.594	13059.3	1	164.41	1.52	5.81	22761512	5
2006	Feb	137.606	86.3067	7493.1	2	164.41	1.52	5.81	21748624	5
2006	Mar	143.473	93.2159	1586.1	3	164.41	1.52	5.81	23625794	5
2006	Abr	39.8525	90.2366	6368.97	4	164.41	1.52	5.81	6727937	5
2006	May	10.216	72.6419	7904.9	5	164.41	1.52	5.81	1884890.25	5
2006	Jun	4.68768	74.3061	6583.99	6	164.41	1.52	5.81	1331231.125	5
2006	Jul	3.32192	95.1287	10490.7	7	164.41	1.52	5.81	1123885.75	5
2006	Ago	7.47425	93.8818	12042.5	8	164.41	1.52	5.81	1851760.25	5
2006	Sep	11.1325	127.269	15121.8	9	164.41	1.52	5.81	2351482.25	5
2006	Oct	21.8277	126.653	12455.2	10	164.41	1.52	5.81	3542499.5	5
2006	Nov	27.6356	132.934	12617	11	164.41	1.52	5.81	4691306	5
2006	Dic	59.3464	131.576	11065.4	12	164.41	1.52	5.81	9654253	5
2007	Ene	127.805	116.928	13976.9	1	164.41	1.52	5.81	21167376	5
2007	Feb	133.172	94.6999	8408.33	2	164.41	1.52	5.81	21454398	5
2007	Mar	134.784	90.9209	1589.03	3	164.41	1.52	5.81	22039118	5
2007	Abr	40.0807	101.141	5813.15	4	164.41	1.52	5.81	7090497.5	5
2007	May	9.96027	75.2218	7681.06	5	164.41	1.52	5.81	1960017.5	5
2007	Jun	4.80158	77.0484	5926.7	6	164.41	1.52	5.81	1611776	5
2007	Jul	3.0237	92.3813	11059.2	7	164.41	1.52	5.81	1087338.25	5
2007	Ago	6.72774	80.8497	13638.7	8	164.41	1.52	5.81	1522404.75	5
2007	Sep	11.5173	115.737	14593.6	9	164.41	1.52	5.81	2322429.5	5
2007	Oct	21.0284	121.367	12510.6	10	164.41	1.52	5.81	3397199.75	5

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2007	Nov	30.6854	114.883	12376	11	164.41	1.52	5.81	4866372.5	5
2007	Dic	58.8481	131.039	10509.5	12	164.41	1.52	5.81	9347344	5
2008	Ene	132.965	104.454	12844.1	1	164.41	1.52	5.81	21171826	5
2008	Feb	139.277	102.071	8420.17	2	164.41	1.52	5.81	23127868	5
2008	Mar	143.023	85.2125	1433.29	3	164.41	1.52	5.81	22862636	5
2008	Abr	41.0361	90.4848	6384.26	4	164.41	1.52	5.81	6989037	5
2008	May	9.47365	77.4216	8235.8	5	164.41	1.52	5.81	1914954.875	5
2008	Jun	4.83858	73.4012	6747.89	6	164.41	1.52	5.81	1412029.25	5
2008	Jul	3.1638	101.151	10163.8	7	164.41	1.52	5.81	1059003.125	5
2008	Ago	7.48324	87.7231	12478	8	164.41	1.52	5.81	1651123.75	5
2008	Sep	12.1952	120.284	16465.4	9	164.41	1.52	5.81	2380346.25	5
2008	Oct	22.0136	109.584	13491.1	10	164.41	1.52	5.81	3707980	5
2008	Nov	29.0624	138.692	12946.3	11	164.41	1.52	5.81	4921264	5
2008	Dic	57.5478	133.83	11986	12	164.41	1.52	5.81	9277857	5
2009	Ene	131.016	114.829	13504	1	164.41	1.52	5.81	21589420	5
2009	Feb	136.922	94.3785	8157.07	2	164.41	1.52	5.81	21690934	5
2009	Mar	142.386	98.509	1559.94	3	164.41	1.52	5.81	23461240	5
2009	Abr	42.1774	90.095	5761.38	4	164.41	1.52	5.81	7286674.5	5
2009	May	10.6796	74.3779	7818.03	5	164.41	1.52	5.81	2062397.5	5
2009	Jun	4.67	72.1834	6911.45	6	164.41	1.52	5.81	1390066.875	5
2009	Jul	3.48342	85.2782	9896.24	7	164.41	1.52	5.81	1021253.188	5
2009	Ago	7.63832	94.5313	12912.8	8	164.41	1.52	5.81	1858488.25	5
2009	Sep	10.6058	115.801	13798.3	9	164.41	1.52	5.81	2315804.25	5
2009	Oct	21.9881	117.088	12290.8	10	164.41	1.52	5.81	3571049.25	5
2009	Nov	29.8437	136.449	14283.3	11	164.41	1.52	5.81	4883453.5	5
2009	Dic	57.6451	140.435	11325.5	12	164.41	1.52	5.81	9291828	5

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2010	Ene	122.883	116.33	12521.8	1	164.41	1.52	5.81	20616200	5
2010	Feb	136.753	100.448	8889.26	2	164.41	1.52	5.81	22007490	5
2010	Mar	144.319	91.6449	1507.2	3	164.41	1.52	5.81	23351316	5
2010	Abr	38.9626	95.9705	5568.64	4	164.41	1.52	5.81	7118257.5	5
2010	May	9.63555	75.9364	7161.18	5	164.41	1.52	5.81	2070199.875	5
2010	Jun	4.55134	70.8666	6284.45	6	164.41	1.52	5.81	1422056.75	5
2010	Jul	3.26625	98.0618	9798.68	7	164.41	1.52	5.81	1094362.625	5
2010	Ago	6.71598	92.1623	13745.3	8	164.41	1.52	5.81	1688075.375	5
2010	Sep	11.2667	119.567	15384	9	164.41	1.52	5.81	2406842.75	5
2010	Oct	20.171	123.686	13162.6	10	164.41	1.52	5.81	3354498	5
2010	Nov	29.3328	140.75	12201.1	11	164.41	1.52	5.81	4865761	5
2010	Dic	65.8759	133.765	10618.3	12	164.41	1.52	5.81	10420055	5
2011	Ene	127.737	114.542	13596.9	1	164.41	1.52	5.81	20930818	5
2011	Feb	128.201	89.839	9075.06	2	164.41	1.52	5.81	19455472	5
2011	Mar	136.549	97.8772	1766.33	3	164.41	1.52	5.81	22359122	5
2011	Abr	38.582	93.5935	5681.22	4	164.41	1.52	5.81	6972775	5
2011	May	10.556	76.2124	7710.15	5	164.41	1.52	5.81	2157301.25	5
2011	Jun	4.58616	66.3869	6914.72	6	164.41	1.52	5.81	1291880.375	5
2011	Jul	3.07925	93.2269	10977.4	7	164.41	1.52	5.81	1105655.25	5
2011	Ago	7.36916	104.43	13939.6	8	164.41	1.52	5.81	1945952.25	5
2011	Sep	11.0067	122.577	15313.6	9	164.41	1.52	5.81	2396072.25	5
2011	Oct	20.3517	115.025	12552.9	10	164.41	1.52	5.81	3446157.75	5
2011	Nov	26.8969	134.328	12769	11	164.41	1.52	5.81	4223584	5
2011	Dic	57.1431	135.423	11186.6	12	164.41	1.52	5.81	9063406	5
2012	Ene	129.315	113.294	13194	1	164.41	1.52	5.81	21137924	5
2012	Feb	140.103	94.8356	8272.26	2	164.41	1.52	5.81	21654356	5

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2012	Mar	142.686	99.2584	1579.43	3	164.41	1.52	5.81	23384016	5
2012	Abr	43.5032	88.1313	6038.77	4	164.41	1.52	5.81	7332473	5
2012	May	9.83014	76.3024	6875.88	5	164.41	1.52	5.81	2166052	5
2012	Jun	4.60974	68.4465	6790.64	6	164.41	1.52	5.81	1380468.5	5
2012	Jul	3.6042	97.7898	9240.78	7	164.41	1.52	5.81	1361612.125	5
2012	Ago	8.0444	96.5649	12745.2	8	164.41	1.52	5.81	1799043.375	5
2012	Sep	11.4681	123.488	14838.2	9	164.41	1.52	5.81	2504764.5	5
2012	Oct	22.3187	117.034	12653.9	10	164.41	1.52	5.81	3711214	5
2012	Nov	28.9181	124.41	13024.3	11	164.41	1.52	5.81	4511490.5	5
2012	Dic	64.1841	136.157	11242.8	12	164.41	1.52	5.81	10211775	5
2013	Ene	129.937	112.093	13353	1	164.41	1.52	5.81	20988614	5
2013	Feb	126.298	89.1939	8212.04	2	164.41	1.52	5.81	18689824	5
2013	Mar	148.34	98.0751	1667.67	3	164.41	1.52	5.81	24167648	5
2013	Abr	41.4833	86.5308	6134.08	4	164.41	1.52	5.81	6935477	5
2013	May	10.1085	78.6553	7488.61	5	164.41	1.52	5.81	2248737.25	5
2013	Jun	4.64792	74.3581	7040.49	6	164.41	1.52	5.81	1524422.75	5
2013	Jul	3.31874	94.4407	9929.17	7	164.41	1.52	5.81	1365607.25	5
2013	Ago	6.38745	96.1138	13663.7	8	164.41	1.52	5.81	1630020.125	5
2013	Sep	11.5278	110.478	15080.7	9	164.41	1.52	5.81	2615286	5
2013	Oct	19.6487	128.966	12213.7	10	164.41	1.52	5.81	3164196.5	5
2013	Nov	31.8253	140.348	12347.8	11	164.41	1.52	5.81	5028233.5	5
2013	Dic	58.8272	135.065	10344.1	12	164.41	1.52	5.81	9221707	5
2014	Ene	128.519	112.38	11673.7	1	164.41	1.52	5.81	20685252	5
2014	Feb	120.384	94.4586	8385.74	2	164.41	1.52	5.81	17814558	5
2014	Mar	136.848	96.9187	1723.52	3	164.41	1.52	5.81	22224600	5
2014	Abr	38.8365	88.9686	6179.77	4	164.41	1.52	5.81	6685624.5	5

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2014	May	9.48202	76.302	7739.84	5	164.41	1.52	5.81	2096093.875	5
2014	Jun	4.90032	65.389	6488.23	6	164.41	1.52	5.81	1504422.875	5
2014	Jul	3.2827	95.2031	10736	7	164.41	1.52	5.81	1356958.875	5
2014	Ago	7.84536	92.805	12930.1	8	164.41	1.52	5.81	1679452	5
2014	Sep	12.0328	124.225	16322.9	9	164.41	1.52	5.81	2710744.5	5
2014	Oct	22.419	113.717	12054.1	10	164.41	1.52	5.81	3559507	5
2014	Nov	27.6226	138.446	13698.4	11	164.41	1.52	5.81	4408251	5
2014	Dic	68.1254	138.336	11427.9	12	164.41	1.52	5.81	10871990	5
2015	Ene	124.156	108.501	13359.7	1	164.41	1.52	5.81	19414360	5
2015	Feb	138.324	93.9018	8795.11	2	164.41	1.52	5.81	20726252	5
2015	Mar	143.014	99.6721	1733.41	3	164.41	1.52	5.81	23373990	5
2015	Abr	40.4444	94.3377	6183.96	4	164.41	1.52	5.81	7196181.5	5
2015	May	9.93762	78.3145	7006.83	5	164.41	1.52	5.81	2302943.75	5
2015	Jun	4.98886	68.0758	6841.39	6	164.41	1.52	5.81	1542801.625	5
2015	Jul	3.28839	97.3511	10466.2	7	164.41	1.52	5.81	1497738.25	5
2015	Ago	6.71711	97.1617	12876.8	8	164.41	1.52	5.81	1568451.875	5
2015	Sep	11.88	122.418	15653.5	9	164.41	1.52	5.81	2733530.25	5
2015	Oct	21.0419	117.143	12618.8	10	164.41	1.52	5.81	3454890.5	5
2015	Nov	31.2284	145.249	12409.5	11	164.41	1.52	5.81	5024946.5	5
2015	Dic	65.7167	118.34	10155.1	12	164.41	1.52	5.81	9897328	5
2016	Ene	121.734	107.372	11800.3	1	164.41	1.52	5.81	18609640	5
2016	Feb	138.293	92.4003	8791.68	2	164.41	1.52	5.81	20448692	5
2016	Mar	145.599	94.9039	1681.54	3	164.41	1.52	5.81	23308046	5
2016	Abr	39.2362	85.1383	6347.88	4	164.41	1.52	5.81	6502330.5	5
2016	May	9.87255	71.93	7465	5	164.41	1.52	5.81	2284711.75	5
2016	Jun	4.52283	70.8889	6861.03	6	164.41	1.52	5.81	1558768.125	5

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2016	Jul	3.49328	90.4774	10228.3	7	164.41	1.52	5.81	1375703.5	5
2016	Ago	7.69122	97.5219	14635.8	8	164.41	1.52	5.81	1817928.5	5
2016	Sep	12.0501	129.414	14284.8	9	164.41	1.52	5.81	2635515.25	5
2016	Oct	22.9441	120.38	12559.2	10	164.41	1.52	5.81	3684470	5
2016	Nov	30.1972	140.343	13253.8	11	164.41	1.52	5.81	4720714.5	5
2016	Dic	59.6201	137.668	10455.7	12	164.41	1.52	5.81	9102823	5
2017	Ene	129.249	113.413	12674.8	1	164.41	1.52	5.81	20202060	5
2017	Feb	140.686	88.5423	9467.16	2	164.41	1.52	5.81	20495870	5
2017	Mar	127.925	90.8611	1658.14	3	164.41	1.52	5.81	20028148	5
2017	Abr	40.5234	90.0553	6011.7	4	164.41	1.52	5.81	6985385.5	5
2017	May	10.381	74.5882	8056.67	5	164.41	1.52	5.81	2269507.5	5
2017	Jun	4.93802	75.5596	6419.16	6	164.41	1.52	5.81	1761561.375	5
2017	Jul	3.41985	93.3068	9956.86	7	164.41	1.52	5.81	1554986.875	5
2017	Ago	7.43057	92.6019	13694.5	8	164.41	1.52	5.81	1580967.25	5
2017	Sep	10.7698	132.931	14662.1	9	164.41	1.52	5.81	2597635.75	5
2017	Oct	22.3423	125.479	12546.5	10	164.41	1.52	5.81	3561662.5	5
2017	Nov	31.222	125.774	13868.8	11	164.41	1.52	5.81	4972063.5	5
2017	Dic	62.4032	128.782	10638.4	12	164.41	1.52	5.81	9295718	5
2018	Ene	133.035	111.795	12334.8	1	164.41	1.52	5.81	20494818	5
2018	Feb	133.994	87.9036	9413.38	2	164.41	1.52	5.81	19271634	5
2018	Mar	136.754	97.5545	1645.05	3	164.41	1.52	5.81	22114096	5
2018	Abr	37.4348	90.4831	6265.34	4	164.41	1.52	5.81	6546959	5
2018	May	10.0764	79.9616	7916.7	5	164.41	1.52	5.81	2355768.75	5
2018	Jun	4.95687	70.736	6380.82	6	164.41	1.52	5.81	1772317.375	5
2018	Jul	3.32814	95.6595	10770.1	7	164.41	1.52	5.81	1554964.375	5
2018	Ago	6.5066	95.1214	13364.8	8	164.41	1.52	5.81	1576619.25	5

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2018	Sep	11.2208	130.313	15673.7	9	164.41	1.52	5.81	2748834	5
2018	Oct	23.5478	119.397	13520.4	10	164.41	1.52	5.81	3900424.5	5
2018	Nov	32.3938	142.799	12223.9	11	164.41	1.52	5.81	4798068	5
2018	Dic	61.5682	130.449	11064.2	12	164.41	1.52	5.81	9166244	5
2019	Ene	132.252	110.33	12858.5	1	164.41	1.52	5.81	20162674	5
2019	Feb	121.81	100.134	8406.96	2	164.41	1.52	5.81	17911504	5
2019	Mar	141.133	92.2099	1721.29	3	164.41	1.52	5.81	22130958	5
2019	Abr	33.787	90.4348	5997.1	4	164.41	1.52	5.81	6147329.5	5
2019	May	9.94145	81.9731	7197.83	5	164.41	1.52	5.81	2532166	5
2019	Jun	4.92201	73.6896	7170.45	6	164.41	1.52	5.81	1733425.5	5
2019	Jul	3.31894	91.2583	11058.6	7	164.41	1.52	5.81	1334871.75	5
2019	Ago	7.45435	87.8092	12902.4	8	164.41	1.52	5.81	1614356	5
2019	Sep	11.5985	127.538	14828.7	9	164.41	1.52	5.81	2627750.25	5
2019	Oct	18.8797	123.858	12127	10	164.41	1.52	5.81	3005212	5
2019	Nov	26.9251	115.032	13456.2	11	164.41	1.52	5.81	4205238	5
2019	Dic	62.7602	131.242	11550.1	12	164.41	1.52	5.81	9384745	5
2020	Ene	131.938	124.467	11922.6	1	164.41	1.52	5.81	21292976	5
2020	Feb	135.261	85.8499	8529.04	2	164.41	1.52	5.81	19322822	5
2020	Mar	138.99	96.5944	1631.71	3	164.41	1.52	5.81	22247446	5
2020	Abr	40.6003	93.6934	6678.6	4	164.41	1.52	5.81	7061148.5	5
2020	May	10.0118	71.9095	7624.68	5	164.41	1.52	5.81	2472708.25	5
2020	Jun	4.54902	77.7647	6649.48	6	164.41	1.52	5.81	1824941.875	5
2020	Jul	3.33638	92.4976	10860.6	7	164.41	1.52	5.81	1470497.25	5
2020	Ago	7.24156	92.1069	14364.1	8	164.41	1.52	5.81	1636017.375	5
2020	Sep	10.8916	122.628	15850.6	9	164.41	1.52	5.81	2534553.25	5
2020	Oct	20.2974	123.598	12233.7	10	164.41	1.52	5.81	3215854	5

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2020	Nov	31.1776	127.56	13377.9	11	164.41	1.52	5.81	4785600	5
2020	Dic	65.8071	138.457	10935.7	12	164.41	1.52	5.81	9832074	5
2021	Ene	126.385	111.841	13757.6	1	164.41	1.52	5.81	19146446	5
2021	Feb	130.756	88.5569	8915.04	2	164.41	1.52	5.81	18730820	5
2021	Mar	135.138	89.2109	1510.49	3	164.41	1.52	5.81	21052498	5
2021	Abr	38.4224	90.1357	6102.28	4	164.41	1.52	5.81	6772525	5
2021	May	10.656	77.448	7460.12	5	164.41	1.52	5.81	2643374.5	5
2021	Jun	4.69217	74.2468	7174.17	6	164.41	1.52	5.81	1806284.25	5
2021	Jul	3.45516	92.508	9963.54	7	164.41	1.52	5.81	1744863.5	5
2021	Ago	6.77169	98.3301	13643.2	8	164.41	1.52	5.81	1756050.625	5
2021	Sep	11.7072	121.623	16429.8	9	164.41	1.52	5.81	2634882.25	5
2021	Oct	21.565	126.465	12890	10	164.41	1.52	5.81	3499672.75	5
2021	Nov	29.0348	137.98	13194.8	11	164.41	1.52	5.81	4416091	5
2021	Dic	63.4722	133.279	10779.5	12	164.41	1.52	5.81	9243735	5
2022	Ene	143.133	121.979	13278.2	1	164.41	1.52	5.81	22549934	5
2022	Feb	136.252	98.1034	8851.46	2	164.41	1.52	5.81	19831508	5
2022	Mar	140.924	92.2384	1621.41	3	164.41	1.52	5.81	22021948	5
2022	Abr	33.1316	91.4631	5881.75	4	164.41	1.52	5.81	6415946	5
2022	May	10.9822	75.533	7084.24	5	164.41	1.52	5.81	2812845	5
2022	Jun	4.72731	68.613	6904.66	6	164.41	1.52	5.81	1850582.75	5
2022	Jul	3.48343	99.2668	10069.4	7	164.41	1.52	5.81	2088517.125	5
2022	Ago	7.31154	88.6652	13725.1	8	164.41	1.52	5.81	1639015.25	5
2022	Sep	11.6739	125.445	15351.2	9	164.41	1.52	5.81	2703926.25	5
2022	Oct	22.5583	130.382	12730.9	10	164.41	1.52	5.81	3663223.25	5
2022	Nov	30.1532	126.732	12368.7	11	164.41	1.52	5.81	4420827	5
2022	Dic	62.6641	140.067	10661.6	12	164.41	1.52	5.81	9071406	5

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2023	Ene	126.356	112.817	12472.4	1	164.41	1.52	5.81	18873874	5
2023	Feb	137.493	86.4078	9180.6	2	164.41	1.52	5.81	19580676	5
2023	Mar	136.057	97.0407	1524.62	3	164.41	1.52	5.81	21689340	5
2023	Abr	40.6898	93.5509	6144.82	4	164.41	1.52	5.81	7399616	5
2023	May	9.6664	76.4015	7086.46	5	164.41	1.52	5.81	2732186.25	5
2023	Jun	4.67924	76.1265	7013.69	6	164.41	1.52	5.81	1931940.625	5
2023	Jul	3.43608	90.1128	10822.4	7	164.41	1.52	5.81	1595128.375	5
2023	Ago	7.3062	84.1199	13778.9	8	164.41	1.52	5.81	1595569.875	5
2023	Sep	11.3649	129.77	14509.4	9	164.41	1.52	5.81	2733293.5	5
2023	Oct	18.5897	122.384	13103.3	10	164.41	1.52	5.81	3171860	5
2023	Nov	27.4142	127.454	14711.2	11	164.41	1.52	5.81	4409619.5	5
2023	Dic	61.4062	137.591	10448.6	12	164.41	1.52	5.81	8789444	5
2024	Ene	114.5	114.18	12644.8	1	164.41	1.52	5.81	17102158	5
2024	Feb	132.786	92.8646	8742.01	2	164.41	1.52	5.81	19181564	5
2024	Mar	139.684	87.7407	1667.58	3	164.41	1.52	5.81	21656126	5
2024	Abr	35.5354	81.2311	6251.83	4	164.41	1.52	5.81	6280235	5
2024	May	10.43	75.2434	7006.47	5	164.41	1.52	5.81	2905017.25	5
2024	Jun	4.57139	71.4489	6206.78	6	164.41	1.52	5.81	2049093.25	5
2024	Jul	3.30661	97.8198	11232.2	7	164.41	1.52	5.81	1789473.75	5
2024	Ago	7.14605	98.7594	11991	8	164.41	1.52	5.81	2155021.5	5
2024	Sep	11.7539	117.489	15585.9	9	164.41	1.52	5.81	2544790.25	5
2024	Oct	21.8262	128.669	12350.3	10	164.41	1.52	5.81	3599892.75	5
2024	Nov	30.8854	132.137	12827.7	11	164.41	1.52	5.81	4634694.5	5
2024	Dic	61.7859	127.127	10792.4	12	164.41	1.52	5.81	9142395	5
2025	Ene	127.463	116.549	12869.1	1	164.41	1.52	5.81	19086370	5
2025	Feb	140.901	97.7128	8174.76	2	164.41	1.52	5.81	20599084	5

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2025	Mar	146.854	88.1044	1675.85	3	164.41	1.52	5.81	22726660	5
2025	Abr	40.5931	81.8603	6057.03	4	164.41	1.52	5.81	6936634.5	5
2025	May	9.93389	72.5972	8040.73	5	164.41	1.52	5.81	2744110.75	5
2025	Jun	4.58424	69.4809	6770.53	6	164.41	1.52	5.81	2006156.625	5
2025	Jul	3.55118	94.0591	11095.4	7	164.41	1.52	5.81	1742193.125	5
2025	Ago	7.49291	84.7961	12909	8	164.41	1.52	5.81	1653330.875	5
2025	Sep	11.059	125.344	13335.5	9	164.41	1.52	5.81	2541911.25	5
2025	Oct	24.9167	123.905	13011.1	10	164.41	1.52	5.81	4143629.25	5
2025	Nov	31.7148	149.714	13492.9	11	164.41	1.52	5.81	4953023	5
2025	Dic	65.3175	133.607	10723.6	12	164.41	1.52	5.81	9613964	5
2026	Ene	124.822	110.403	12374.8	1	164.41	1.52	5.81	18371028	5
2026	Feb	126.345	93.0457	7901.23	2	164.41	1.52	5.81	18425480	5
2026	Mar	142.083	93.4899	1639.96	3	164.41	1.52	5.81	22270854	5
2026	Abr	38.3451	104.434	6439.01	4	164.41	1.52	5.81	7838770	5
2026	May	9.53919	76.3386	7303.02	5	164.41	1.52	5.81	2904728	5
2026	Jun	4.49874	67.5489	6890.77	6	164.41	1.52	5.81	2063219.25	5
2026	Jul	3.3165	99.3141	11004.9	7	164.41	1.52	5.81	2006151.5	5
2026	Ago	7.80055	91.1043	13575.2	8	164.41	1.52	5.81	1772911.125	5
2026	Sep	11.7385	119.508	14757.7	9	164.41	1.52	5.81	2616181.25	5
2026	Oct	23.8785	122.073	13325.7	10	164.41	1.52	5.81	4071338.75	5
2026	Nov	28.7148	125.84	12561.9	11	164.41	1.52	5.81	4487903	5
2026	Dic	61.9724	125.677	10794.7	12	164.41	1.52	5.81	9310773	5
2027	Ene	117.069	108.711	13244.9	1	164.41	1.52	5.81	17159848	5
2027	Feb	139.585	91.5699	8188.94	2	164.41	1.52	5.81	20178742	5
2027	Mar	133.51	91.912	1680.46	3	164.41	1.52	5.81	20942014	5
2027	Abr	41.2004	88.2629	5681.28	4	164.41	1.52	5.81	7558813	5

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2027	May	10.3084	72.3528	7336.83	5	164.41	1.52	5.81	3070820.5	5
2027	Jun	5.05316	75.3942	6798.28	6	164.41	1.52	5.81	2218949.25	5
2027	Jul	3.21512	95.7313	11041	7	164.41	1.52	5.81	1844649	5
2027	Ago	7.16204	101.589	14117.1	8	164.41	1.52	5.81	2013553.875	5
2027	Sep	12.3253	124.278	15800.8	9	164.41	1.52	5.81	2839875.25	5
2027	Oct	23.6627	123.4	12591.3	10	164.41	1.52	5.81	4148720.5	5
2027	Nov	29.2741	135.608	12095.7	11	164.41	1.52	5.81	4500489	5
2027	Dic	61.9125	140.018	9616.72	12	164.41	1.52	5.81	8995981	5
2028	Ene	137.674	121.623	12520.4	1	164.41	1.52	5.81	20751284	5
2028	Feb	139.176	93.4147	9158.62	2	164.41	1.52	5.81	20060928	5
2028	Mar	147.655	87.1035	1675.8	3	164.41	1.52	5.81	22838520	5
2028	Abr	38.9682	90.8849	5809.49	4	164.41	1.52	5.81	7525354	5
2028	May	11.0613	79.3842	7253.4	5	164.41	1.52	5.81	3231122.75	5
2028	Jun	4.42289	71.0039	6891.54	6	164.41	1.52	5.81	2134609	5
2028	Jul	3.47472	100.665	10898.1	7	164.41	1.52	5.81	2199514.75	5
2028	Ago	7.65298	96.7152	12338.9	8	164.41	1.52	5.81	2160560.75	5
2028	Sep	11.2674	128.898	15310.5	9	164.41	1.52	5.81	2832750.5	5
2028	Oct	22.6559	118.776	12250	10	164.41	1.52	5.81	4214646.5	5
2028	Nov	29.761	136.081	12506.1	11	164.41	1.52	5.81	4642669	5
2028	Dic	61.6242	126.505	11404.4	12	164.41	1.52	5.81	9350057	5
2029	Ene	125.981	123.525	13794.5	1	164.41	1.52	5.81	18929692	5
2029	Feb	134.946	88.6905	7728.14	2	164.41	1.52	5.81	19630400	5
2029	Mar	130.381	87.2263	1740.21	3	164.41	1.52	5.81	20389682	5
2029	Abr	39.6011	92.2732	5359.65	4	164.41	1.52	5.81	7931313	5
2029	May	9.56288	78.807	7640	5	164.41	1.52	5.81	3057983.75	5
2029	Jun	4.70425	74.4447	7296.67	6	164.41	1.52	5.81	2222313.75	5

Año	Mes	Precipitación	ETo	Demanda	Mes	Área	Pendiente	Densidad de Drenaje	Disponibilidad Hídrica Predicha	Simulación
2029	Jul	3.39553	95.0586	10585	7	164.41	1.52	5.81	2018473.5	5
2029	Ago	8.17215	85.1713	13713	8	164.41	1.52	5.81	1765415.125	5
2029	Sep	11.3134	125.879	14845.5	9	164.41	1.52	5.81	2865037.25	5
2029	Oct	22.0459	124.993	14925.2	10	164.41	1.52	5.81	3968639.5	5
2029	Nov	31.1555	128.328	12656	11	164.41	1.52	5.81	5030658.5	5
2029	Dic	60.9454	120.822	10621.8	12	164.41	1.52	5.81	9372808	5
2030	Ene	132.549	107.823	13486.8	1	164.41	1.52	5.81	19242334	5
2030	Feb	138.799	89.9711	8566.94	2	164.41	1.52	5.81	20046138	5
2030	Mar	151.987	97.0952	1628.71	3	164.41	1.52	5.81	24001090	5
2030	Abr	38.9051	90.8567	5874.73	4	164.41	1.52	5.81	7646387	5
2030	May	9.10168	83.1651	7590.5	5	164.41	1.52	5.81	3118291.75	5
2030	Jun	4.83347	72.1904	6497.08	6	164.41	1.52	5.81	2419088	5
2030	Jul	3.40156	87.1545	11677.6	7	164.41	1.52	5.81	1635188.25	5
2030	Ago	6.84859	90.2499	12968.1	8	164.41	1.52	5.81	1875124.25	5
2030	Sep	12.1115	122.499	14401.3	9	164.41	1.52	5.81	3130496.75	5
2030	Oct	23.486	125.112	13262.7	10	164.41	1.52	5.81	4393997.5	5
2030	Nov	31.0173	150.053	14342.7	11	164.41	1.52	5.81	5049778	5
2030	Dic	60.218	143.518	11006.9	12	164.41	1.52	5.81	8831164	5



UNSCH

FACULTAD DE
INGENIERÍA
DE MINAS, GEOLOGÍA Y CIVIL

ACTA DE SUSTENTACIÓN DE TESIS N° 034-2025-FIMGC

PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO CIVIL

En la Universidad Nacional de San Cristóbal de Huamanga de la ciudad de Ayacucho, en cumplimiento a la **RESOLUCIÓN DECANAL No 253-2025-FIMGC-D**, a los **veintinueve días del mes de agosto de 2025**, siendo las **4:00 p.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: **Ing. Hemerson LIZARBE ALARCON** y **Ing. Edward LEON PALACIOS**, actuando como secretario docente el **MSc. Ing. Saul Walter RETAMOZO FERNÁNDEZ**, para proceder a la sustentación de tesis para optar el **Título Profesional de Ingeniero Civil**, del bachiller:

JHAC HAROLD TABOADA VALENZUELA

Quien presentó la tesis denominada:

**DESARROLLO DE UN MODELO PREDICTIVO DE LA DISPONIBILIDAD HÍDRICA
USANDO REDES NEURONALES ARTIFICIALES (ANN) EN LA CUENCA DEL RÍO
CHALCAS, DISTRITO SAN PEDRO DE PALCO, AYACUCHO**

Los señores miembros del jurado, luego de expuesta la tesis y absueltas las preguntas, deliberaron y declararon:

Aprobado con diecisiete (17)

Siendo las **5:30 p.m.** del día **29 de agosto de 2025**, culmina el acto de sustentación de tesis, y en conformidad con lo actuado, los miembros del jurado firman al pie del presente.

MSc. Ing. José Ernesto Estrada Cárdenas
Presidente

Ing. Edward LEON PALACIOS
Miembro - Asesor

Ing. Hemerson LIZARBE ALARCON
Miembro

MSc. Saul Walter RETAMOZO FERNANDEZ
Secretario docente de la FIMGC



CONSTANCIA DE ORIGINALIDAD DE TRABAJO DE INVESTIGACIÓN

CONSTANCIA N° 016-2025-FIMGC/ASIH

El que suscribe; responsable verificador de originalidad de trabajos de tesis de pregrado con el software Turnitin, de la Escuela 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° 697-2024-FIMGC-UNSCH-D**, dejo constancia de originalidad de trabajo de investigación, que el/la Sr./Srta.

Apellidos y Nombres : Jhac Harold TABOADA VALENZUELA
Escuela Profesional : INGENIERÍA CIVIL
Título de la Tesis : DESARROLLO DE UN MODELO PREDICTIVO DE LA
DISPONIBILIDAD HÍDRICA USANDO REDES
NEURONALES ARTIFICIALES (ANN) EN LA
CUENCA DEL RÍO CHALCAS, DISTRITO SAN PEDRO
DE PALCO, AYACUCHO
Evaluación de la Originalidad : 13 % Índice de Similitud
Identificador de la entrega : 2754773010

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, 18 de setiembre del 2025



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

Mg. 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 LA DISPONIBILIDAD HÍDRICA USANDO REDES NEURONALES ARTIFICIALES (ANN) EN LA CUENCA DEL RÍO CHALCAS, DISTRITO SAN PEDRO DE PALCO, AYACUCHO

por Jhac Harold TABOADA VALENZUELA

Fecha de entrega: 18-sept-2025 11:06a. m. (UTC-0500)

Identificador de la entrega: 2754773010

Nombre del archivo: Te_Jhac_Harold_Taboada_Valenzuela.pdf (7.7M)

Total de palabras: 72109

Total de caracteres: 304746

DESARROLLO DE UN MODELO PREDICTIVO DE LA DISPONIBILIDAD HÍDRICA USANDO REDES NEURONALES ARTIFICIALES (ANN) EN LA CUENCA DEL RÍO CHALCAS, DISTRITO SAN PEDRO DE PALCO, AYACUCHO

INFORME DE ORIGINALIDAD

13%

INDICE DE SIMILITUD

14%

FUENTES DE INTERNET

7%

PUBLICACIONES

7%

TRABAJOS DEL
ESTUDIANTE

FUENTES PRIMARIAS

1

Submitted to Universidad Nacional de San
Cristóbal de Huamanga

Trabajo del estudiante

3%

2

repositorio.upeu.edu.pe

Fuente de Internet

2%

3

hdl.handle.net

Fuente de Internet

2%

4

fdocumentos.tips

Fuente de Internet

1%

5

repositorio.ana.gob.pe

Fuente de Internet

1%

6

repositorio.unj.edu.pe

Fuente de Internet

1%

7

dspace.unach.edu.ec

Fuente de Internet

<1%

8	repositorio.unfv.edu.pe Fuente de Internet	<1 %
9	bibdigital.epn.edu.ec Fuente de Internet	<1 %
10	ribuni.uni.edu.ni Fuente de Internet	<1 %
11	www.coursehero.com Fuente de Internet	<1 %
12	uvadoc.uva.es Fuente de Internet	<1 %
13	repositorioacademico.upc.edu.pe Fuente de Internet	<1 %
14	www.worldclim.org Fuente de Internet	<1 %
15	Submitted to Universidad Catolica de Avila Trabajo del estudiante	<1 %
16	repositorio.udh.edu.pe Fuente de Internet	<1 %
17	repositorio.comillas.edu Fuente de Internet	<1 %
18	Submitted to Universidad Internacional de la Rioja Trabajo del estudiante	<1 %

tesis.unsm.edu.pe

19

Fuente de Internet

<1 %

20

juandomingofarnos.wordpress.com

Fuente de Internet

<1 %

21

repositorio.unsch.edu.pe

Fuente de Internet

<1 %

22

repository.udistrital.edu.co

Fuente de Internet

<1 %

23

repositorio.upt.edu.pe

Fuente de Internet

<1 %

24

rua.ua.es

Fuente de Internet

<1 %

25

repositorio.uss.edu.pe

Fuente de Internet

<1 %

26

livrosdeamor.com.br

Fuente de Internet

<1 %

27

repositorio.usfq.edu.ec

Fuente de Internet

<1 %

28

repositorio.puce.edu.ec

Fuente de Internet

<1 %

29

Submitted to Universidad de Cantabria

Trabajo del estudiante

<1 %

30

cortolima.gov.co

Fuente de Internet

<1 %

31

www.sectorelectricidad.com

Fuente de Internet

<1 %

32

www.slideshare.net

Fuente de Internet

<1 %

Excluir citas

Activo

Excluir coincidencias

< 30 words

Excluir bibliografía

Activo