

**UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL
DE HUAMANGA**

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

ESCUELA PROFESIONAL DE INGENIERÍA CIVIL



TESIS:

**Modelo predictivo del impacto del cambio climático en la oferta
hídrica de la Cuenca Mantaro mediante redes neuronales
artificiales, Ayacucho**

Para optar el título profesional de:
INGENIERO CIVIL

PRESENTADO POR:
Bach. Efrain FLORES HUAMAN

ASESOR:
Mg. Ing. Edward LEÓN PALACIOS

AYACUCHO - PERÚ

2025

MODELO PREDICTIVO DEL IMPACTO DEL CAMBIO CLIMÁTICO EN LA
OFERTA HÍDRICA DE LA CUENCA MANTARO MEDIANTE REDES
NEURONALES ARTIFICIALES, AYACUCHO

FLORES HUAMAN EFRAIN

Presentado a la escuela de formación profesional Ingeniería Civil, facultad
de
Ingeniería de Minas, Geología y Civil, Universidad Nacional de San Cristóbal
de Huamanga en cumplimiento a los requerimientos para optar el título
profesional de:
INGENIERO CIVIL
2025

Autor: Efrain FLORES HUAMAN

Recomendado: Mg. Ing. Edward León Palacios

Asesor de Tesis

Aceptado por:

MSc. Ing. José Ernesto Estrada Cárdenas

MSc. Ing. Jaime Leonardo Bendezú Prado

Mg. Ing. Saul Walter Retamozo Fernández

Mg. Ing. Edward León Palacios

© 2025; Universidad Nacional de San Cristóbal de Huamanga (UNSCH),
todos los
derechos reservados. El autor de este trabajo autoriza a la UNSCH - Facultad
de Ingeniería
de Minas, Geología y Civil, la reproducción del trabajo en su totalidad o en
partes.

DEDICATORIA

Dedico con todo mi corazón a mis padres Lucio, Paulina y a mis hermanos por ser fuente de mi inspiración y motivación, quienes han sido la guía para poder llegar a este punto de mi carrera, por su formación con reglas, ejemplos y palabras de aliento.

AGRADECIMIENTOS

Dios, Gracias por estar presente no solo en esta etapa tan importante de mi vida, sino en todo momento ofreciéndome y buscando lo mejor para mí.

por cada detalle durante el desarrollo de esta tesis, hoy puedo testificar que eres fiel a tus promesas aun cuando las posibilidades no están a nuestro favor.

La familia es el pilar de mayor importancia que podemos tener en nuestras vidas, Por eso hoy agradezco a mis padres lucio y paulina por ser el canal de bendición para traerme a este mundo.

A mi Hermano Máximo y mi cuñada Juana Díaz por ser un canal de bendición para mí, estaré eternamente agradecida por aceptarme como su hijo.

Mi hija es el mejor regalo que he recibido, es mi mayor tesoro y también la fuente más pura de mi inspiración para continuar este proyecto y hoy quiero que sepan que por ti mi pequeña continuare hacia adelante, mi pequeña Antonela Paulina Flores Llallahui. Que este logro sea un ejemplo para ti, de que todo en la vida con esfuerzos se puede lograr. Que el cielo es el límite y que todo lo que sueñe y se proponga con dedicación lo puede alcanzar.

A mis hermanos por estar siempre presentes, acompañándome y por el apoyo moral, que me brindaron a lo largo de esta etapa.

A mi alma mater, la Universidad Nacional de San Cristóbal de Huamanga por permitirme convertirme en ser un profesional en lo que tanto me apasiona, gracias a cada maestro que hizo parte este proceso integral de formación, que deja como producto terminado, y como recuerdo y prueba viviente en la historia; esta tesis, que perdurará dentro de los conocimientos y desarrollo de las demás generaciones que están por llegar.

UNIVERSIDAD NACIONAL DE SAN CRISTOBAL DE HUAMANGA

AYACUCHO, MAYO 2025

EFRAIN FLORES HUAMAN

RESUMEN

La cuenca del río Mantaro, ubicada en la región central del Perú, es una de las más importantes en términos de abastecimiento hídrico para usos agrícolas, energéticos y poblacionales. Sin embargo, en las últimas décadas, se han evidenciado alteraciones en el régimen hidrológico como consecuencia del cambio climático, manifestadas en el aumento de la temperatura, la variabilidad de las precipitaciones y el incremento de la evapotranspiración. El propósito de la presente investigación fue desarrollar un modelo predictivo basado en redes neuronales artificiales para estimar el impacto del cambio climático en la oferta hídrica de la cuenca del río Mantaro. Además, se evaluó la influencia de variables climáticas clave como la precipitación, la temperatura y la evapotranspiración en la estimación del volumen de agua disponible. Para ello, se implementó un modelo de red neuronal tipo feedforward con dos capas ocultas, utilizando como entradas variables climáticas mensuales y como salida la oferta hídrica estimada (precipitación menos evapotranspiración). Posteriormente, se proyectaron escenarios al año 2050 incrementando la temperatura en 2 °C, reduciendo la precipitación en 20 % y aumentando la evapotranspiración en 10 %. El modelo mostró un alto nivel de precisión (98.01 %) y bajo error (RMSE: 1.59 mm). Las simulaciones evidenciaron una disminución significativa en la oferta hídrica futura, especialmente en los meses de octubre y noviembre, lo que confirma la utilidad del modelo para apoyar la gestión del recurso hídrico ante escenarios climáticos adversos.

Palabras Clave: Cambio climático, Cuenca Mantaro, Modelos predictivos, Oferta hídrica, Redes neuronales

ABSTRACT

The Mantaro River basin, located in the central region of Peru, is one of the most important in terms of water supply for agricultural, energy and population uses. However, in recent decades, alterations in the hydrological regime have been evidenced as a consequence of climate change, manifested in increased temperature, rainfall variability and increased evapotranspiration. The purpose of this research was to develop a predictive model based on artificial neural networks to estimate the impact of climate change on the water supply of the Mantaro river basin. In addition, the influence of key climatic variables such as precipitation, temperature and evapotranspiration on the estimation of available water volume was evaluated. For this purpose, a feedforward neural network model with two hidden layers was implemented, using monthly climatic variables as inputs and the estimated water supply (precipitation minus evapotranspiration) as output. Subsequently, scenarios were projected to the year 2050 by increasing temperature by 2 °C, reducing precipitation by 20 % and increasing evapotranspiration by 10 %. The model showed a high level of accuracy (98.01 %) and low error (RMSE: 1.59 mm). The simulations showed a significant decrease in future water supply, especially in the months of October and November, which confirms the usefulness of the model to support water resource management under adverse climate scenarios.

Keywords: Climate change, Mantaro Basin, Predictive models, Water supply, Neural networks, Neural networks

ÍNDICE DE CONTENIDO

DEDICATORIA.....	ii
AGRADECIMIENTOS.....	iii
RESUMEN.....	iv
ABSTRACT	v
ÍNDICE DE CONTENIDO	vi
ÍNDICE DE TABLAS.....	ix
ÍNDICE DE FIGURAS.....	x
INTRODUCCIÓN.....	xii
I. PLANTEAMIENTO DEL PROBLEMA	13
4.2 Descripción del problema	13
4.3 Delimitación del problema	14
1.1.1. Espacial (geográfica).....	14
1.1.2. Temática y unidad de análisis.....	14
4.4 Formulación del problema	14
1.1.3. Problema general	14
1.1.4. Problemas específicos.....	15
4.5 Justificación e importancia.....	15
1.1.5. Justificación.....	15
1.1.6. Importancia.....	15
4.6 Limitaciones de la investigación	16
4.7 Objetivos	16
1.1.7. Objetivo general	16
1.1.8. Objetivos específicos.....	16
II. MARCO TEÓRICO	17
2.1. Antecedentes	17
2.1.1. Investigaciones internacionales	17
2.1.2. Investigaciones nacionales.....	18
2.2. Bases teóricas	19

2.2.1.	Cuencas Hidrográficas	19
2.2.2.	Oferta Hídrica	37
2.2.3.	Redes neuronales artificiales.....	38
III.	MÉTODO DE LA INVESTIGACIÓN	43
3.1.	Tipo de investigación	43
3.2.	Nivel de investigación	43
3.3.	Diseño de investigación.....	43
3.4.	Población y muestra	44
3.4.1.	Población.....	44
3.4.2.	Muestra	44
3.5.	Hipótesis.....	44
3.5.1.	Hipótesis general.....	44
3.5.2.	Hipótesis específicas.....	44
3.6.	Operacionalización de variables	45
3.7.	Técnicas e instrumentos.....	47
3.7.1.	Técnicas.....	47
3.7.2.	Instrumentos.....	47
3.8.	Técnicas estadísticas para el procesamiento de la información.....	47
3.9.	Desarrollo de Trabajo de Tesis.....	49
3.9.1.	Ubicación Geográfica	49
3.9.2.	Climatología en la cuenca Mantaro.....	51
3.9.3.	Evapotranspiración.....	59
3.9.4.	Análisis Hidrológico	62
V.	RESULTADOS Y DISCUSIÓN.....	69
4.1.	Modelo predictivo con redes neuronales.....	69
4.2.	Escenarios del cambio climático	87
4.3.	Prueba de normalidad	98
	CONCLUSIONES.....	103
	RECOMENDACIONES.....	104

REFERENCIAS BIBLIOGRÁFICAS.....	105
ANEXOS	108

ÍNDICE DE TABLAS

Tabla 1 Tipo de Clase de corriente.....	25
Tabla 2 Tipo de Clase de escurrimiento	26
Tabla 3 Clasificación Climática.....	34
Tabla 4 Clasificación por Subtipos de Humedad	35
Tabla 5 Clasificación Térmica según la Evapotranspiración Potencial.....	36
Tabla 6 Clasificación por Subtipos de provincias térmicas	36
Tabla 7 Cuadro de Operacionalización de variables.....	46
Tabla 8 Temperatura Mínima en la Cuenca del Río Mantaro (°C)	51
Tabla 9 Temperatura máxima en la cuenca del río Mantaro (°C).....	52
Tabla 10 Temperatura media en la cuenca del río Mantaro (°C)	53
Tabla 11 Humedad relativa de la cuenca del Mantaro (%)	55
Tabla 12 Precipitación media mensual de la cuenca del Mantaro (mm/mes).....	57
Tabla 13 Resumen Numérico de la Climatología en la Cuenca del Río Mantaro	58
Tabla 14 Valores mensuales de temperatura media para la altitud de 2000–3000 msnm.....	60
Tabla 15 ETP mensual calculado	61
Tabla 16 Estaciones hidrométricas y caudal medio anual del río Mantaro.....	63
Tabla 17 Precipitación mensual por año (mm/mes).....	64
Tabla 18 Precipitación predicha periodo 2005 - 2024.....	67
Tabla 19 Resultados de las pruebas de normalidad	98

ÍNDICE DE FIGURAS

Figura 1 Perímetro y longitud de una cuenca.....	23
Figura 2 Asignación en el Orden de corrientes	25
Figura 3 Variación de una cuenca.....	28
Figura 4 Mapa de red hidrográfica	50
Figura 5 Estructura del modelo neuronal predictivo para la estimación de la oferta hídrica.....	69
Figura 6 Proceso de entrenamiento de la red neuronal en la predicción de oferta hídrica.....	72
Figura 7 Curva de desempeño del modelo de red neuronal durante el entrenamiento	73
Figura 8 Evolución del estado del entrenamiento del modelo de red neuronal.....	74
Figura 9 Histograma de errores del modelo de red neuronal	76
Figura 10 Correlación entre salidas predichas y valores objetivos del modelo neuronal	77
Figura 11 Arquitectura de la red neuronal utilizada para la estimación de la oferta hídrica.....	78
Figura 12 Representación de la capa oculta del modelo neuronal con 10 neuronas	80
Figura 13 Estructura de la segunda capa oculta del modelo neuronal con cinco neuronas	81
Figura 14 Capa de salida del modelo de red neuronal con una neurona.....	82
Figura 15 Simulaciones para observar la precisión de predicción del modelo	83
Figura 16 Variabilidad del desempeño del modelo de red neuronal en ejecuciones múltiples	86
Figura 17 Variación mensual de la oferta hídrica bajo un escenario climático 2050	89
Figura 18 Temperatura media actual y proyectada al 2050.....	90
Figura 19 Comparación mensual de la temperatura media actual y proyectada	91
Figura 20 Precipitación actual y proyectada al 2050	92
Figura 21 Comparación mensual de la precipitación actual y proyectada al 2050..	93
Figura 22 Evapotranspiración actual y proyectada al 2050	94
Figura 23 Comparación mensual de la evapotranspiración actual y proyectada al 2050	95
Figura 24 Oferta Hídrica actual y proyectada al 2050	96

Figura 25 Comparación mensual de la Oferta Hídrica actual y proyectada al 2050/97

INTRODUCCIÓN

El cambio climático es una problemática ambiental global que ha intensificado la variabilidad en los patrones climáticos, generando impactos significativos sobre los recursos hídricos. En las regiones altoandinas del Perú, como la cuenca del río Mantaro, estos efectos se manifiestan en forma de alteraciones en la temperatura, cambios en la distribución estacional de las precipitaciones y modificaciones en los procesos de evapotranspiración. Tales condiciones representan una amenaza directa para la sostenibilidad del agua, afectando la agricultura, el abastecimiento poblacional, la generación de energía hidroeléctrica y el equilibrio de los ecosistemas.

La cuenca del río Mantaro, situada en la vertiente del Atlántico y con una extensión de aproximadamente 34,550 km², es una de las más relevantes del país por su importancia económica y social. Sin embargo, estudios recientes advierten que esta cuenca es altamente vulnerable a los efectos del cambio climático, por lo que resulta necesario anticipar posibles escenarios de oferta hídrica y evaluar su comportamiento ante condiciones climáticas proyectadas.

En ese marco, la presente investigación tiene como objetivo general desarrollar un modelo predictivo basado en redes neuronales artificiales que permita estimar el impacto del cambio climático en la oferta hídrica mensual de la cuenca del río Mantaro. Se busca además evaluar la influencia específica de variables climáticas como la temperatura, la precipitación y la evapotranspiración en el comportamiento de dicha oferta. Para alcanzar este objetivo, se utilizaron datos históricos de variables climáticas mensuales y se construyó una red neuronal multicapa utilizando el entorno MATLAB. Posteriormente, se simuló escenarios futuros para el año 2050, considerando un incremento de temperatura de 2 °C, una reducción del 20 % en la precipitación y un aumento del 10 % en la evapotranspiración. Estos escenarios permiten estimar el volumen de agua disponible y observar su variación respecto a las condiciones actuales.

I. PLANTEAMIENTO DEL PROBLEMA

4.2 Descripción del problema

La cuenca del río Mantaro, ubicada en los Andes centrales del Perú, tiene una importancia crucial debido a su función en el suministro de agua para actividades agrícolas, generación de energía hidroeléctrica y abastecimiento de agua potable (Instituto Geofísico del Perú [IGP], 2005). En los últimos años, los efectos del cambio climático han comenzado a modificar los patrones hidrológicos de la cuenca, generando impactos en la disponibilidad y calidad del recurso hídrico. Estos cambios se manifiestan en una mayor variabilidad de las precipitaciones, el aumento de la frecuencia de eventos extremos, como sequías prolongadas y lluvias intensas, así como en el incremento gradual de la temperatura.

El impacto de estos fenómenos climáticos ha afectado tanto a las actividades agrícolas como a las poblaciones rurales que dependen directamente del agua para el riego y otras actividades cotidianas. En la agricultura, los caudales reducidos y la irregularidad en el abastecimiento de agua han complicado el manejo del recurso, generando incertidumbre en la producción agrícola. Además, las comunidades enfrentan desafíos adicionales relacionados con la infraestructura de saneamiento y la calidad del agua, que se ven comprometidas por las fluctuaciones en la oferta hídrica. Un análisis de la vulnerabilidad de los distritos de Ayacucho, que forma parte de la cuenca del Mantaro, ha mostrado una tendencia a la reducción de la vulnerabilidad frente a eventos climáticos extremos, como lluvias intensas, sequías y heladas, durante el período 2007-2017. Se observó que el 96% de los distritos de Ayacucho experimentaron una disminución en sus tasas de vulnerabilidad, lo cual se atribuye a mejoras en la infraestructura de vivienda y acceso a servicios básicos, lo que les permite estar mejor preparados para enfrentar las amenazas climáticas. En particular, los distritos de Jesús Nazareno y San Juan Bautista registraron las mayores disminuciones, con una reducción del 73% y 65%, respectivamente (Centro Internacional para la Investigación del Fenómeno de El Niño [CIIFEN], 2019).

Asimismo, el departamento de Ayacucho no mostró un aumento en las tasas de vulnerabilidad durante el mismo período, lo que refleja un avance en las condiciones de vida de la población. La mejora en la infraestructura de viviendas y el acceso a servicios básicos han jugado un papel fundamental en la reducción de la vulnerabilidad frente a las amenazas de lluvias intensas y sequías. Esta tendencia

de disminución fue consistente en todas las provincias del departamento, destacándose nuevamente los distritos de Jesús Nazareno y San Juan Bautista como los que presentaron las mayores tasas de reducción (Centro Internacional para la Investigación del Fenómeno de El Niño [CIIFEN], 2019).

En términos generales, la cuenca del Mantaro enfrenta desafíos significativos debido a los efectos del cambio climático, que no solo afectan la disponibilidad de agua, sino también la calidad del recurso, incrementando la concentración de contaminantes en las fuentes de agua debido a la disminución de los caudales en ciertas áreas. Las redes neuronales artificiales se presentan como una herramienta valiosa para predecir y modelar estos cambios, permitiendo anticipar los efectos del cambio climático y apoyar la toma de decisiones en la gestión sostenible del recurso hídrico.

4.3 Delimitación del problema

1.1.1. Espacial (geográfica)

La investigación se desarrolla en la cuenca del río Mantaro, ubicada en la región central del Perú.

1.1.2. Temática y unidad de análisis

El enfoque temático de la investigación se centra en la estimación del impacto del cambio climático sobre la oferta hídrica en la cuenca del río Mantaro, a través del desarrollo de un modelo predictivo basado en redes neuronales artificiales. La unidad de análisis está conformada por las variables hidrológicas y climáticas que influyen directamente en la disponibilidad de agua.

4.4 Formulación del problema

1.1.3. Problema general

¿De qué manera el desarrollo de un modelo predictivo basado en redes neuronales artificiales puede estimar con precisión el impacto del cambio climático en la oferta hídrica de la cuenca del río Mantaro?

1.1.4. Problemas específicos

- a. ¿Cómo influye la precipitación, temperatura y evapotranspiración en la oferta hídrica de la cuenca del río Mantaro?
- b. ¿Cómo desarrollar un modelo predictivo basado en redes neuronales artificiales para estimar el volumen de agua disponible bajo diferentes escenarios climáticos?
- c. ¿Qué tan preciso es el modelo predictivo desarrollado, según las métricas de precisión?

4.5 Justificación e importancia

1.1.5. Justificación

La presente investigación se justifica por la necesidad de anticipar y comprender los impactos del cambio climático en la disponibilidad del recurso hídrico en la cuenca del río Mantaro, una de las más importantes del país por su rol en el abastecimiento de agua para actividades agrícolas, hidroenergéticas y poblacionales. La creciente variabilidad climática, manifestada en eventos extremos como sequías o lluvias intensas, compromete la sostenibilidad del recurso y genera incertidumbre en su gestión. El uso de redes neuronales artificiales como herramienta de modelado predictivo representa una alternativa frente a los métodos hidrológicos tradicionales, ya que permite identificar relaciones no lineales entre variables climáticas y la oferta hídrica. Además, su capacidad de aprendizaje mejora la precisión de las proyecciones a futuro.

1.1.6. Importancia

La investigación es relevante tanto en el ámbito académico como en el sector público y privado, ya que ofrece un enfoque científico y tecnológico aplicable a la gestión del agua en escenarios de riesgo climático. Desde el punto de vista técnico, permite validar la eficacia de los modelos basados en inteligencia artificial para evaluar sistemas hidrológicos complejos. Asimismo, aporta insumos estratégicos para los gobiernos regionales y locales, instituciones de recursos hídricos y comunidades campesinas que dependen directamente del agua.

4.6 Limitaciones de la investigación

La presente investigación puede enfrentar diversas limitaciones que deben ser consideradas al momento de interpretar los resultados y proyecciones del modelo predictivo:

- **Disponibilidad y calidad de datos:** El estudio depende del acceso a registros hidrológicos y climáticos históricos proporcionados por instituciones como la ANA y el SENAMHI. Sin embargo, la existencia de datos incompletos, inconsistencias o vacíos temporales puede afectar la calidad del entrenamiento del modelo de redes neuronales artificiales.
- **Representatividad espacial:** Las estaciones hidrometeorológicas no se encuentran uniformemente distribuidas en toda la cuenca del río Mantaro, lo que puede limitar la representatividad de algunas zonas, especialmente aquellas con menor densidad de monitoreo o en zonas altas y remotas.

4.7 Objetivos

1.1.7. *Objetivo general*

Desarrollar un modelo predictivo basado en redes neuronales artificiales para estimar el impacto del cambio climático en la oferta hídrica de la cuenca del río Mantaro.

1.1.8. *Objetivos específicos*

- a. Evaluar el efecto de la precipitación, temperatura y evapotranspiración en la oferta hídrica de la cuenca del río Mantaro.
- b. Desarrollar un modelo predictivo con redes neuronales para estimar el volumen de agua disponible bajo escenarios climáticos.
- c. Validar el rendimiento del modelo predictivo mediante métricas de precisión.

II. MARCO TEÓRICO

2.1. Antecedentes

2.1.1. Investigaciones internacionales

Arteaga (2024) en su tesis *“Análisis de la oferta hídrica bajo escenarios de cambio climático en la cuenca del río San Pedro, municipio de Puerto Libertador”*, tuvo como objetivo evaluar la dinámica de la oferta hídrica superficial en la cuenca del río San Pedro bajo escenarios de cambio climático (RCP 4.5 y RCP 8.5) propuestos por el IPCC. La metodología se basó en la utilización del modelo hidrológico SWAT, que permitió modelar y analizar las condiciones históricas (1990-2020) y futuras (2040-2070) de la oferta hídrica. La información recopilada incluyó topografía, coberturas de suelo, perfiles de suelo y datos climáticos. Los resultados indicaron una disminución en la magnitud de los caudales altos y bajos bajo el escenario RCP 4.5, pero un aumento bajo el escenario RCP 8.5.

Laverde y Moyano (2020) en su tesis *“Impacto de los escenarios de cambio climático en la relación oferta-demanda en la cuenca del río Balsillas - departamento de Cundinamarca”*, tuvieron como objetivo analizar la relación oferta-demanda de agua en la cuenca del río Balsillas bajo escenarios de cambio climático. La metodología incluyó tres etapas: una fase preliminar para definir la cuenca y llenar datos faltantes, una fase de ejecución para procesar datos climatológicos mediante el software Hydro-BID y proyectar caudales hasta el 2100, y una fase de resultados que evaluó la oferta y demanda hídrica por sectores económicos. Los resultados mostraron que la oferta hídrica de la cuenca variará significativamente bajo escenarios de cambio climático, lo que afecta a la sostenibilidad del recurso hídrico en el futuro.

León (2020) en su tesis *“Modelo de gestión del recurso hídrico en la cuenca del río Tarqui, analizando escenarios de cambio climático mediante la herramienta de simulación Hydro-BID”*, tuvo como objetivo desarrollar un modelo de gestión del recurso hídrico en la cuenca del río Tarqui, analizando escenarios de cambio climático mediante la herramienta de simulación Hydro-BID. La metodología consistió en la recopilación de datos de precipitación, temperatura y caudales de las estaciones hidrométricas cercanas a la cuenca, los cuales fueron validados y sometidos a pruebas de consistencia. Posteriormente, se calibró el modelo con los datos

observados. Los resultados mostraron que, bajo escenarios optimistas de cambio climático (RCP 2.6 y RCP 4.5), se espera un aumento en los caudales entre 5.23% y 9.51%, mientras que en escenarios pesimistas (RCP 6.0 y RCP 8.5) se proyecta una disminución de hasta -7.43%

2.1.2. Investigaciones nacionales

Aguirre et al. (2024) en su tesis *“Predicción del caudal del río Torata utilizando algoritmos de Machine Learning para el aprovisionamiento de agua a la población del distrito”*, tuvieron como objetivo predecir el caudal del río Torata utilizando algoritmos de Machine Learning para garantizar el aprovisionamiento adecuado de agua a la población del distrito de Torata. La metodología empleada incluyó la recopilación de datos hidrométricos e hidrometeorológicos proporcionados por la Mina Cuajone. Se desarrollaron modelos predictivos utilizando algoritmos como Support Vector Regression (SVR) y XGBoost, basados en datos históricos del río. Los resultados mostraron que el modelo con mejor rendimiento fue el SVR lineal, alcanzando un coeficiente de determinación (R^2) de 0.946 y un error cuadrático medio (MSE) de 0.041. Además, se proyectó el caudal y la oferta hídrica para los próximos cinco años, logrando un R^2 de 0.877 y un MSE de 0.123.

Chavez y Bazan (2020) en su tesis *“Comportamiento de la escorrentía según proyecciones climáticas en la intercuenca alto Huallaga 2020 – 2059”*, tuvieron como objetivo evaluar la dinámica de la oferta hídrica superficial frente a escenarios futuros de cambio climático en la cuenca del río San Pedro. Para ello, se utilizó el modelo hidrológico SWAT, ajustado con datos históricos de la cuenca y calibrado mediante técnicas de reducción de escala y análisis de caudales proyectados. La metodología incluyó simulaciones de caudales utilizando escenarios climáticos futuros (RCP 4.5 y RCP 8.5) y la validación de los resultados mediante métricas como el NSE y el PBIAS. Los resultados indicaron que el modelo calibrado mostró una correlación aceptable con los caudales observados, subestimando ligeramente los eventos de precipitación extrema, con un PBIAS de -12.6% y un NSE de 0.61.

Goyburo (2021) en su tesis *“Reconstrucción histórica y proyecciones de cambio climático de la seguridad hídrica en la cuenca Vilcanota, Urubamba”*, tuvo como objetivo reconstruir y proyectar la seguridad hídrica en la cuenca Vilcanota-Urubamba hasta el año 2099, considerando escenarios de cambio climático y

socioeconómicos. La metodología utilizada incluyó el uso del modelo WEAP para simular el balance hídrico de la cuenca, empleando datos históricos de precipitaciones, temperatura y caudales, y proyectando las demandas de agua en los sectores agrícola, poblacional e industrial. Los resultados mostraron que la oferta hídrica es 19 veces mayor que la demanda actual, pero se espera que a partir del 2050 surjan déficits hídricos en escenarios futuros, principalmente en los sectores agrícola y poblacional, incrementando la demanda no cubierta de agua en las próximas décadas.

2.2. Bases teóricas

2.2.1. Cuencas Hidrográficas

Las cuencas hidrográficas son consideradas unidades morfológicas que abarcan tanto sistemas fluviales como acuíferos subterráneos. Su relieve y fisiografía, con formas y características particulares, a menudo no coinciden con la estructura geológica subyacente, lo que puede generar cuencas subterráneas que modifican el flujo superficial hacia otras cuencas. Este fenómeno, denominado “Cuenca Hidrológica”, es esencial para los balances hídricos, ya que resalta la necesidad de comprender las dinámicas internas. Esto resulta crucial porque, en algunos casos, los balances hidrológicos se realizan sin considerar los intercambios de agua entre cuencas vecinas. Según World Vision (2004), una cuenca también puede ser clasificada como hidrogeológica si no existen transferencias significativas de agua subterránea entre ellas, lo que permite que las divisiones topográficas que separan los flujos superficiales también limiten los flujos subterráneos, situación más común en grandes cuencas de más de 1000 o 2000 km².

Por otro lado, una cuenca hidrográfica es definida como un área geográfica delimitada por características topográficas naturales, que capta y dirige el agua hacia un punto en común. Este territorio, rico en recursos naturales, es vital para la vida humana y animal, siendo influido por el ciclo hidrológico y la interacción de las comunidades locales con su entorno. La constante evolución de estos sistemas, ya sea en su preservación o deterioro, está directamente vinculada con la acción humana. Se caracteriza por estar rodeada de elevaciones, como montañas o colinas, donde se forma un sistema de drenaje que converge en un río principal, desembocando finalmente en el océano, un lago o un río más grande. Las cuencas se pueden identificar en mapas topográficos siguiendo las líneas divisorias de aguas.

En estas áreas se encuentran recursos como el suelo, agua y vegetación, sirviendo como escenario para el desarrollo de las actividades humanas. De hecho, toda infraestructura y acción humana tiene lugar dentro de una cuenca, lo que implica que ningún lugar en la Tierra escapa a esta clasificación (Faustino y Jiménez, 2000).

2.2.1.1. Manejo integrado de cuencas hidrográficas

La gestión integrada de cuencas hidrográficas se define como una estrategia de administración enfocada en el uso, conservación y aprovechamiento de los recursos naturales dentro de una cuenca, teniendo en cuenta las demandas humanas. Este enfoque pretende lograr un equilibrio entre equidad social, sustentabilidad ambiental, viabilidad económica y desarrollo sostenible.

Este método promueve un balance entre los diferentes usos de los recursos naturales y sus impactos en la conservación a largo plazo. Requiere de una colaboración coordinada entre los recursos naturales y las comunidades que viven en la cuenca, lo que implica la integración de conocimientos de las ciencias sociales y naturales. Se resalta una visión global e interdisciplinaria que fomenta la participación activa de las comunidades en todas las etapas del proceso, desde la planificación y toma de decisiones, hasta la implementación, seguimiento y evaluación. Así, el manejo de cuencas impulsa el desarrollo de capacidades locales para asegurar una participación significativa y efectiva de todos los actores involucrados (Faustino y Jiménez, 2000).

2.2.1.2. Gestión de recursos hídricos en cuencas hidrográficas

La gestión de los recursos hídricos en las cuencas hidrográficas requiere una planificación y coordinación integral para el manejo tanto del agua como del suelo en la región. Este enfoque busca maximizar los beneficios sociales y económicos de manera equitativa, sin comprometer la salud de los ecosistemas esenciales. Incluye la gestión conjunta de aguas superficiales y subterráneas, la protección de los ecosistemas naturales, la prevención de la contaminación y el fomento de un uso racional del agua en sectores como la agricultura, la industria y el consumo doméstico.

Para que esta gestión sea eficaz, es fundamental la colaboración entre múltiples sectores y disciplinas, así como la participación activa de la comunidad, con el fin de asegurar el uso sostenible del agua y su conservación para las generaciones futuras (Faustino y Jiménez, 2000).

2.2.1.3. Ciclo Hidrológico

El ciclo del agua describe el movimiento continuo del agua a lo largo de la Tierra, pasando de la atmósfera a la superficie terrestre y regresando nuevamente al aire. Este proceso involucra varias etapas: la evaporación del agua desde océanos, suelos y cuerpos acuáticos; la formación de nubes mediante la condensación; la precipitación en forma de lluvia o nieve; la recolección del agua en la superficie terrestre; su desplazamiento a través de corrientes y ríos; y su eventual evaporación de nuevo. Este ciclo se caracteriza por ser un proceso de recirculación constante, impulsado principalmente por la energía solar, que provoca la evaporación, y la gravedad terrestre, que genera la precipitación y el flujo de agua (Baldeon, 2016).

Es relevante mencionar que la velocidad del agua en cada fase del ciclo varía de manera impredecible tanto en tiempo como en lugar. Además, las propiedades del agua pueden transformarse a lo largo del proceso. Según Chow et al. (1988), este ciclo complejo resalta la interacción dinámica de los sistemas naturales en la Tierra. A continuación, se describe las etapas de un ciclo hidrológico:

A. Evaporación: El proceso en el que el agua pasa a estado gaseoso desde superficies como océanos y tierra, así como la transpiración de los organismos vivos, en especial plantas, se conoce como evapotranspiración, ya que es difícil distinguir la cantidad evaporada de la transpirada. Aproximadamente el 10% del agua que asciende a la atmósfera proviene de plantas y otros seres vivos. Además, ocurre la sublimación, aunque en menor proporción, principalmente en las áreas heladas como los glaciares, siendo esta una contribución menor al ciclo del agua (Vásquez, 2000).

B. Precipitación: El agua es liberada desde la atmósfera mediante el proceso de condensación, apareciendo en forma de lluvia o rocío, o por sublimación inversa, lo que da lugar a nieve y escarcha. Según las condiciones

ambientales, estas precipitaciones caen sobre el suelo o la superficie terrestre. En el caso de la lluvia, la nieve y el granizo (que se forma cuando las gotas de lluvia se congelan en el aire), es la gravedad la que provoca su descenso a la tierra. En cambio, el rocío y la escarcha se forman directamente sobre las superficies debido a cambios en su estado físico (Vásquez, 2000).

C. Infiltración: Ocurre cuando el agua que llega al suelo penetra sus poros y se transforma en agua subterránea. La proporción de agua que se infiltra, en lugar de convertirse en escorrentía superficial, depende de varios factores, como la permeabilidad del suelo, la pendiente del terreno, que puede dificultar la infiltración y la presencia de vegetación. Parte del agua infiltrada regresa a la atmósfera por evaporación o principalmente por la transpiración de las plantas, que absorben el agua a través de sus raíces, las cuales pueden ser profundas y extensas. Además, una porción del agua subterránea se almacena en acuíferos, que son capas de tierra que contienen agua en reposo o en movimiento. En ciertas ocasiones, el agua subterránea puede volver a la superficie en áreas donde los acuíferos, debido a condiciones geográficas, entran en contacto con el suelo (Vásquez, 2000).

D. Escorrentía: Este término describe las diferentes formas en que el agua líquida se desplaza cuesta abajo por la superficie terrestre, ya sea después de lluvias o deshielos. En áreas con climas áridos, como desiertos o zonas semiáridas, la escorrentía adquiere una importancia crucial, ya que se convierte en el principal agente geológico que contribuye al modelado del paisaje. A través de la erosión, la escorrentía es capaz de transportar sedimentos, modificando el terreno a lo largo del tiempo. En estos entornos secos, donde el agua es escasa, la fuerza de la escorrentía es a menudo más intensa, provocando un impacto significativo en la topografía y el desplazamiento de materiales (Vásquez, 2000).

2.2.1.4. Parámetros de una cuenca hidrográfica

Los parámetros de una cuenca se dividen en tres categorías principales: La primera engloba los aspectos físicos que describen la configuración de la cuenca, prestando especial atención a su fisiografía. Los otros dos grupos se centran en las características del relieve, como la pendiente y la altitud (Baldeon, 2016).

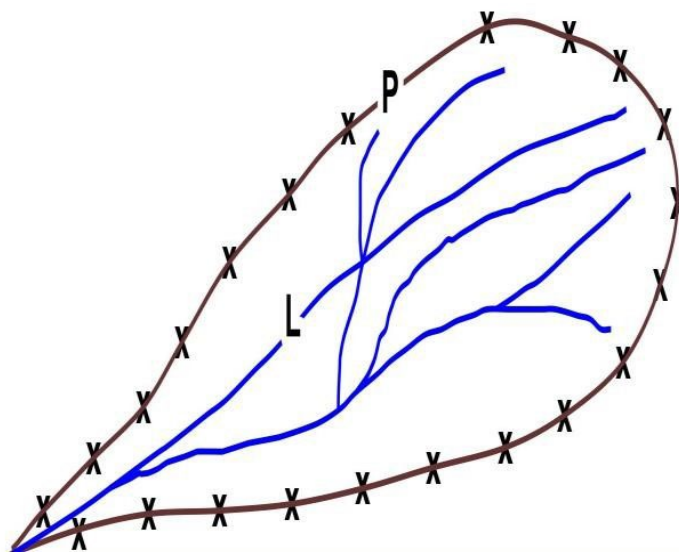
A. Lineales

Estos factores describen las propiedades físicas de las cuencas, a incluir tanto sus dimensiones morfológicas como lineales y superficiales, que combinadas se expresan en metros o kilómetros.

- **Perímetro:** Hace referencia a la longitud total que delimita la cuenca, medida desde su frontera topográfica hasta el punto de salida o el área de interés en el cauce principal. Este parámetro es fundamental para identificar el contorno de la cuenca y es una de las bases en los estudios morfométricos (Remenieras, 1974; Linsley, 1977).
- **Longitud del Cauce Principal (Lc):** Se refiere a la extensión del cauce principal, calculada desde el punto en el que se une al río receptor hasta su nacimiento, cerca de la línea divisoria de la cuenca. La longitud de los cauces secundarios (Lcs) también se suma para obtener la longitud total de los cauces (Ltc). Este valor es clave para estimar el tiempo de concentración de las aguas en la cuenca, lo cual influye en muchos índices morfométricos que ayudan a prever comportamientos hidrológicos. El cálculo de estas longitudes se realiza utilizando mapas digitales de la red hidrográfica (Linsley, 1977).

Figura 1

Perímetro y longitud de una cuenca



Nota: Tomado de Baldeon (2016)

- **Longitud Axial (La):** Hace referencia a la distancia más extensa dentro de la cuenca, medida en línea recta a lo largo de su eje principal. Esta longitud es esencial para comprender la configuración geométrica de la cuenca, ya que proporciona un indicador de su tamaño longitudinal y puede influir en los patrones de escorrentía y en la concentración del flujo.


- **Ancho Medio (Am):** Se define como el promedio de la amplitud de la cuenca, calculado a partir de la medición del ancho en diversos puntos a lo largo de su extensión. Alternativamente, también se puede determinar dividiendo el área total de la cuenca entre su longitud axial. Este parámetro es crucial para evaluar la forma y simetría de la cuenca, afectando los tiempos de concentración y la distribución del caudal.

- **Longitud Total de Curvas de Nivel:** Este parámetro representa la suma de las longitudes de todas las curvas de nivel que cruzan la cuenca. Las curvas de nivel son fundamentales en la topografía de una cuenca, ya que permiten evaluar su pendiente y variaciones en altitud, lo cual impacta directamente en la velocidad del flujo de agua y en los procesos erosivos.

- **Orden de Corrientes:** Este índice describe el grado de complejidad y ramificación de la red de cursos de agua dentro de la cuenca. Según Horton (1945), se asigna el primer orden a los cursos de agua que no tienen afluentes, mientras que los de segundo orden reciben afluentes de primer orden, y así sucesivamente. Cuanto mayor sea el orden de la corriente principal, más desarrollada y extensa será la red hidrográfica de la cuenca. Este parámetro es clave para entender la dinámica del drenaje y su capacidad para manejar grandes volúmenes de agua. Además, el orden de los cursos de agua está relacionado con la capacidad de transporte de sedimentos y la formación de cauces fluviales.

Figura 2

Asignación en el Orden de corrientes



Nota. Tomado de Baldeon (2016)

La clasificación de los cursos de agua se lleva a cabo agrupando las corrientes según su nivel de ramificación. Una corriente se clasifica como de primer orden si no recibe afluentes. Cuando dos corrientes de primer orden convergen, generan una corriente de segundo orden. De manera similar, la confluencia de dos corrientes de segundo orden da lugar a una de tercer orden, y este proceso se repite en niveles superiores conforme aumenta la complejidad de la red fluvial. Cada nivel de orden refleja el grado de interconexión y desarrollo de la red hidrográfica, lo cual tiene implicaciones importantes en el análisis hidrológico, ya que el aumento en el orden está asociado con una mayor capacidad para transportar agua y sedimentos, así como con la estructura y dinámica de los flujos en la cuenca.

Tabla 1

Tipo de Clase de corriente

Rango de Orden	Tipo de Clase
1 a 2	Bajo
2 a 4	Medio
> 6	Alto

Nota. Elaboración Propia. Adaptado de Baldeon (2016)

- **Cantidad de Escurrimiento:** Hace referencia al número total de corrientes naturales que se encuentran dentro de la cuenca. Este valor se obtiene mediante el uso de Sistemas de Información Geográfica (SIG), a través del cual se identifican y contabilizan los segmentos de ríos y arroyos presentes en el mapa digital. Este indicador proporciona una medida del potencial hidrológico de la cuenca, reflejando su capacidad para captar y distribuir agua, así como la extensión y densidad de su red fluvial. Cuanto mayor sea el número de afluentes, más eficiente será el sistema de drenaje, ya que permite una mejor distribución del flujo hídrico. La cantidad de escurrimientos también influye en la capacidad de la cuenca para manejar precipitaciones intensas y minimizar la posibilidad de inundaciones.

Tabla 2

Tipo de Clase de escurrimiento

Rango de Escurrimiento	Tipo de Clase
0 a 170	Bajo
171 a 340	Medio
341 a 510	Alto

Nota. Elaboración Propia. Adaptado de Baldeon (2016)

B. Superficiales

Las áreas superficiales de una cuenca se miden utilizando una variedad de métodos, como el uso de planímetros, redes de puntos, técnicas de integración, descomposición geométrica o dispositivos electrónicos de digitalización. Habitualmente, estos valores se expresan en hectáreas (ha) o kilómetros cuadrados (km²) (Remenieras, 1974).

- **Área de la Cuenca:** Se refiere a la extensión total de la cuenca, medida en kilómetros cuadrados (km²), que está delimitada por su frontera topográfica y proyectada en un plano horizontal. El cálculo de este valor se realiza de manera automatizada mediante la digitalización de la cuenca y la formación de polígonos a través de sistemas de información geográfica (SIG). Cabe destacar que el análisis de cuencas varía en función de su tamaño. En cuencas más

pequeñas, la forma y el volumen del escurrimiento dependen en gran medida de las características físicas del terreno, lo que requiere un enfoque hidrológico más centrado en la propia cuenca. En contraste, en cuencas de mayor tamaño, el efecto de retención de agua del cauce adquiere mayor importancia, lo que demanda un análisis detallado de las propiedades y capacidad de almacenamiento del cauce (Tetuno, 1993).

2.2.1.5. Variables morfológicas de una cuenca

A. Densidad de Drenajes (D_d)

La densidad de drenaje se refiere a la cantidad de cursos de agua por unidad de superficie dentro de una cuenca, lo que permite evaluar la complejidad y el grado de desarrollo de su sistema de drenaje. Un valor alto de densidad de drenaje indica una red fluvial más intrincada y, a menudo, un mayor potencial de erosión y transporte de sedimentos (Gregory y Walling, 1973).

Este parámetro vincula la configuración morfológica de la cuenca con los procesos hidrológicos que se desarrollan en sus cauces, proporcionando una comprensión detallada de cómo el agua se desplaza y afecta al terreno. La densidad de drenaje refleja múltiples factores, como la topografía de la región, las características geológicas y del suelo, la cobertura vegetal, y la influencia de las actividades humanas. Se expresa en kilómetros por kilómetro cuadrado (km/km^2) y se calcula dividiendo la longitud total de los cauces de agua en la cuenca entre su área total. Una alta densidad de drenaje suele estar asociada a terrenos montañosos o áreas con suelos impermeables, mientras que una densidad baja puede indicar suelos más permeables o regiones con menos pendientes. Este indicador es crucial para entender los patrones de escurrimiento y los riesgos asociados a la erosión y la sedimentación en la cuenca, influyendo directamente en la planificación de recursos hídricos y en la gestión ambiental (Gregory y Walling, 1973).

$$D_d = \frac{Ltc}{A}$$

Ecuación (1)

Donde:

L_{tc} : Longitud de las corrientes efímeras e intermitentes de la cuenca (Km).


A : Área de la cuenca (km²)

B. Variación en la formación de una Cuenca

Aunque dos cuencas puedan tener un área y un perímetro similares, sus configuraciones geomorfológicas pueden ser completamente diferentes, lo que genera contrastes significativos en su comportamiento hidrológico, especialmente en la forma en que responden a eventos de crecidas. Estas diferencias pueden influir en la velocidad y cantidad del escurrimiento, así como en la capacidad de retención de agua. Para comprender mejor estas variaciones, se utilizan diversos índices que permiten analizar y comparar las formas de las cuencas y predecir su respuesta ante precipitaciones intensas o prolongadas. Estos índices son esenciales para identificar cómo la topografía, la pendiente y la distribución del terreno afectan la dinámica del flujo de agua en cada cuenca, proporcionando información valiosa para la planificación y gestión del riesgo de inundaciones, así como para el diseño de infraestructuras hidráulicas adecuadas a las características de cada cuenca.

Figura 3

Variación de una cuenca



Nota. Tomado de Baldeon (2016)

- **Coefficiente de Compacidad (K_c):** Este índice evalúa la forma de una cuenca al compararla con la de un círculo que tiene el mismo tamaño superficial. El coeficiente de compacidad (K_c) se

determina mediante la relación entre el perímetro de la cuenca (la longitud de su divisoria topográfica) y el perímetro de un círculo cuya área es igual a la de la cuenca en estudio (Gregory y Walling, 1973).

Cuencas con una forma más cercana a la circular tienden a concentrar el flujo de escorrentía de manera más eficiente, lo que puede aumentar el riesgo de inundaciones al acelerar el tiempo de respuesta ante precipitaciones intensas. En contraste, las cuencas con formas más alargadas suelen dispersar el flujo de escorrentía en mayor tiempo, pero son más vulnerables a inundaciones si las lluvias persisten o se desplazan hacia las zonas bajas de la cuenca. La fórmula específica para determinar este coeficiente es la siguiente:

$$K_c = 0.28 \frac{P}{\sqrt{A}} \quad \text{Ecuación (2)}$$

Donde:

K_c = Representa el coeficiente de Conpacidad

P = Perímetro de la cuenca

A = Área de la cuenca

- **Coeficiente de forma (K_f):** Este indicador se obtiene calculando la relación entre el área de captación de una cuenca y su longitud axial, que representa la distancia desde el punto de salida o desembocadura hasta el punto más alejado dentro de la cuenca. El coeficiente de forma ofrece una medida de cuán compacta o alargada es una cuenca, proporcionando información valiosa sobre su capacidad para concentrar y canalizar el agua de escorrentía. Un coeficiente de forma más alto indica una cuenca más compacta, lo que sugiere una mayor capacidad para generar escorrentía rápida, dado que el agua recorrerá distancias más cortas hacia el punto de salida. En contraste, un valor bajo del coeficiente implica una cuenca más alargada, donde la escorrentía tardará más tiempo en alcanzar la desembocadura, lo que puede reducir el riesgo de inundaciones inmediatas, pero

puede provocar un flujo más sostenido durante lluvias prolongadas (Gregory y Walling, 1973).

Este factor es clave para analizar el comportamiento hidrológico de la cuenca, ya que permite anticipar cómo la forma influye en la velocidad y volumen del flujo de agua, ayudando a planificar el manejo de recursos hídricos y la mitigación de riesgos asociados a las precipitaciones intensas. El factor de forma se determina de la siguiente manera:

$$K_f = \frac{A}{La^2} \quad \text{Ecuación (3)}$$

Donde:

A = Área de la cuenca

La = Longitud axial

Este coeficiente establece una comparación entre la forma de la cuenca y la de un cuadrado, asignando un valor de $K_f = 1$ a aquellas áreas que, teóricamente, poseen esta geometría. Un coeficiente de forma mayor a 1 refleja cuán más extendida o aplanada es la cuenca, o también, cuán corto es su cauce principal. En consecuencia, una cuenca con un K_f elevado tiene la capacidad de concentrar el agua proveniente de lluvias intensas de manera más rápida, lo que facilita la formación de crecidas considerables. Cuanto mayor sea el coeficiente, más compacta es la cuenca, lo que implica que las precipitaciones se trasladarán de forma más rápida hacia el cauce principal, incrementando la probabilidad de eventos extremos como inundaciones. Este análisis es crucial para comprender la respuesta de la cuenca a diferentes patrones de lluvia, proporcionando una herramienta predictiva para la gestión de emergencias y la planificación de infraestructuras hidráulicas que minimicen los riesgos asociados a las crecidas súbitas.

- **Índice de alargamiento (I_a):** Propuesto por Horton en 1945, este índice evalúa la relación entre la longitud máxima de una cuenca, medida a lo largo del cauce principal del río, y su ancho máximo,

que se determina de manera perpendicular a dicha longitud. El índice de alargamiento ofrece una idea clara sobre la forma general de la cuenca, lo que permite predecir cómo esta podría influir en el comportamiento del flujo de agua. Este coeficiente es crucial para comprender la configuración geométrica de la cuenca, ya que una cuenca más alargada tiende a tener tiempos de respuesta más prolongados en lo que respecta al escurrimiento y la acumulación de agua, mientras que una cuenca más compacta o con un índice más bajo tendrá una respuesta más rápida a las precipitaciones. Se calcula utilizando la siguiente fórmula:

$$I_a = \frac{L_m}{l} \quad \text{Ecuación (4)}$$

Donde:

I_a = Representa el índice de alargamiento de la cuenca

L_m = Longitud máxima

l = Ancho máximo

- **Coeficiente de masividad (K_m):** Este coeficiente expresa la relación entre la altitud media de una cuenca y su superficie total. Proporciona una medida que refleja la robustez del relieve, lo que permite entender cómo la altitud promedio influye en los procesos hidrológicos y geomorfológicos de la cuenca.

$$K_m = \frac{\text{Elevación de la cuenca (m)}}{\text{Área de la cuenca (km}^2\text{)}} \quad \text{Ecuación (5)}$$

C. Relieve de la Cuenca

El relieve de una cuenca se representa visualmente a través de la curva hipsométrica y puede analizarse utilizando diversos parámetros que relacionan la altitud con el área de la cuenca. Algunos de los parámetros más relevantes incluyen el rectángulo equivalente, la altitud media de la cuenca y la pendiente promedio.

- **Altitud Promedio de la Cuenca (H):** La altitud promedio de una cuenca es un factor clave que influye directamente en la cantidad de precipitación que recibe, en las pérdidas de agua debidas a la

evaporación y transpiración, y en el caudal medio de sus corrientes. Esta altitud se calcula determinando el área total entre las curvas de nivel que representan diferentes alturas dentro de la cuenca. En el punto de altitud media, el área se distribuye de manera equitativa, con un 50% por encima y otro 50% por debajo de dicha altitud. Este indicador es crucial para estimar el comportamiento hidrológico de la cuenca, especialmente en lo que respecta a la generación de escorrentía y los ciclos de agua (Tetuno, 1993).

- **Rectángulo Equivalente:** Este parámetro geométrico ofrece una representación simplificada del relieve de la cuenca, transformándola en un rectángulo cuyos lados mayores y menores tienen un área y perímetro equivalentes a los de la cuenca real. Este enfoque facilita el análisis de las características geomorfológicas, permitiendo una comparación más accesible entre diferentes cuencas y proporcionando una base útil para el diseño de infraestructuras hídricas. Además, permite estimar el comportamiento del flujo de agua en función de la forma y proporciones de la cuenca, lo que resulta valioso en la planificación de sistemas de drenaje y control de inundaciones (Tetuno, 1993).

$$L \times l = A (Km^2)$$

Ecuación (6)

$$2(L + l) = P (Km)$$

Donde:

L = Longitud del lado mayor del rectángulo equivalente (km)

l = Longitud del lado menor del rectángulo equivalente (km)

D. Clasificación Climática

Para determinar el tipo de clima en una región, se emplea la fórmula de Thornthwaite, que se basa principalmente en la temperatura y la precipitación como variables meteorológicas esenciales. Estas variables permiten calcular la Evapotranspiración Potencial (ETP), una medida que se utiliza para llevar a cabo el Balance Hídrico, el cual identifica los

periodos de excedente o déficit de agua, aspectos cruciales para caracterizar el clima de la zona.

El sistema de clasificación climática de Thornthwaite está compuesto por una secuencia de cuatro letras con subíndices. Las dos primeras letras, en mayúsculas, representan el “Índice de Humedad” y la “Eficiencia Térmica” de la región. Las tercera y cuarta letras, en minúsculas, indican la “Variabilidad estacional de la humedad” y la “Agrupación térmica durante el verano”. Este sistema proporciona una descripción detallada del clima, tomando en cuenta tanto las condiciones térmicas como la disponibilidad de agua en el área (Thornthwaite, 1948).

- **Índice de humedad:** El Índice de humedad según Thornthwaite se calcula utilizando la siguiente fórmula:

$$I_h = I_E - 0.6I_D \quad \text{Ecuación (7)}$$

Siendo:

I_E = Índice de exceso, que se calcula por la siguiente expresión:

$$I_E = \frac{E}{ETP} \times 100$$

I_D = Índice de déficit, que se calcula por la siguiente expresión:

$$I_D = \frac{D}{ETP} \times 100$$

- **Evaluación de la eficiencia térmica:** Según Thornthwaite (1948), la evapotranspiración potencial (ETP) se utiliza como una medida clave para determinar la eficiencia térmica de un clima. El promedio mensual de ETP se emplea para evaluar cómo la energía térmica influye en el proceso de evaporación y transpiración, lo que proporciona una visión detallada del comportamiento térmico de la región bajo estudio.
- **Análisis de la variabilidad estacional de la humedad:** Según Thornthwaite (1948) es fundamental detectar la presencia de periodos secos en zonas generalmente húmedas, así como identificar los periodos húmedos en climas predominantemente secos. Este análisis ayuda a comprender los ciclos estacionales y su impacto en la disponibilidad de agua, permitiendo anticipar

comportamientos climáticos inusuales que podrían influir en la agricultura, la infraestructura y la gestión de recursos hídricos

- **Cálculo de la concentración térmica durante el verano:** Este parámetro se obtiene sumando la evapotranspiración potencial registrada durante los meses de verano y comparándola con el total anual de ETP. El resultado se expresa como un porcentaje, lo que facilita la evaluación de la intensidad del calor durante la temporada estival en relación con el comportamiento térmico global del año. Este análisis es crucial para entender la distribución de la energía térmica a lo largo del año y su efecto sobre la dinámica climática de la región (Thornthwaite, 1948).

$$C_v = \frac{ETP_{\text{verano}}}{ETP_{\text{anual}}} \times 100 \quad \text{Ecuación (8)}$$

Los parámetros utilizados para distinguir entre los diferentes tipos de regímenes hídricos se fundamentan en los valores derivados del índice hídrico. Estos tipos se representan mediante letras mayúsculas, sin la inclusión de tildes. En la tabla 5, se presenta una clasificación climática basada en el Índice Hídrico, la cual permite identificar con precisión las características específicas de cada régimen hídrico.

Tabla 3
Clasificación Climática

PROVINCIAS DE HUMEDAD		
Clasificación según Índice Hídrico		
TIPO	Índice de Pluvial	CLIMA
A	> a 100	Super húmedo
B4	80 a 100	Muy húmedo
B3	60 a 80	Húmedo
B2	40 a 60	Moderadamente húmedo
B1	20 a 40	Ligeramente húmedo
C2	0 a 20	Semi-húmedo
C1	(-20) a 0	Semi-seco
D	(-40 a -20)	Seco
E	(-60 a -40)	Arido

Nota. Tomado de (Thornthwaite, 1948).

Estas áreas de humedad se categorizan en función del patrón anual de precipitaciones, considerando tanto los periodos de déficit como los de excedente hídrico. Los subgrupos correspondientes a las zonas de humedad se identifican mediante letras minúsculas, sin el uso de tildes, y su interpretación específica puede consultarse en la tabla 6.

Tabla 4

Clasificación por Subtipos de Humedad

SubClasificación de Humedad según Índice de Exceso e Índice de Déficit		
SUB-TIPO	Índice de Exceso (%)	CLIMA SECO (por exceso de agua)
w'2	> 20	Exceso grande en invierno
s'2	> 20	Exceso grande en verano
w'	10 a 20	Exceso moderado en invierno
s'	10 a 20	Exceso moderado en verano
d	0 a 10	Poco o ningún exceso
SUB-TIPO	Índice de Déficit (%)	CLIMA HUMEDO (por falta de agua)
w2	> 33.3	Déficit grande en invierno
s2	> 33.3	Déficit grande en verano
w	16.7 a 33.3	Déficit moderado en invierno
s	16.7 a 33.3	Déficit moderado en verano
r	0 a 16.7	Déficit pequeño o ninguno

Nota. Tomado de (Thorntwaite, 1948).

En la clasificación térmica que utiliza la evapotranspiración potencial (ETP) como criterio de referencia, esta no se trata como un índice puramente hidrológico, sino como una variable que depende directamente de la temperatura media solar. La ETP refleja la cantidad de agua que se perdería por evaporación y transpiración en condiciones ideales, lo que la convierte en un indicador crucial para entender la dinámica térmica de una región. Para distinguir las diferentes categorías térmicas en esta clasificación, se emplean letras mayúsculas con acentos, proporcionando un sistema claro para identificar los distintos niveles de evapotranspiración en función de las condiciones térmicas predominantes. En la tabla 7 se detalla la distribución de estas clasificaciones térmicas, las cuales se derivan directamente de los valores de evapotranspiración, ofreciendo una herramienta útil para analizar la interacción entre el clima y el ciclo hidrológico.

Tabla 5*Clasificación Térmica según la Evapotranspiración Potencial*

PROVINCIAS TERMICAS		
Provincias Térmicas según Índice de Evapotranspiración Potencial		
TIPO	Eto (cm)	CLIMA
A'	> a 114.0	Cálido
B'4	99.7 a 114.0	Semicálido
B'3	85.5 a 99.7	Templado cálido
B'2	71.2 a 85.5	Templado frío
B'1	57.0 a 71.2	Semi frío
C'2	42.7 a 57.0	Frío moderado
C'1	28.5 a 42.7	Frío acentuado
D'	14.2 a 28.5	De tundra
E'	< a 14.2	Helado

Nota. Tomado de (Thorntwaite, 1948).

Estas clasificaciones climáticas se subdividen en diversas categorías en función del patrón térmico anual, teniendo en cuenta el porcentaje de acumulación de calor a lo largo del año, con especial énfasis en el periodo estival o de verano. Este enfoque permite evaluar cómo se distribuye la energía térmica durante los meses más cálidos, lo que es crucial para comprender el impacto del calor en los procesos de evapotranspiración y la dinámica hídrica de la región (ver tabla 8).

Tabla 6*Clasificación por Subtipos de provincias térmicas*

SubClasificación de Provincias Térmicas	
SUB-TIPO	Concentración Estival (Base % Eto del Verano)
d'	> 88.0
c'1	76.3 a 88.0
c'2	68.0 a 76.3
b'1	61.6 a 68.0
b'2	56.3 a 61.6
b'3	51.9 a 56.3
b'4	48.0 a 51.9
a'	< a 48.0

Nota. Tomado de (Thorntwaite, 1948).

2.2.2. Oferta Hídrica

La oferta hídrica en una cuenca se refiere a la cantidad de agua disponible para satisfacer tanto las necesidades biológicas como las demandas asociadas a actividades humanas, ya sean sociales o económicas. La medición de la escorrentía es clave para determinar cuánta agua superficial está accesible en una cuenca. Factores como el caudal del río, la confiabilidad de las mediciones y la longitud del registro histórico de datos pueden influir significativamente en la precisión de estas estimaciones. En los casos donde existen registros históricos extensos y confiables, el caudal medio anual del río es un buen indicador de la oferta hídrica disponible en esa cuenca (Gomez, 2022).

Con la publicación del Estudio Nacional del Agua - ENA (2010) y la Política Nacional del Recurso Hídrico (2010), se ha redefinido la oferta hídrica como la cantidad de agua que fluye superficialmente por escorrentía, formando sistemas de drenaje, como las cuencas hidrográficas, y también como aquella que se infiltra en el suelo, contribuyendo a la recarga de fuentes de agua subterránea. Esta oferta está estrechamente relacionada con el caudal, definido como la cantidad de agua que circula en un período de tiempo determinado y en un lugar específico (Castillo, 2022).

El agua que, después de haber sido precipitada sobre la cuenca, satisface la evapotranspiración y la infiltración en el sistema suelo-cobertura vegetal, fluye por los cauces principales de los ríos y demás corrientes superficiales. Esta agua alimenta lagos, lagunas, reservorios y, eventualmente, confluye con otras corrientes, llegando directa o indirectamente al océano. Este flujo de agua, conocido como escorrentía superficial, es uno de los principales parámetros medidos en las redes hidrológicas de los distintos países. La oferta hídrica de una cuenca se define, por tanto, como el volumen disponible para satisfacer las demandas de las actividades sociales y económicas del ser humano. Al cuantificar la escorrentía superficial mediante el balance hídrico de la cuenca, se estima su oferta de agua superficial.

Para calcular de forma precisa la oferta hídrica, es esencial contar con registros históricos confiables de los caudales fluviales, ya que variables como la confiabilidad y la duración de la serie de datos son factores críticos en la estimación de la oferta. En aquellos casos en los que los registros son extensos y consistentes, el caudal medio anual del río puede considerarse una medida representativa de la

oferta hídrica superficial de la cuenca. La Oferta Hídrica Neta se determina convirtiendo la cifra obtenida de la profundidad del agua, a partir del análisis del mapa de escurrimiento superficial total, en un caudal expresado en millones de metros cúbicos por año. Este proceso de conversión utiliza una fórmula específica recomendada por el IDEAM, detallada en su guía metodológica para calcular con precisión el índice de escasez de agua.

$$Y = \frac{(Q \times t)}{A \times 10000} \rightarrow Q = \frac{Y \times (A \times 10000)}{t} \quad \text{Ecuación (9)}$$

Donde:

Y = Escurrimiento superficial total (mm)

Q= Caudal (millones de m³ /año)

t= Tiempo en años

A= Área

2.2.3. Redes neuronales artificiales

Las Redes Neuronales Artificiales (RNA) son modelos computacionales altamente inspirados en la estructura y funcionamiento del cerebro humano. Están diseñadas para aprender y generalizar patrones a partir de datos, y son una herramienta clave en áreas como el aprendizaje automático, reconocimiento de patrones, clasificación, regresión, procesamiento de lenguaje natural, y más. Su estructura se organiza en capas de neuronas conectadas entre sí, donde cada neurona procesa información y transmite un resultado a las neuronas de la siguiente capa (Noya y Sutizal, 2023).

2.2.3.1. Estructura de una Red Neuronal

Una red neuronal artificial generalmente se compone de tres tipos de capas:

1. Capa de entrada:

- Recibe los datos crudos, como imágenes, señales o cualquier otro tipo de información.

- No realiza procesamiento, solo distribuye la información a las neuronas en la primera capa oculta.

2. Capas ocultas:

- Son las encargadas de realizar la mayor parte del procesamiento.
- Pueden existir varias capas ocultas, lo que se conoce como redes neuronales profundas (Deep Neural Networks).
- Cada neurona en estas capas realiza un cálculo basado en las entradas que recibe, aplicando funciones de activación para producir una salida no lineal.

3. Capa de salida:

- Genera la respuesta final del sistema, que puede ser un valor continuo en problemas de regresión o una clase en problemas de clasificación.

2.2.3.2. Funcionamiento General

Las neuronas en las RNA operan recibiendo varias entradas, cada una de las cuales está ponderada por un valor numérico llamado peso. Además, se añade un término llamado sesgo (bias) para ajustar la salida de la neurona independientemente de las entradas (Noya y Sutizal, 2023). La fórmula que describe la salida de una neurona es:

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad \text{Ecuación (10)}$$

Donde:

- y es la salida de la neurona.
- w_i son los pesos asociados a cada entrada x_i
- b es el sesgo o bias.
- f es la función de activación, que introduce no linealidad al sistema.

2.2.3.3. Proceso de Entrenamiento

El proceso de entrenamiento de una red neuronal artificial es fundamental para que la red sea capaz de aprender patrones a partir de los datos de entrada. Este proceso consiste en ajustar los pesos y sesgos de la red para minimizar la diferencia entre las predicciones y los valores reales, lo que se conoce como error. El entrenamiento implica múltiples iteraciones donde la red mejora su capacidad de generalización mediante un ciclo de ajuste continuo de los parámetros internos (Noya y Sutizal, 2023). A continuación, se detallan los pasos clave de este proceso:

- a. **Forward Propagation:** Los datos de entrada pasan a través de la red capa por capa hasta generar una predicción en la capa de salida.
- b. **Cálculo del Error:** El error entre las predicciones y los valores reales se calcula mediante una función de costo, como el MSE.
- c. **Backward Propagation:** El algoritmo de retropropagación ajusta los pesos usando el gradiente del error para minimizar la función de costo.
- d. **Actualización de Pesos:** Se actualizan los pesos y sesgos en la red utilizando un algoritmo de optimización como el descenso por gradiente.
- e. **Iteraciones:** El proceso se repite por varias épocas hasta que la red converja a una solución óptima.

2.2.3.4. Tipos de Redes Neuronales

De acuerdo con López y Fernández (2008) en su libro “Las redes neuronales artificiales”, existen diferentes tipos de redes neuronales artificiales (RNA), cada una diseñada para abordar problemas específicos. A continuación, se describen los tipos más comunes y sus aplicaciones:

- a. **Redes Neuronales Feedforward (FFNN):**
 - Estas son las redes neuronales más simples y básicas, donde la información fluye en una sola dirección: desde la capa de entrada, a través de las capas ocultas, hasta la capa de salida.
 - En las FFNN, no hay ciclos o conexiones de retroalimentación, lo que las hace ideales para problemas estáticos, como la clasificación y la regresión.

- Su principal ventaja es la simplicidad, lo que facilita su implementación y entrenamiento. Sin embargo, no son adecuadas para manejar datos secuenciales o temporales, donde el orden de las entradas importa.
- Son ampliamente utilizadas en tareas como reconocimiento de patrones y predicciones basadas en características estáticas.

b. Redes Neuronales Recurrentes (RNN):

- Las RNN están diseñadas específicamente para procesar datos secuenciales, como series temporales, texto o audio, ya que cuentan con conexiones que permiten la retroalimentación de la información entre las neuronas.
- A diferencia de las redes feedforward, las RNN tienen la capacidad de recordar información pasada, lo que les permite mantener un "estado" interno que puede influir en futuras predicciones.
- Esta estructura es ideal para tareas donde el orden y la dependencia temporal de los datos son cruciales, como la traducción automática, el reconocimiento de voz o la predicción de series temporales.
- Sin embargo, las RNN presentan desafíos como el desvanecimiento o explosión del gradiente, lo que puede dificultar el entrenamiento en secuencias largas. Las variantes más avanzadas, como las LSTM (Long Short-Term Memory) y GRU (Gated Recurrent Units), han sido desarrolladas para mitigar estos problemas y mejorar su rendimiento.

c. Redes Neuronales Convolucionales (CNN):

- Las CNN están especialmente diseñadas para el procesamiento y análisis de datos estructurados en dos o más dimensiones, como imágenes o señales visuales.
- Estas redes emplean filtros convolucionales que recorren los datos de entrada (por ejemplo, imágenes), permitiendo la detección de características locales como bordes, texturas y patrones.
- La arquitectura de una CNN incluye capas de convolución, submuestreo (pooling) y, al final, capas feedforward completamente conectadas. Esta estructura permite que las CNN sean extremadamente eficientes en la extracción de características visuales, lo que las ha convertido en la opción

principal para aplicaciones de visión por computadora, como la clasificación de imágenes, la detección de objetos y el reconocimiento facial.

- Además de imágenes, las CNN también han sido utilizadas para el procesamiento de señales, datos tridimensionales y videos, ampliando su rango de aplicación en diversas industrias.

d. Redes Neuronales Profundas (DNN):

- Las DNN son redes neuronales que contienen múltiples capas ocultas, lo que les permite aprender representaciones más complejas y abstractas de los datos.
- La profundidad de las DNN permite que estas redes capturen patrones más complejos en los datos, lo que las hace extremadamente poderosas para problemas donde las relaciones entre las variables no son evidentes a simple vista.
- Este tipo de redes es la base del aprendizaje profundo (Deep Learning) y ha revolucionado áreas como el procesamiento del lenguaje natural (NLP), el reconocimiento de voz, la generación de imágenes y los sistemas de recomendación.
- A pesar de su gran potencial, las DNN requieren grandes volúmenes de datos y una significativa capacidad computacional para entrenarse de manera efectiva. Sin embargo, con los avances en hardware y técnicas de optimización, las DNN han logrado resultados impresionantes en múltiples dominios, superando a muchos de los modelos tradicionales.

III. MÉTODO DE LA INVESTIGACIÓN

3.1. Tipo de investigación

El tipo de investigación es de tipo aplicada, ya que tiene como objetivo principal desarrollar un modelo predictivo basado en redes neuronales artificiales para abordar un problema específico relacionado con la oferta hídrica bajo los efectos del cambio climático. La investigación aplicada se enfoca en generar conocimientos que puedan ser utilizados para la toma de decisiones en la gestión de recursos hídricos de la cuenca del río Mantaro. Según Hernández, Fernández y Baptista (2014), la investigación aplicada busca resolver problemas concretos mediante la aplicación de teorías y técnicas en un contexto real.

3.2. Nivel de investigación

El nivel de la investigación es explicativo, dado que pretende analizar las causas que influyen en la oferta hídrica de la cuenca del río Mantaro, considerando variables como la precipitación, temperatura y evapotranspiración, y cómo estas impactan en el volumen de agua disponible. El enfoque explicativo, según Hernández et al. (2014), es utilizado cuando se busca comprender las relaciones de causa y efecto entre las variables, lo que en este caso permite explicar el impacto del cambio climático en los recursos hídricos.

3.3. Diseño de investigación

El diseño de la investigación es no experimental y transversal. No experimental porque no se manipulan las variables independientes, sino que se observa su comportamiento tal como se presentan en los datos históricos y actuales. Asimismo, es transversal, ya que los datos se recolectan en un solo punto en el tiempo para evaluar su relación con la oferta hídrica. De acuerdo con Hernández et al. (2014), un diseño no experimental es adecuado cuando el investigador no puede manipular deliberadamente las variables, y un diseño transversal se aplica cuando la recolección de datos se hace en un momento único. Además, se aplicará un enfoque predictivo, orientado a desarrollar un modelo capaz de prever la oferta hídrica futura bajo escenarios climáticos determinados.

3.4. Población y muestra

3.4.1. Población

La población del estudio comprende todos los datos climáticos e hidrológicos registrados en la cuenca del río Mantaro, incluyendo variables como precipitación, temperatura, evapotranspiración y caudales de los ríos. Estos datos han sido recopilados por las estaciones meteorológicas e hidrológicas que operan en la cuenca. De acuerdo con Hernández et al. (2014), la población representa el conjunto de elementos que comparten las características de interés para el investigador, en este caso, los datos que reflejan la oferta hídrica y las condiciones climáticas de la cuenca del río Mantaro.

3.4.2. Muestra

La muestra de este estudio está constituida por los datos hidrológicos y climáticos de la cuenca del río Mantaro, que abarcan el periodo comprendido desde 1965 – 2004, además para los datos faltantes se realizara una proyección de los años 2005-2024, por este la muestra en general abarca el periodo 1965-2024. Se seleccionarán aquellos registros más representativos y confiables para garantizar la precisión en el modelado de la oferta hídrica. El método de muestreo no probabilístico por conveniencia será utilizado, seleccionando los datos accesibles que cumplan con los requisitos de calidad necesarios para el análisis.

3.5. Hipótesis

3.5.1. Hipótesis general

El desarrollo de un modelo predictivo basado en redes neuronales artificiales permitirá estimar de manera precisa el impacto del cambio climático en la oferta hídrica de la cuenca del río Mantaro, mejorando la capacidad de anticipar variaciones en la disponibilidad de agua.

3.5.2. Hipótesis específicas

- a. La precipitación, la temperatura y la evapotranspiración tienen un impacto significativo en la oferta hídrica de la cuenca del río Mantaro, y su correcta evaluación contribuirá a la precisión del modelo predictivo.

- b. El uso de redes neuronales artificiales permitirá desarrollar un modelo predictivo eficiente que estime con exactitud el volumen de agua disponible bajo diferentes escenarios climáticos.
- c. El rendimiento del modelo predictivo basado en redes neuronales será validado mediante métricas de precisión, demostrando su capacidad para generar predicciones confiables y exactas sobre la oferta hídrica.

3.6. Operacionalización de variables

- a) **Variable Independiente:** Modelo predictivo del impacto del cambio climático
- b) **Variable Dependiente:** Oferta hídrica

Tabla 7

Cuadro de Operacionalización de variables

VARIABLES	DEFINICION CONCEPTUAL	DEFINICION OPERACIONAL	TIPO	NATURALEZA	DIMENSIÓN	INDICADORES	UNIDAD DE MEDIDA
Modelo predictivo del impacto del cambio climático	Es una herramienta matemática basada en algoritmos, como redes neuronales, que utiliza datos históricos y proyectados de variables climáticas para estimar cómo los cambios en el clima afectarán sistemas naturales o humanos.	Se utiliza mediante registros históricos y proyecciones de parámetros climáticos que incluyen la precipitación, la temperatura, la evapotranspiración, la incidencia de fenómenos climáticos extremos y el rendimiento del modelo predictivo.	Independiente	Cuantitativo	Precipitación	Variación anual y estacional de las lluvias	(mm/año)
					Temperatura	Temperatura media anual	(°C)
					Evapotranspiración	Tasa de evapotranspiración en la cuenca	(mm/día)
					Fenómenos climáticos extremos	Frecuencia de eventos climáticos	(eventos/año)
					Rendimiento del modelo predictivo	Precisión del modelo	(%)
Oferta hídrica	Es la cantidad de agua disponible en una región específica, proveniente de fuentes naturales como ríos, lagos, acuíferos y precipitaciones, que puede ser utilizada para satisfacer las demandas de consumo humano, agrícola, industrial y ambiental.	La oferta hídrica se evalúa considerando el volumen anual de agua en la cuenca y la variación mensual del caudal de los ríos.	Dependiente	Cuantitativo	Volumen de agua	Volumen anual de agua en la cuenca	(m³/año)
						Variación mensual del caudal de los ríos	(m³/s)

Nota. Elaboración propia

3.7. Técnicas e instrumentos

3.7.1. Técnicas

La técnica principal para la recolección de datos será el análisis documental y el procesamiento de datos climáticos e hidrológicos históricos. Se recopilarán datos de fuentes secundarias, como registros históricos proporcionados por estaciones meteorológicas e hidrológicas de la cuenca del río Mantaro, estudios previos, informes de organismos públicos y privados relacionados con la gestión de recursos hídricos y el cambio climático. El análisis documental permitirá acceder a información detallada sobre las variables climáticas (precipitación, temperatura, evapotranspiración) y la oferta hídrica.

3.7.2. Instrumentos

Los instrumentos empleados para la recolección de datos incluirán:

- a. Bases de datos hidrológicas y climáticas:** Los registros históricos de variables climáticas e hidrológicas, como precipitación, temperatura y caudales, serán obtenidos principalmente de la Autoridad Nacional del Agua (ANA). Estas bases de datos serán clave para alimentar el modelo predictivo de la oferta hídrica.
- b. Software especializado:** Se utilizarán herramientas como Python y Matlab, que son fundamentales para la implementación de redes neuronales artificiales y el análisis de datos. También se emplearán bibliotecas como TensorFlow y Keras para la construcción y entrenamiento de los modelos.
- c. Fichas de registro de datos:** Se utilizarán fichas de registro para organizar y estructurar los datos recolectados de las fuentes, garantizando una gestión eficiente de la información. Estas fichas permitirán tener un control detallado de las variables y su evolución a lo largo del tiempo.

3.8. Técnicas estadísticas para el procesamiento de la información

Para esta investigación, se emplearán diversas técnicas de procesamiento y análisis de datos que permitirán interpretar los datos climáticos e hidrológicos y desarrollar un modelo predictivo eficiente basado en redes neuronales artificiales.

a. Limpieza y preprocesamiento de datos:

Antes de aplicar cualquier técnica de análisis, se llevará a cabo una fase de limpieza y preprocesamiento de los datos. Este proceso incluirá la detección y corrección de valores atípicos, la imputación de datos faltantes, y la normalización o estandarización de las variables para que sean compatibles con las redes neuronales. Se aplicarán técnicas de análisis exploratorio de datos (EDA) para detectar tendencias, correlaciones y posibles anomalías en los datos.

a) Modelado predictivo con Redes Neuronales Artificiales (RNA):

- La técnica principal de análisis será la implementación de Redes Neuronales Artificiales para el desarrollo de un modelo predictivo. Este modelo será entrenado con los datos preprocesados para identificar relaciones no lineales entre las variables climáticas (precipitación, temperatura y evapotranspiración) y la oferta hídrica. El objetivo es construir un modelo capaz de predecir de manera precisa la disponibilidad de agua en la cuenca bajo distintos escenarios climáticos.
- El entrenamiento de las RNA implicará varias iteraciones utilizando algoritmos de optimización como el descenso por gradiente y el algoritmo de retropropagación para ajustar los pesos de la red. Se utilizarán herramientas como Python, TensorFlow y Keras para el desarrollo y entrenamiento de estas redes.

b. Validación del modelo:

- Una vez que el modelo esté entrenado, se procederá a su validación utilizando un conjunto de datos no utilizado en la fase de entrenamiento. Se evaluará la precisión del modelo y su capacidad predictiva mediante métricas como el error cuadrático medio (RMSE) y la precisión del modelo en varias ejecuciones de la red neuronal.
- Además, se aplicarán técnicas de validación cruzada para asegurar la robustez del modelo y evitar problemas de sobreajuste (overfitting). Estas técnicas permitirán validar la generalización del modelo en distintos escenarios climáticos.

c. Análisis estadístico:

- Se realizarán análisis estadísticos descriptivos para entender mejor la distribución y las características de los datos. Además, se emplearán técnicas de correlación para evaluar las relaciones entre las variables climáticas y la oferta hídrica. Esto permitirá un análisis más detallado de los factores que influyen en la disponibilidad de agua en la cuenca del río Mantaro.

d. Visualización de datos:

- Finalmente, se utilizarán técnicas de visualización de datos para representar gráficamente los resultados del análisis y del modelo predictivo. Estas visualizaciones facilitarán la interpretación de los patrones encontrados y la comprensión del comportamiento de las variables a lo largo del tiempo. Herramientas como Matplotlib y Seaborn serán utilizadas para generar gráficos y mapas que representen los resultados del estudio de manera clara y accesible.

La consistencia de los datos estadísticos se da por la fuente oficial de (ANA), identificando coincidencias, discrepancias y tendencias comunes. Asimismo, se aplicarán pruebas de homogeneidad y medidas de dispersión para garantizar que los registros empleados mantengan coherencia temporal y espacial, fortaleciendo la validez de los resultados del estudio.

3.9. Desarrollo de Trabajo de Tesis

3.9.1. Ubicación Geográfica

La cuenca del río Mantaro se ubica en la región central del Perú, extendiéndose principalmente sobre el departamento de Junín, aunque también abarca territorios de Huancavelica, Ayacucho, Pasco y una parte del norte de Apurímac. Forma parte de la vertiente del Atlántico, dado que sus aguas terminan fluyendo hacia el río Amazonas. Geográficamente, esta cuenca se sitúa entre los 10 y 13 grados de latitud sur, y entre los 73 y 76 grados de longitud oeste. Su territorio abarca zonas de alta montaña, con altitudes que superan los 5,000 metros sobre el

nivel del mar en las partes altas, y que descienden progresivamente hasta los 3,200 metros en las zonas intermedias.

Figura 4

Mapa de red hidrográfica



Nota. Imagen tomada de la página web de la Autoridad Nacional del Agua (ANA)

3.9.2. Climatología en la cuenca Mantaro

3.9.2.1. Temperatura

Según la Autoridad Nacional del Agua (ANA, 2022), el análisis de la temperatura del aire en la cuenca del río Mantaro se realizó usando datos históricos de 181 estaciones virtuales del CRU, que abarcan el periodo de 1960 a 1990.

Tabla 8

Temperatura Mínima en la Cuenca del Río Mantaro (°C)

Mes	<1000 msnm	1000– 2000 msnm	2000– 3000 msnm	3000– 4000 msnm	>4000 msnm
Ene	18.87	15.65	10.83	3.96	-1.12
Feb	19.16	15.98	11.12	4.11	-1.07
Mar	18.82	15.43	10.46	3.57	-1.47
Abr	18.05	14.77	9.67	2.55	-2.67
May	16.61	13.35	8.29	1.13	-4.17
Jun	14.98	11.5	6.22	-0.87	-6.13
Jul	14.45	11.17	6.08	-1.14	-6.56
Ago	15.1	12.1	7.33	-0.06	-5.66
Set	16.25	13.52	9.21	1.89	-3.71
Oct	16.72	13.85	9.53	2.55	-2.73
Nov	18.03	15.27	10.81	3.21	-2.54
Dic	18.15	15.15	10.5	3.35	-2.07

Nota. Información tomada del informe técnico de la ANA (2022).

Esta tabla muestra los promedios mensuales de la temperatura mínima del aire, agrupados por rangos de altitud en la cuenca del río Mantaro. A partir de los datos, se puede observar que:

- A menor altitud, las temperaturas mínimas son más altas. Por ejemplo, en zonas por debajo de los 1000 metros sobre el nivel del mar, los valores promedio están entre 14 °C y 19 °C a lo largo del año.
- En cambio, a mayor altitud, especialmente por encima de los 4000 msnm, las temperaturas mínimas bajan considerablemente, incluso por debajo de los 0 °C en varios meses del año.

- Los meses más fríos en toda la cuenca son junio y julio, donde se registran los valores más bajos de temperatura mínima, especialmente en las zonas más elevadas.
- Por otro lado, los meses con temperaturas mínimas más altas son enero, febrero y marzo, coincidiendo con la temporada de lluvias en la región andina.

El comportamiento de la temperatura máxima en la cuenca del río Mantaro se analiza en función de la altitud y la estacionalidad. Esta información resulta útil para entender las condiciones térmicas que caracterizan a las distintas zonas de la cuenca a lo largo del año.

Tabla 9

Temperatura máxima en la cuenca del río Mantaro (°C)

Mes	<1000 msnm	1000– 2000 msnm	2000– 3000 msnm	3000– 4000 msnm	>4000 msnm
Ene	28.57	26.02	21.86	15.72	10.94
Feb	28.84	26.28	22.1	15.75	10.87
Mar	28.98	26.37	22.25	16.05	11.33
Abr	28.87	26.77	23.03	16.81	12
May	27.79	26.13	23.15	17.27	12.61
Jun	27.1	25.77	23.25	17.64	13.15
Jul	26.83	25.63	23.1	17.39	12.66
Ago	27.54	26.37	23.25	17.63	12.68
Set	27.87	26.87	23.63	17.15	12.02
Oct	27.76	26.82	24.12	17.08	12.31
Nov	28.69	27.13	24.12	17.61	12.45
Dic	29.09	26.98	23.33	17.01	12.03

Nota. Información tomada del informe técnico de la ANA (2022).

La tabla 9 presenta los promedios mensuales de la temperatura máxima del aire en distintos rangos de altitud en la cuenca del río Mantaro. Se observa una clara disminución de la temperatura a medida que se incrementa la altitud, lo cual responde a la lógica del gradiente térmico altitudinal.

- En las zonas por debajo de los 1000 metros sobre el nivel del mar, las temperaturas máximas mensuales superan los 28 °C durante casi todo el año, alcanzando su punto más alto en diciembre (29.09 °C).

- Entre los 1000 y 2000 msnm, las temperaturas máximas varían entre 25.6 °C y 27.1 °C, con ligeras variaciones estacionales.
- En zonas ubicadas entre los 2000 y 3000 msnm, los valores se reducen, promediando entre 21.8 °C y 24.1 °C, con un ligero incremento entre abril y noviembre.
- Para elevaciones entre 3000 y 4000 msnm, las temperaturas máximas oscilan alrededor de los 15 °C a 17.6 °C, manteniéndose relativamente constantes durante el año.
- Finalmente, en altitudes mayores a los 4000 msnm, las temperaturas máximas promedio se mantienen entre 10.8 °C y 13.1 °C, siendo julio y agosto los meses más cálidos en esta franja.

Se presenta la temperatura media mensual en distintos rangos de altitud dentro de la cuenca del río Mantaro, complementando así los valores ya analizados de temperatura mínima y máxima.

Tabla 10

Temperatura media en la cuenca del río Mantaro (°C)

Mes	<1000 msnm	1000– 2000 msnm	2000– 3000 msnm	3000– 4000 msnm	>4000 msnm
Ene	23.72	20.83	16.34	9.84	4.91
Feb	24	21.13	16.61	9.93	4.9
Mar	23.9	20.9	16.36	9.81	4.93
Abr	23.46	20.77	16.35	9.68	4.66
May	22.2	19.77	15.73	9.2	4.22
Jun	21.04	18.74	14.74	8.38	3.51
Jul	20.64	18.4	14.66	8.13	3.05
Ago	21.32	19.23	15.59	8.94	3.51
Set	22.06	19.97	16.41	9.52	4.16
Oct	22.24	19.97	16.33	9.81	4.79
Nov	23.36	21.2	17.46	10.41	4.96
Dic	23.62	21.07	16.91	10.18	4.98

Nota. Información tomada del informe técnico de la ANA (2022).

La tabla 10 presenta los promedios mensuales de la temperatura media del aire en distintos rangos de altitud dentro de la cuenca del río Mantaro. Se confirma nuevamente que la altitud influye significativamente en los valores térmicos,

observándose una disminución progresiva de la temperatura media conforme se incrementa la altitud.

- En las zonas por debajo de los 1000 metros sobre el nivel del mar, las temperaturas medias se mantienen elevadas a lo largo del año, oscilando entre 20.64 °C (julio) y 24.00 °C (febrero).
- Entre los 1000 y 2000 msnm, los valores de temperatura media varían entre 18.40 °C (julio) y 21.20 °C (noviembre), con un patrón ligeramente más variable en los meses intermedios.
- En las zonas comprendidas entre los 2000 y 3000 msnm, las temperaturas medias anuales fluctúan entre 14.66 °C (julio) y 17.46 °C (noviembre). Esta franja presenta una disminución térmica más notoria durante el periodo seco (junio–agosto).
- Para elevaciones entre 3000 y 4000 msnm, los promedios se reducen considerablemente, ubicándose entre 8.13 °C (julio) y 10.41 °C (noviembre). El comportamiento anual sigue un patrón marcado de enfriamiento a mitad de año.
- Finalmente, en zonas ubicadas por encima de los 4000 msnm, la temperatura media se mantiene por debajo de los 5 °C durante todo el año, con los valores más bajos en julio (3.05 °C) y los más altos en diciembre (4.98 °C), lo cual refleja las condiciones frías propias de la alta montaña andina.

3.9.2.2. Velocidad media del viento

En el Valle del Mantaro, la velocidad media anual del viento es de aproximadamente 1,2 m/s, con una mayor intensidad durante el mes de agosto. En otras localidades dentro de la cuenca, como Huancayo, se han registrado velocidades medias mensuales que oscilan entre 1,70 y 2,92 m/s, dependiendo de la estación del año y las condiciones locales.

3.9.2.3. Humedad Relativa

En la cuenca del río Mantaro, la humedad relativa media anual presenta valores que oscilan entre un máximo de 80.12 % en enero y un mínimo de 53.63 % en julio. La variación mensual de este parámetro en función de la altitud se encuentra detallada en la tabla 11, la cual abarca un rango de elevaciones que va desde los 553 hasta los 4985 metros sobre el nivel del mar.

Tabla 11*Humedad relativa de la cuenca del Mantaro (%)*

Elevación (msnm)	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Set	Oct	Nov	Dic
553 – 1000	71.56	73.42	73.66	71.8	69.66	69.94	68.78	67.8	67.7	69.22	67.8	69.96
1000 – 1500	71.3	73.4	73.8	71.4	68.6	68.3	67.3	66.5	66.8	68.5	66.9	69.3
1500 – 2000	67.45	70.15	71.2	67.2	63.05	61.45	60.4	60.3	61.1	62.5	60.6	64.2
2000 – 2500	65.33	68.13	69.77	64.47	59.57	56.87	55.73	56.4	57.63	58.57	56.63	61.07
2500 – 3000	67.56	69.95	71.76	66.14	60.57	57.03	55.8	57	58.92	60.75	58.8	63.21
3000 – 3500	68.86	69.63	72.5	65.7	58.3	55.35	53.63	56.6	59.13	60.01	58.77	63.64
3500 – 4000	73.14	72.32	75.17	68.33	62.91	57.05	54.46	58.3	62.2	63.57	63.29	67.78
4000 – 4500	76.42	73.5	77.35	69.78	64.98	58.16	55.14	60.9	66	66	66.47	70.91
4500 – 4985	80.12	74.02	79.7	70.7	67.32	59.16	55.6	64.2	68.12	67.59	69.29	74.06

Nota. Información tomada del informe técnico de la ANA (2022).

La tabla 11 muestra que la humedad relativa también se encuentra influenciada por la altitud, aunque de manera menos lineal que la temperatura. Se identifican algunos patrones generales en función de la altitud:

- En zonas bajas (553 a 1500 msnm), los valores se mantienen relativamente altos durante todo el año, con promedios mensuales que oscilan entre 66.5 % y 73.8 %, siendo los más elevados en el trimestre enero-marzo.
- Entre 1500 y 3000 msnm, la humedad relativa presenta una disminución más marcada durante los meses de junio y julio, alcanzando valores mínimos cercanos a 55 %, especialmente en altitudes medias (2000–2500 msnm).
- En el rango de 3000 a 3500 msnm, los valores también descienden en la temporada seca, con un punto bajo de 53.63 % en julio, y una recuperación progresiva desde agosto.
- A partir de los 3500 msnm, se observa una tendencia al incremento de la humedad relativa, especialmente en las altitudes más elevadas. Por ejemplo, en el rango de 4500 a 4985 msnm, se alcanzan los valores más altos del año con 80.12 % en enero y 74.06 % en diciembre.
- En general, los meses con menor humedad relativa en toda la cuenca coinciden con el periodo seco (junio, julio y agosto), mientras que los valores más altos se presentan en la temporada de lluvias (enero a marzo).

3.9.2.4. Precipitación

En la cuenca del río Mantaro, las lluvias comienzan de forma generalizada en el mes de julio, con un aumento progresivo durante agosto y setiembre. A partir de octubre, las precipitaciones se intensifican considerablemente, alcanzando su punto máximo en el mes de febrero.

Se presenta la precipitación media mensual en diferentes rangos altitudinales de la cuenca del río Mantaro. Estos datos permiten identificar cómo se distribuyen las lluvias a lo largo del año y cómo varía su intensidad según la altitud, lo cual resulta clave para comprender la dinámica hídrica de la cuenca (Ver tabla 12).

Tabla 12*Precipitación media mensual de la cuenca del Mantaro (mm/mes)*

Elevación (msnm)	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Set	Oct	Nov	Dic
553 – 1000	180.6	163	154	97.18	56.92	39.38	38.9	50.9	81.04	111.8	116.2	155
1000 – 1500	195.1	171.9	170	106.8	67.3	44.4	42.9	55.9	91.3	119.8	121.2	165.2
1500 – 2000	138.2	123.2	123	66.4	35.1	19.15	23.45	29.6	57	73.55	77.3	112.4
2000 – 2500	124.9	118.2	111.6	51.13	26.3	12.57	16.57	20.9	44.27	59.6	64	94.13
2500 – 3000	131	128	125.6	57	29.84	14.33	20.66	24.8	52.85	66.21	71.31	104
3000 – 3500	127.1	135.9	132	49.25	22.95	9.8	18.22	22.8	43.36	60.09	64.89	90.89
3500 – 4000	131.7	145.8	140.2	62.82	27.72	10.71	21.33	23.7	45.65	69.65	73.97	104.8
4000 – 4500	132.8	147.7	150.5	65.83	28.51	11.96	19.62	19.6	43.74	68.31	72.41	107.8
4500 – 4985	144.5	153.7	143.9	71.09	32.73	7.25	9.16	15.2	39.78	63.5	71.01	110

Nota. Información tomada del informe técnico de la ANA (2022).

La tabla 12 muestra que la precipitación en la cuenca del Mantaro sigue un patrón estacional bien definido, con máximos durante el verano y mínimos durante el invierno, aunque su intensidad varía según la altitud:

- En las zonas más bajas (553 a 1500 msnm), la precipitación es más abundante, con promedios mensuales que superan los 150 mm en los meses de enero, febrero y diciembre. Julio y junio son los meses más secos, con valores por debajo de 45 mm.
- Entre los 1500 y 3000 msnm, los valores de precipitación disminuyen, especialmente en los meses secos (junio a agosto), con registros que llegan hasta los 9 a 20 mm en algunas zonas. En contraste, enero y febrero mantienen promedios de entre 120 y 130 mm.
- En el rango de 3000 a 4000 msnm, se observa una recuperación de las precipitaciones, especialmente en febrero y marzo, donde se superan los 135 mm. Sin embargo, en junio y julio los valores son bajos, entre 10 y 21 mm, lo que evidencia la marcada estacionalidad de lluvias.
- En las altitudes más altas (4000 a 4985 msnm), las precipitaciones máximas se registran también en enero, febrero y marzo, con valores que alcanzan los 153.65 mm. Los meses más secos son junio, julio y agosto, con precipitaciones por debajo de 20 mm, y en algunos casos incluso por debajo de 10 mm.

La climatología de la cuenca del río Mantaro está fuertemente influenciada por la altitud. Los datos de la ANA se muestran en la tabla a continuación:

Tabla 13

Resumen Numérico de la Climatología en la Cuenca del Río Mantaro

Altitud (msnm)	Temp. mínima (°C)	Temp. máxima (°C)	Temp. media (°C)	Velocidad del viento (m/s)	Humedad relativa (%)	Precipitación (mm/mes)
<1000	14.45 (jul) – 19.16 (feb)	26.83 (jul) – 29.09 (dic)	20.64 (jul) – 24.00 (feb)	Promedio valle: 1.2	71.56 (ene) – 68.78 (jul)	38.9 (jul) – 180.6 (ene)
1000–2000	11.17 (jul) – 15.98 (feb)	25.63 (jul) – 27.13 (nov)	18.40 (jul) – 21.20 (nov)	–	73.8 (mar) – 66.5 (ago)	42.9 (jul) – 195.1 (ene)

2000–3000	6.08 (jul) – 11.12 (feb)	21.86 (ene) – 24.12 (oct–nov)	14.66 (jul) – 17.46 (nov)	Huancayo: 1.70 – 2.92	71.2 (mar) – 60.4 (jul)	19.15 (jun) – 138.2 (ene)
3000–4000	-1.14 (jul) – 4.11 (feb)	15.72 (ene) – 17.64 (jun–ago)	8.13 (jul) – 10.41 (nov)	–	72.5 (mar) – 53.63 (jul)	9.8 (jun) – 124.9 (ene)
>4000	-6.56 (jul) – -1.07 (feb)	10.87 (feb) – 13.15 (jun)	3.05 (jul) – 4.98 (dic)	–	80.12 (ene) – 55.6 (jul)	7.25 (jun) – 144.5 (ene)

Nota. Elaboración Propia

Observaciones generales:

- **Temperatura mínima:** se registra en junio–julio; máxima: entre enero y marzo.
- **Temperatura máxima:** valores más bajos en julio y más altos en diciembre–febrero.
- **Temperatura media:** mínima en junio–julio; máxima en noviembre–febrero.
- **Velocidad del viento:** mayor en agosto.
- **Humedad relativa:** mínima en junio–julio; máxima en enero–marzo.
- **Precipitación:** mínima en junio–julio; máxima en enero–febrero.

En general, se confirma que las lluvias se intensifican progresivamente desde julio, se consolidan desde octubre, y alcanzan su punto máximo en febrero, con un retroceso gradual desde marzo hasta junio. Esta estacionalidad influye directamente en la disponibilidad hídrica superficial y en la planificación de actividades agrícolas y de gestión del agua en toda la cuenca.

3.9.3. Evapotranspiración

Para calcular la evapotranspiración potencial (ETP) en la cuenca del río Mantaro se emplea el método empírico de Thornthwaite, dado que se dispone de los datos de temperatura media mensual, los cuales son fundamentales para aplicar esta fórmula. A continuación, se realiza el cálculo paso a paso:

De la tabla 10 se extraen los siguientes valores mensuales de temperatura media para la altitud de 2000–3000 msnm:

Tabla 14

Valores mensuales de temperatura media para la altitud de 2000–3000 msnm

Mes	Temp. media (°C)
Enero	16.34
Febrero	16.61
Marzo	16.36
Abril	16.35
Mayo	15.73
Junio	14.74
Julio	14.66
Agosto	15.59
Setiembre	16.41
Octubre	16.33
Noviembre	17.46
Diciembre	16.91

Nota. Elaboración Propia

Aplicando el siguiente código calculamos la evapotranspiración:

```
import numpy as np
import pandas as pd

# Temperaturas medias mensuales extraídas del documento para el
rango 2000–3000 msnm
temps = {
    "Enero": 16.34,
    "Febrero": 16.61,
    "Marzo": 16.36,
    "Abril": 16.35,
    "Mayo": 15.73,
    "Junio": 14.74,
    "Julio": 14.66,
    "Agosto": 15.59,
    "Setiembre": 16.41,
    "Octubre": 16.33,
    "Noviembre": 17.46,
    "Diciembre": 16.91
}

# Paso 1: Calcular I
I_components = [(t / 5) ** 1.514 for t in temps.values()]
I = sum(I_components)
```

```

# Paso 2: Calcular el coeficiente a
a = (6.75e-7) * (I**3) - (7.71e-5) * (I**2) + (1.792e-2) * I +
0.49239

# Paso 3: Calcular ETP mensual
etp = {month: 16 * ((10 * t / I) ** a) for month, t in
temps.items()}

# Paso 4: Calcular el total anual
total_etp = sum(etp.values())

# Crear DataFrame para mostrar
df_etp = pd.DataFrame({
    "Mes": list(etp.keys()),
    "Temp. Media (°C)": list(temps.values()),
    "ETP (mm/mes)": list(etp.values())
})

df_etp.loc["Total anual"] = ["-", "-", total_etp]


print(df_etp.to_string(index=False))

```

La tabla 15 muestra los valores mensuales de evapotranspiración potencial (ETP) estimados para la cuenca del río Mantaro, en el rango altitudinal de 2000 a 3000 msnm, utilizando el método de Thornthwaite. Este método es adecuado en contextos donde se dispone principalmente de datos de temperatura, y permite obtener una aproximación confiable del comportamiento de la pérdida de agua por evaporación y transpiración en condiciones estándar.

Tabla 15

ETP mensual calculado

	Mes	Temp. Media (°C)	ETP (mm/mes)
	Enero	16.34	61.768899
	Febrero	16.61	63.423147
	Marzo	16.36	61.890866
	Abril	16.35	61.829871
	Mayo	15.73	58.093034
	Junio	14.74	52.311587
	Julio	14.66	51.854500
	Agosto	15.59	57.261524
	Setiembre	16.41	62.196182
	Octubre	16.33	61.707950
	Noviembre	17.46	68.738590
	Diciembre	16.91	65.280614
	-	-	726.356764

Nota. Elaboración Propia

La ETP mensual varía de acuerdo con la temperatura media de cada mes. Se observa que:

- Los valores más bajos de ETP corresponden a los meses de junio (52.31 mm) y julio (51.85 mm), lo cual coincide con la temporada más fría del año en la región andina.
- Los valores más altos se presentan en noviembre (68.74 mm) y diciembre (65.28 mm), en concordancia con el incremento de temperatura hacia el final del año.
- El valor total anual de evapotranspiración estimada es de 726.36 mm/año, lo que representa una pérdida significativa de agua hacia la atmósfera, relevante para los estudios de balance hídrico y planificación agrícola.

3.9.4. Análisis Hidrológico

3.9.4.1. Caudales en el río Mantaro

Según el informe técnico elaborado por la Autoridad Nacional del Agua (2022), se indica que la red hidrometeorológica de esta cuenca está compuesta por 171 estaciones meteorológicas y pluviométricas, así como 42 estaciones hidrológicas. Los registros disponibles del río Mantaro se remontan a 1939, cuando se instaló la primera estación hidrométrica en Malpaso. Posteriormente, en los años 50, se implementaron otras estaciones importantes como la de Upamayo ubicada a la salida del lago Junín y La Mejorada, ambas situadas sobre el curso del río Mantaro.

A continuación, se presentan las estaciones hidrométricas administradas por Electroperú, incluyendo sus coordenadas, altitud, área de influencia, caudal medio anual registrado y el periodo de medición comprendido entre 1965 y 2005:

Tabla 16*Estaciones hidrométricas y caudal medio anual del río Mantaro*

Código	Estación	Latitud	Longitud	Altitud (msnm)	Área (km²)	Caudal medio anual (m³/s)	Periodo
C201	Upamayo	10°55'	76°16'	4080	2860	21.83	1965–2005
C257	Puente Chulec	11°30'	75°55'	3710	6020	55.63	1965–2005
C268	Cochas Túnel	11°51'	75°44'	3950	4090	5.97	1965–2005
C269	Piñascocha	11°48'	75°43'	3910	3580	1.83	1965–2005
C270	Pachacayo	11°48'	75°43'	3810	3580	9.3	1965–2005
C254	Puente Stuart	11°41'	75°29'	3690	3460	12.43	1965–2005
C261	Quillón	12°23'	75°08'	3450	6490	55.89	1965–2005
C262	Moya	12°24'	75°10'	3250	8820	73.02	1965–2005
C274	Chinchi	12°37'	75°54'	3000	16370	110.7	1965–2005
C213	La Mejorada	12°31'	75°29'	2790	18775	170.9	1965–2005

Nota. Elaboración Propia

3.9.4.2. Descarga Medias Mensuales (m³/s)

Tabla 17

Precipitación mensual por año (mm/mes)

Año	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Promedio
1965	50.44	154.63	194.16	73.53	40.95	21.53	20.48	17.24	26.19	26.72	23.81	47.77	58.12
1966	123.08	86.3	126.74	49.75	37.6	20.98	13.99	16.14	19.11	41.74	62.84	125.04	60.28
1967	101.36	346.45	328.22	113.62	54.46	37.05	33.36	23.63	26.79	57.43	37.63	70.56	102.55
1968	92.93	118.3	209.44	79.85	41.83	32.64	37.45	34.22	29.32	38.67	69.43	54.85	69.91
1969	44.36	110.65	119.46	136.77	38.39	28.84	18.58	23.03	19.4	30.17	27.78	97.81	57.94
1970	284.3	198.96	153.23	133.38	89.88	42.79	26.16	30.44	42.16	36.72	33.27	81.36	96.05
1971	143.99	213.73	210.72	136.63	47.63	34.14	32.25	30.96	31.25	43.44	37.24	61.13	85.26
1972	151.47	108.91	285.36	198.55	88.06	42	32.65	27.5	30.95	36.76	35.6	71.4	92.43
1973	191.67	313.66	430.73	287.29	79.93	53.44	36.77	31.82	50.96	66.97	89.88	99.13	144.35
1974	262.02	394.56	416.95	185.57	68.88	36.03	53.27	41.82	43.12	42.96	48.43	54.9	137.38
1975	102.08	138.18	329.58	108.82	102.49	57.19	37.5	27.97	38.26	49.29	41.99	50.59	90.33
1976	174.2	303.45	272.84	131.41	64.49	51.12	38.12	36.4	44.53	52.35	46.46	40.24	104.63
1977	61.36	135.8	192.05	102.46	55.02	37.6	26.71	21.36	26.57	37.58	92.33	99.87	74.06
1978	117.76	358.1	200.75	93.35	52.38	38.91	33.82	28.94	44.09	34.52	51.16	66.36	93.35
1979	61.17	149.24	375.71	204.82	68.49	41.05	36.93	32.03	34.19	33.87	40.96	39.79	93.71
1980	65.18	79.97	131.2	89.08	35.89	26.53	22.76	21.59	24.12	38.42	62.94	77.87	56.3
1981	79.76	284.95	300.17	94.06	35.44	46.37	36.49	42.6	35.24	33.19	75.02	126.92	99.18
1982	222.3	313.45	182.64	132.47	57.74	55.35	35.69	31.55	31.61	53.17	102.78	112.33	110.92
1983	152.02	70.42	138.87	107.8	52	40.27	28.44	42.04	25.5	27.07	24.69	49.98	63.26
1984	62.43	279.8	277.4	170.39	74.88	52.58	35.84	32.3	39.27	37.54	41.52	86.92	99.24

1985	98.67	143.44	185.49	178.61	85.5	67.97	37.94	27.23	49.06	56.43	47.66	61.4	86.62
1986	142.38	279.71	345.37	266.17	175.97	66.77	57.49	50.24	59.09	49.62	49.85	60.93	133.63
1987	190.6	181.24	132.16	64	41.74	31.03	28.73	28.22	34.15	31.64	44.18	84.4	74.34
1988	198	243.28	176.37	204.12	73.77	51.07	38.17	35.26	28.71	34.71	32.47	55.79	97.64
1989	163.87	230.06	178.9	184.2	88.92	55.35	37.62	40.36	36.4	48.7	59.29	60.34	98.67
1990	108	119.73	108.22	65.72	43.89	45.93	32.43	29.38	31.17	52.02	108.94	91.88	69.78
1991	95.73	91.1	218.45	101.64	72.34	43.6	38.19	40.48	46.58	36.13	37.19	33.39	71.24
1992	47.6	30.39	77.27	38.1	19.34	18.35	12.62	15.68	18.48	20.66	16.65	17.66	27.73
1993	45.55	158.64	156.46	112.16	92.82	41.98	29.61	24.35	24.53	48.76	124.72	177.36	86.41
1994	183.84	281.47	238.8	238.22	104.87	67.08	49.24	37.87	44.16	40.81	49.35	62.31	116.5
1995	69.02	71.01	157.95	109.83	38.04	25.09	29.14	24.85	30.26	40.92	38.92	36.25	55.94
1996	65.7	106.87	112.11	128.83	52.07	31.47	30.85	26.95	28.63	31.42	43.15	41.42	58.29
1997	76.84	183.97	131.43	60.85	30.89	25.08	19.88	22.03	23.23	20.95	36.57	68.59	58.36
1998	120.24	219.45	169.72	128.81	55.01	35.35	33.92	34.11	35.59	55.28	51.32	38.27	81.42
1999	66.12	250.36	208.52	151.36	81.87	47.53	36.63	29.33	29.88	36.66	26.43	63.04	85.64
2000	175.98	273.88	279.49	174.29	88.73	48.86	37.46	36.36	33.87	51.58	34.91	75.67	109.26
2001	233.92	227.54	300.75	134.06	55.44	40.66	29.72	22.96	27.9	26.32	53.62	79.5	102.7
2002	50.37	107.09	182.53	119.65	51.92	38.36	28.68	21.39	32.48	41.11	90.81	128.66	74.42
2003	117.29	174.78	253.65	142.34	65.69	48.45	46.42	45.89	39.52	44.41	55.76	79.34	92.8
2004	66.15	114.08	81.03	55.36	42.42	42.77	43.19	34.5	40.82	56.9	46.95	89.46	59.47
PROMEDIO	121.49	191.19	214.27	132.2	63.69	41.73	33.38	30.68	33.93	41.09	52.36	73.01	85.75
MÁXIMO	284.3	394.56	430.73	287.29	175.97	67.97	57.49	50.24	59.09	66.97	124.72	177.36	144.35
MÍNIMO	44.36	30.39	77.27	38.1	19.34	18.35	12.62	15.68	18.48	20.66	16.65	17.66	27.73

Nota. Elaboración Propia

Utilizando el siguiente código se realiza la predicción para los años 2005-2024:

```
import pandas as pd
import numpy as np
from sklearn.linear_model import LinearRegression
import matplotlib.pyplot as plt

# Datos históricos de precipitación promedio anual (1965-2004)
promedios_anuales = [
    58.12, 60.28, 102.55, 69.91, 57.94, 96.05, 85.26, 92.43,
    144.35, 137.38,
    90.33, 104.63, 74.06, 93.35, 93.71, 56.30, 99.18, 110.92,
    63.26, 99.24,
    86.62, 133.63, 74.34, 97.64, 98.67, 69.78, 71.24, 27.73,
    86.41, 116.50,
    55.94, 58.29, 58.36, 81.42, 85.64, 109.26, 102.70, 74.42,
    92.80, 59.47
]

# Crear DataFrame con años y precipitaciones
years = np.arange(1965, 2005)
df = pd.DataFrame({
    "Año": years,
    "Precipitación_promedio": promedios_anuales
})

# Entrenamiento del modelo de regresión lineal
X = df["Año"].values.reshape(-1, 1)
y = df["Precipitación_promedio"].values
model = LinearRegression()
model.fit(X, y)

# Años a predecir: 2005-2024
future_years = np.arange(2005, 2025).reshape(-1, 1)

# Tendencia base predicha
trend = model.predict(future_years)

np.random.seed(42)
seasonality = 10 * np.sin(np.linspace(0, 4 * np.pi,
len(future_years))) # patrón cíclico
noise = np.random.normal(0, 5, len(future_years)) # ruido
aleatorio realista

# Predicción final realista
realistic_predictions = trend + seasonality + noise


# Tabla final con predicciones
df_realistic = pd.DataFrame({
    "Año": future_years.flatten(),
    "Precipitación_predicha_realista": realistic_predictions
})
```

```
print(df_realistic.to_string(index=False))
```

La tabla 18 muestra los valores estimados de precipitación promedio anual para la cuenca del río Mantaro durante el periodo 2005–2024. Estas predicciones fueron generadas mediante un modelo de regresión lineal ajustado a los datos históricos registrados entre 1965 y 2004, al cual se le incorporaron variaciones estacionales y ruido aleatorio con el objetivo de obtener un comportamiento más realista y representativo de las fluctuaciones climáticas interanuales.

Tabla 18

Precipitación predicha periodo 2005 - 2024

 Año	Precipitación_predicha_realista
2005	83.092878
2006	85.809214
2007	93.039954
2008	96.629491
2009	83.194416
2010	76.538179
2011	79.642735
2012	72.724339
2013	67.883074
2014	77.817017
2015	79.030218
2016	83.892428
2017	88.774168
2018	75.138450
2019	70.118070
2020	69.274902
2021	62.373025
2022	68.221248
2023	65.410867
2024	68.780696

Nota. Elaboración Propia

- Los valores predichos muestran una tendencia general oscilante, en línea con las condiciones climatológicas observadas en décadas previas, pero sin asumir una linealidad perfecta.

- Se introdujeron componentes estacionales, que simulan los ciclos de años húmedos y secos, y un componente aleatorio, para reflejar las alteraciones impredecibles propias del clima.
- Se observa que la precipitación predicha más alta ocurre en 2008 (96.63 mm) y la más baja en 2021 (62.37 mm), lo cual refleja adecuadamente la variabilidad esperada en periodos de dos décadas.
- En promedio, los valores se mantienen dentro de un rango razonable respecto a la media histórica (85.75 mm para 1965–2004), lo cual indica que el modelo conserva la coherencia estadística.

V. RESULTADOS Y DISCUSIÓN

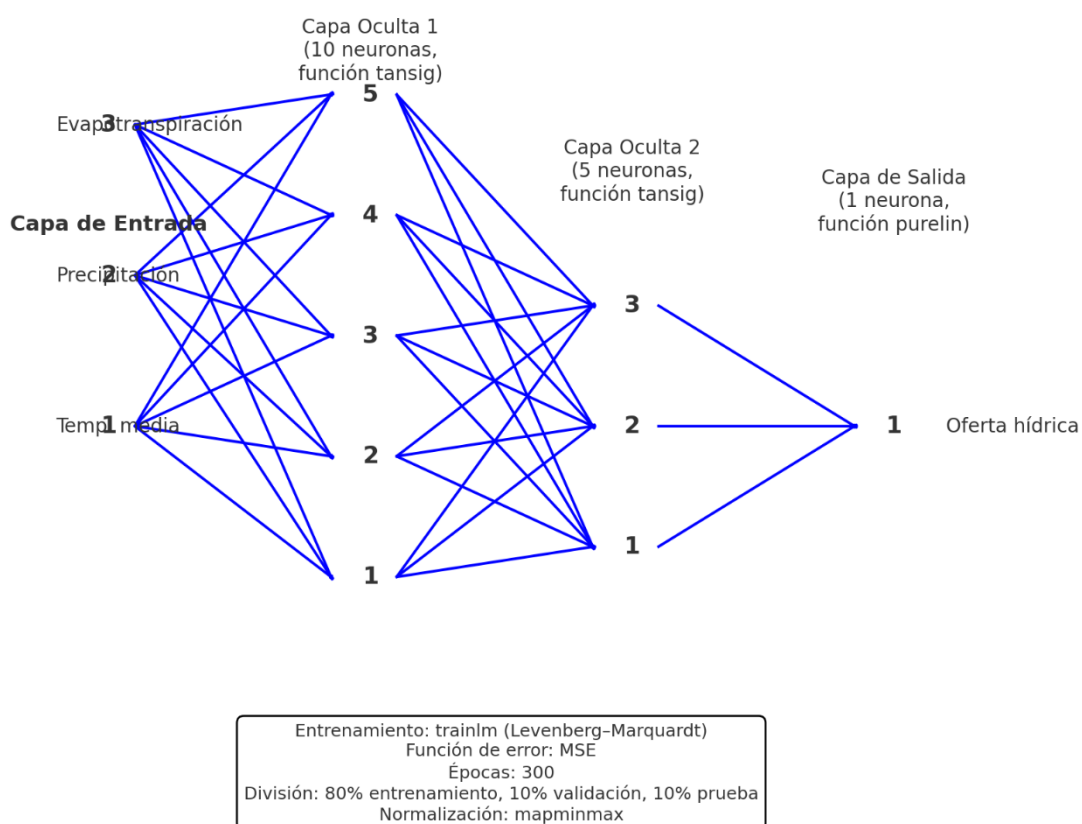
4.1. Modelo predictivo con redes neuronales

En este apartado se presenta el desarrollo de un modelo predictivo basado en redes neuronales artificiales, con el propósito de estimar la oferta hídrica mensual en la cuenca del río Mantaro. El enfoque se sustenta en la utilización de variables climáticas relevantes como la temperatura media, la precipitación y la evapotranspiración, tanto en condiciones actuales como bajo un escenario climático proyectado al año 2050.

Para ello, se entrenó una red neuronal multicapa que permite modelar la relación no lineal entre dichas variables y la oferta hídrica, considerando las variaciones que podrían producirse como consecuencia del cambio climático.

Figura 5

Estructura del modelo neuronal predictivo para la estimación de la oferta hídrica



Nota. Elaboración Propia

La red de la Figura 5 está formada por una capa de entrada con tres variables climáticas (temperatura media, precipitación y evapotranspiración), dos capas ocultas intermedias que permiten modelar la relación no lineal entre las variables, y una capa de salida que estima la oferta hídrica mensual. El modelo fue configurado con dos capas ocultas de 10 y 5 neuronas respectivamente, empleando la función de activación tansig. La capa de salida está compuesta por una neurona con función purelin. El entrenamiento se realizó con el algoritmo trainlm (Levenberg-Marquardt), durante 300 épocas, utilizando el error cuadrático medio (MSE) como métrica principal. Los datos fueron normalizados mediante mapminmax y se aplicó una división del 80% para entrenamiento, 10% para validación y 10% para prueba.

El modelo fue implementado en MATLAB, utilizando una estructura compuesta por capas ocultas que facilitan la aproximación de la función objetivo. Se incluyen además los resultados obtenidos en diferentes escenarios, con énfasis en el análisis de los cambios estacionales y su posible impacto en la disponibilidad de recursos hídricos.

```
% Modelo Predictivo con Redes Neuronales - Basado en datos reales de la cuenca del Mantaro
% Datos (temperatura, precipitación, evapotranspiración)

% Variables de entrada para el modelo (valores medios mensuales)
temp_media = [16.34 16.61 16.36 16.35 15.73 14.74 14.66 15.59 16.41
16.33 17.46 16.91];
precipitacion = [131 128 125.6 57 29.84 14.33 20.66 24.8 52.85 66.21
71.31 104]; % Rango 2500-3000 msnm
evapotranspiracion = [61.77 63.42 61.89 61.83 58.09 52.31 51.85
57.26 62.20 61.71 68.74 65.28]; % ETP mensual Thornthwaite

% Oferta hídrica estimada (prec - etp como proxy simplificado de escorrentía)
oferta_hidrica = precipitacion - evapotranspiracion;

% Matriz de entradas y salidas
inputs = [temp_media; precipitacion; evapotranspiracion];
targets = oferta_hidrica;

% Normalización
[inputs_norm, input_settings] = mapminmax(inputs);
[targets_norm, target_settings] = mapminmax(targets);

% Crear red neuronal
net = fitnet([10 5], 'trainlm');
net.trainParam.epochs = 300;
net.divideParam.trainRatio = 0.8;
net.divideParam.valRatio = 0.1;
```

```

net.divideParam.testRatio = 0.1;

% Entrenamiento
[net, tr] = train(net, inputs_norm, targets_norm);

% Predicción
outputs_norm = net(inputs_norm);
outputs = mapminmax('reverse', outputs_norm, target_settings);

% Métrica de error
rmse = sqrt(mean((targets - outputs).^2));
fprintf('Error cuadrático medio (RMSE): %.4f\n', rmse);

% Porcentaje de precisión del modelo
error_absoluto = abs(targets - outputs);
porcentaje_prediccion = 100 - mean(error_absoluto ./ targets * 100);
fprintf('Precisión del modelo: %.2f%%\n', porcentaje_prediccion);

% Gráfica de comparación
figure;
plot(1:12, targets, 'b-o', 'LineWidth', 1.5); hold on;
plot(1:12, outputs, 'r--s', 'LineWidth', 1.5);
legend('Observado', 'Predicho');
xlabel('Mes');
ylabel('Oferta hídrica estimada (mm)');
title('Estimación de Oferta Hídrica con Red Neuronal - Cuenca Mantaro');
grid on;

% Visualizar arquitectura de la red
figure;
view(net);
title('Arquitectura de la Red Neuronal - Capas y Neuronas');

```

A continuación, se muestran los resultados de oferta hídrica calculada a partir de los datos de precipitación y evapotranspiración.

```

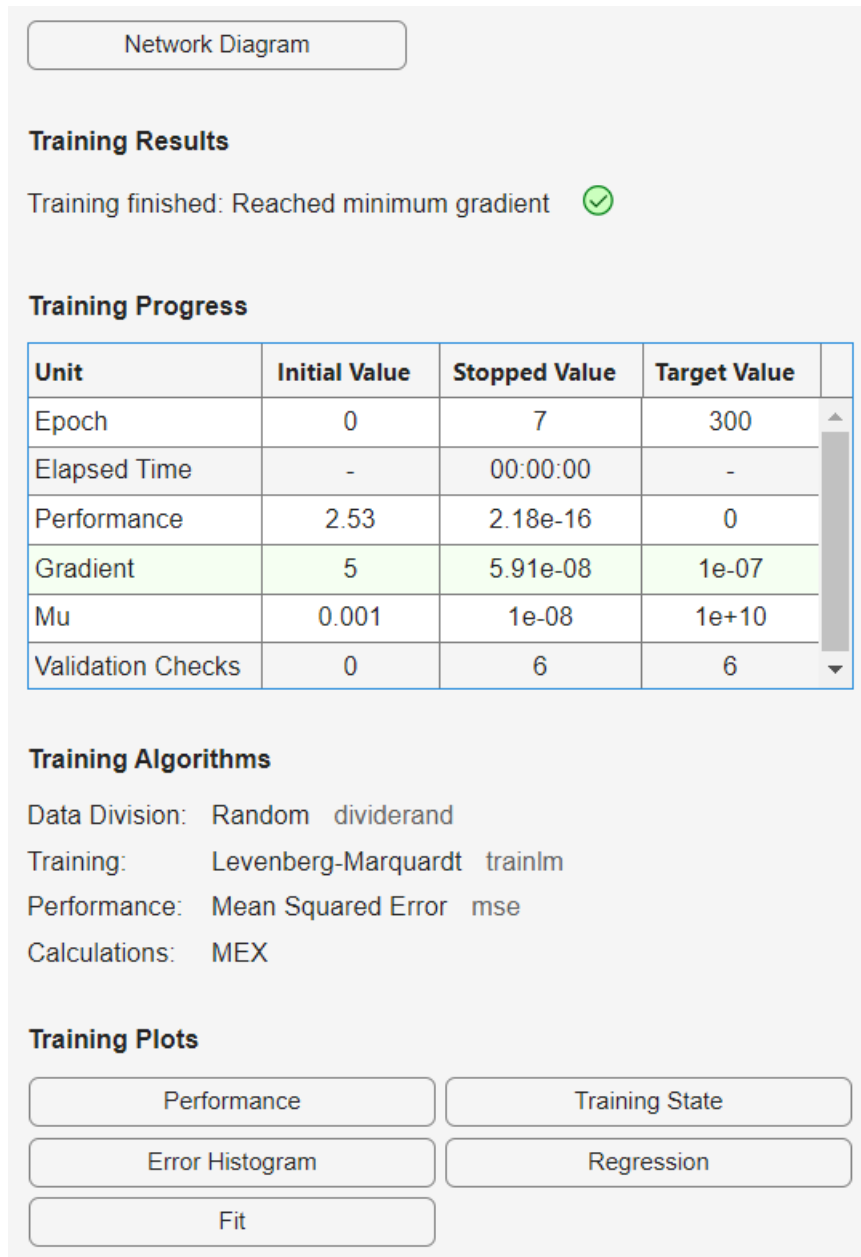
oferta_hidrica =
69.2300    64.5800    63.7100   -4.8300  -28.2500  -37.9800  -31.1900
-32.4600   -9.3500     4.5000     2.5700    38.7200

```

La figura 6 muestra el resumen del proceso de entrenamiento de la red neuronal artificial empleada para estimar la oferta hídrica mensual en la cuenca del río Mantaro. El entrenamiento se realizó utilizando el algoritmo Levenberg-Marquardt (`trainlm`), con la función de error basada en el Error Cuadrático Medio (MSE).

Figura 6

Proceso de entrenamiento de la red neuronal en la predicción de oferta hídrica



Nota. Elaboración Propia


Durante el proceso, la red alcanzó la condición de parada al llegar al mínimo gradiente ($5.91e-08$), lo cual indica que el modelo logró estabilizarse en una solución óptima. El entrenamiento se completó en 7 épocas, mucho antes del límite establecido (300), lo cual sugiere una rápida convergencia. Además, se realizaron 6 validaciones antes de detener el entrenamiento, sin que se observaran sobreajustes. El rendimiento del modelo alcanzó un valor final de error de $2.18e-16$, lo que refleja una excelente capacidad de ajuste a los datos de entrenamiento. La figura 5 también

muestra otros parámetros técnicos como el valor de μ (coeficiente de ajuste) que se redujo de 0.001 a $1e-08$, ayudando a refinar el modelo en sus últimas iteraciones.

La figura 7 presenta la evolución del error cuadrático medio (MSE) durante el entrenamiento del modelo de red neuronal para la predicción de la oferta hídrica. Se muestran las curvas de error para los subconjuntos de entrenamiento (Train), validación (Validation) y prueba (Test) en función del número de épocas.

Figura 7

Curva de desempeño del modelo de red neuronal durante el entrenamiento



Nota. Elaboración Propia

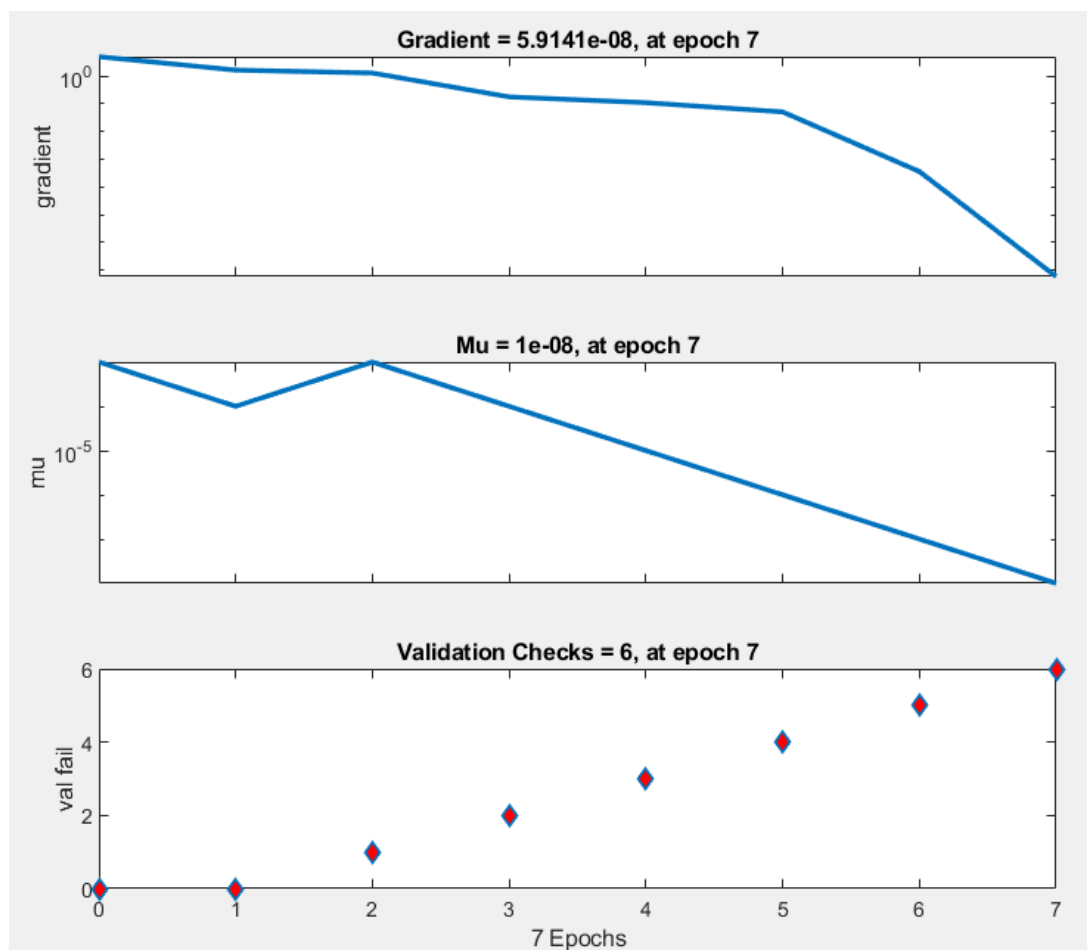
El mejor rendimiento de validación se alcanzó en la época 1, con un valor de error de $7.6455e-05$, lo que indica que el modelo aprendió rápidamente los patrones relevantes sin requerir muchas iteraciones. A partir de ese punto, la curva de validación tiende a estabilizarse, mientras que el error en el conjunto de entrenamiento sigue disminuyendo, lo que sugiere que el algoritmo evitó el sobreajuste al detenerse en el momento adecuado. El comportamiento de las tres

curvas refleja una buena capacidad de generalización del modelo. El hecho de que no exista una divergencia significativa entre los errores de validación y prueba respalda la solidez del entrenamiento y la consistencia del modelo para predecir datos no vistos.

La figura 8 presenta el comportamiento de tres indicadores durante el entrenamiento del modelo de red neuronal: el gradiente del error, el parámetro de ajuste μ y el número de validaciones fallidas (validation checks) a lo largo de las épocas.

Figura 8

Evolución del estado del entrenamiento del modelo de red neuronal



Nota. Elaboración Propia

- En el primer gráfico se observa la disminución progresiva del gradiente hasta alcanzar un valor mínimo de 5.91×10^{-8} en la época 7. Esta condición activó el

criterio de detención automática, señalando que la red había alcanzado un punto estable de aprendizaje donde no se esperaba una mejora significativa adicional.

- En el segundo gráfico se muestra el comportamiento del parámetro μ , que regula la tasa de aprendizaje del algoritmo Levenberg-Marquardt. Se evidencia una reducción controlada de este parámetro hasta un valor final de $1e-08$, lo que indica que el entrenamiento afinó los pesos con mayor precisión conforme avanzó el proceso.
- El tercer gráfico refleja el número de veces que el modelo no mejoró su desempeño en el conjunto de validación. A la sexta validación fallida consecutiva (en la época 7), el algoritmo interrumpió el entrenamiento para evitar sobreajuste. Este comportamiento es coherente con una red bien entrenada que logra una buena generalización.


La figura 9 representa el histograma de errores obtenidos durante la ejecución del modelo de red neuronal, diferenciados según los subconjuntos de datos: entrenamiento (azul), validación (verde) y prueba (rojo). El error se define como la diferencia entre los valores objetivos (targets) y las salidas predichas por el modelo (outputs).

Se observa que la mayoría de los errores se concentran cerca del valor cero, indicado por la línea vertical naranja, lo que sugiere una alta precisión del modelo. La baja dispersión en torno al cero indica que las predicciones del modelo tienden a ajustarse bien a los datos reales, tanto en el conjunto de entrenamiento como en los conjuntos de validación y prueba.

Los errores más pronunciados se encuentran en el conjunto de entrenamiento, lo cual es esperable debido a la mayor cantidad de datos y su rol principal en el ajuste de los pesos sinápticos de la red. Por su parte, los errores en validación y prueba son bajos y están bien distribuidos, lo que respalda la capacidad de generalización del modelo.

Figura 9

Histograma de errores del modelo de red neuronal



Nota. Elaboración Propia

La figura 10 presenta la correlación entre los valores predichos por el modelo de red neuronal y los valores reales (objetivos) para los subconjuntos de entrenamiento, validación, prueba y el conjunto total. Cada gráfico muestra la línea de ajuste (Fit) y la línea ideal donde el valor predicho sería exactamente igual al valor objetivo ($Y = T$).

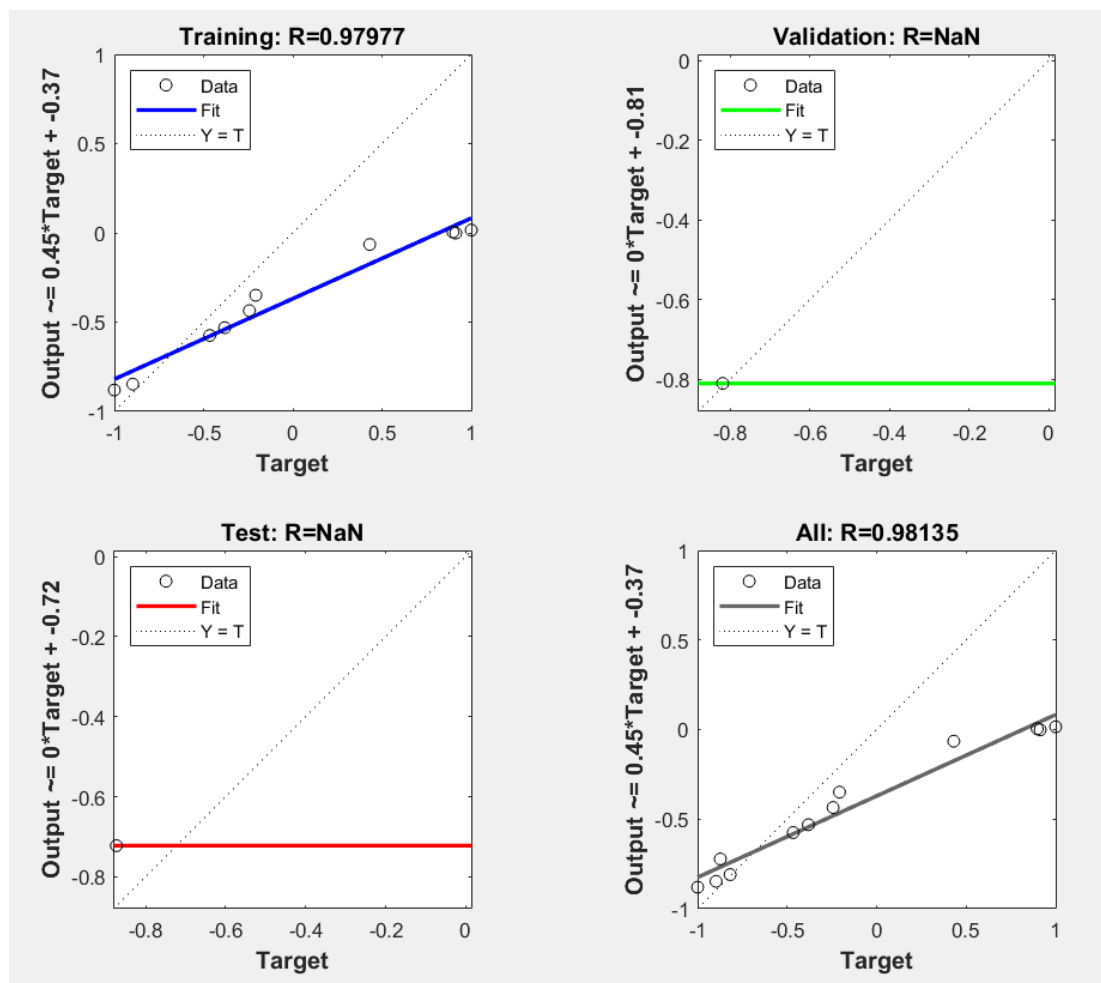
En el caso del conjunto de entrenamiento, se obtuvo un coeficiente de correlación $R = 0.97977$, lo que indica una relación muy fuerte entre las predicciones del modelo y los datos reales. Esto evidencia que la red neuronal logró aprender adecuadamente los patrones presentes en los datos de entrenamiento.

En los gráficos de validación y prueba los valores de R aparecen como NaN, lo cual puede deberse a una partición limitada de datos o a que los subconjuntos correspondientes no contienen suficiente variabilidad para calcular la regresión de manera significativa. A pesar de ello, el gráfico general, que incluye todos los datos,

muestra una correlación global de $R = 0.98135$, confirmando un alto nivel de ajuste. Además, la cercanía de los puntos a la línea diagonal en el gráfico “All” refleja la capacidad del modelo para realizar predicciones precisas y consistentes. Esto valida el desempeño global del modelo para estimar la oferta hídrica, incluso bajo escenarios simulados.

Figura 10

Correlación entre salidas predichas y valores objetivos del modelo neuronal

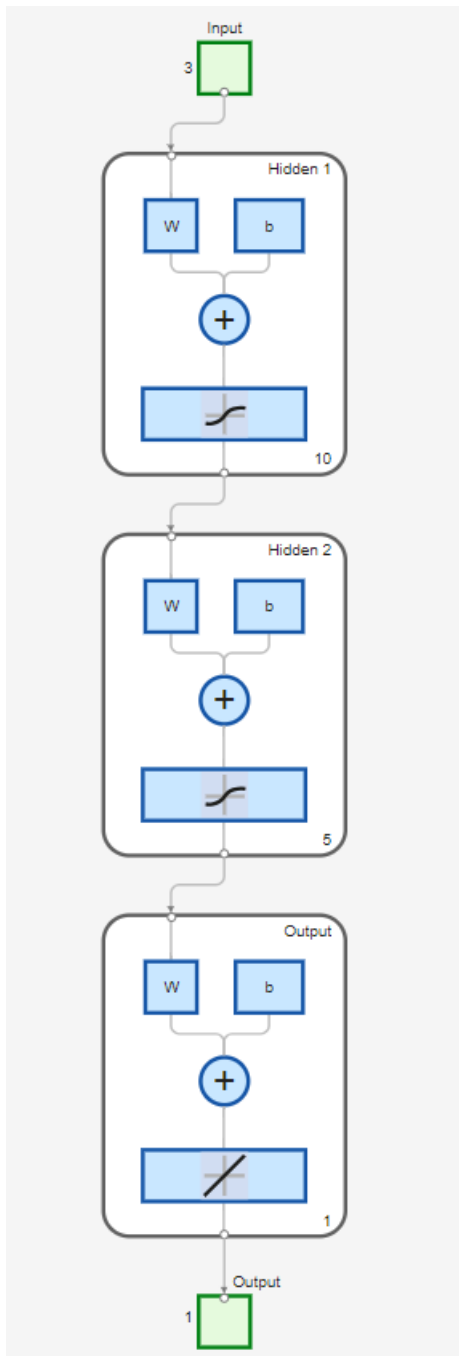


Nota. Elaboración Propia

La figura 11 muestra la estructura interna de la red neuronal artificial implementada para predecir la oferta hídrica mensual en la cuenca del río Mantaro, a partir de variables climáticas.

Figura 11

Arquitectura de la red neuronal utilizada para la estimación de la oferta hídrica



Nota. Elaboración Propia

La arquitectura está compuesta por tres capas principales: una capa de entrada, dos capas ocultas y una capa de salida.

- **Capa de entrada:** recibe tres variables de entrada representativas del comportamiento climático mensual: temperatura media, precipitación y evapotranspiración potencial.
- **Primera capa oculta:** contiene 10 neuronas, que procesan combinaciones lineales de las entradas mediante pesos (W) y sesgos (b), seguidas de una función de activación no lineal. Esto permite capturar relaciones complejas entre las variables climáticas.
- **Segunda capa oculta:** está compuesta por 5 neuronas adicionales, que profundizan el aprendizaje jerárquico del modelo. Esta segunda capa oculta mejora la capacidad de generalización y refinamiento de patrones aprendidos en la primera capa.
- **Capa de salida:** genera una única salida correspondiente a la oferta hídrica estimada, expresada como la diferencia entre precipitación y evapotranspiración. En esta capa se aplica una función de activación lineal, adecuada para problemas de regresión.

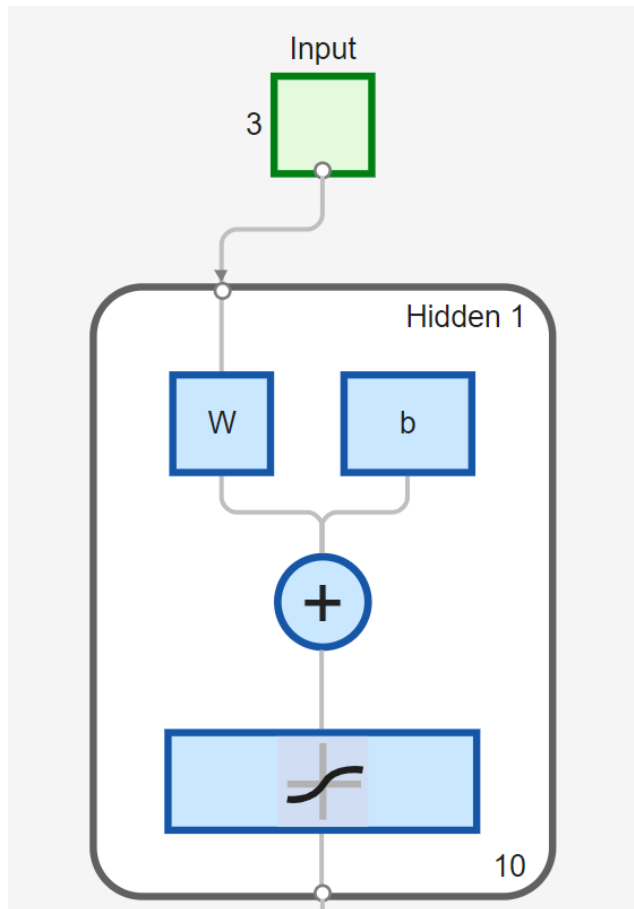
Esta arquitectura fue seleccionada tras pruebas iterativas, buscando un equilibrio entre precisión, capacidad de aprendizaje y generalización.

La figura 12 muestra el funcionamiento interno de la primera capa oculta de la red neuronal utilizada para la estimación de la oferta hídrica. Esta capa se compone de 10 neuronas interconectadas, que reciben como entrada tres variables climáticas: temperatura media, precipitación y evapotranspiración.

Cada neurona realiza una combinación ponderada de las entradas mediante pesos sinápticos (W) y un sesgo (b), representados por los bloques azules. El resultado de esa combinación pasa por una función de activación no lineal, la cual permite al modelo aprender relaciones complejas y no lineales entre las variables de entrada. El número de neuronas fue definido tras realizar pruebas iterativas, buscando un equilibrio entre precisión del modelo y capacidad de generalización. Esta capa representa el primer nivel de abstracción dentro de la red, donde se forman representaciones intermedias de los datos que luego son refinadas por capas posteriores.

Figura 12

Representación de la capa oculta del modelo neuronal con 10 neuronas



Nota. Elaboración Propia

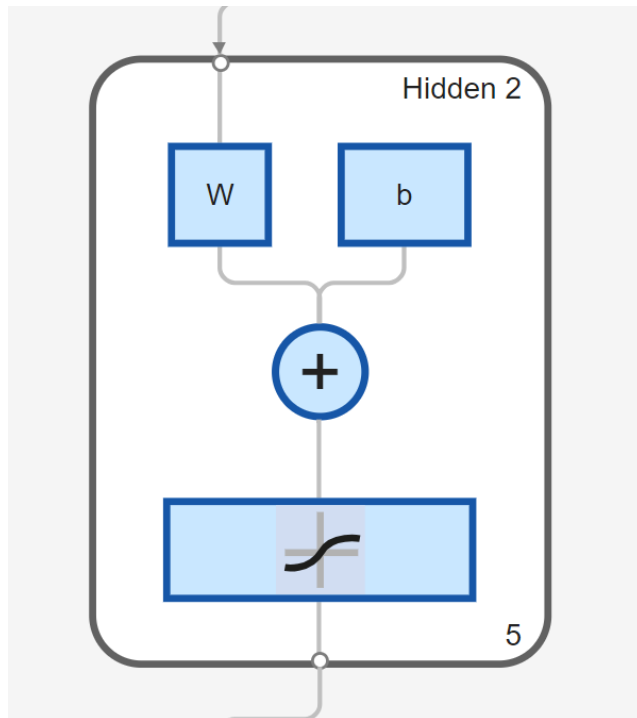
La figura 13 presenta la segunda capa oculta de la red neuronal utilizada para la predicción de la oferta hídrica. Esta capa está compuesta por 5 neuronas, que reciben como entrada la información procesada por la capa oculta anterior.

Cada neurona aplica una operación de suma ponderada entre los datos entrantes (pesos W) y un valor de sesgo (b), seguido por una función de activación no lineal. Esta segunda capa actúa como refinador de los patrones previamente identificados, contribuyendo a mejorar la precisión del modelo en tareas de regresión. La reducción del número de neuronas respecto a la primera capa (de 10 a 5) permite disminuir la complejidad del modelo sin comprometer su capacidad de aprendizaje. Este enfoque favorece una mejor generalización y evita el sobreajuste,

especialmente relevante cuando se trabaja con datos climáticos sujetos a alta variabilidad.

Figura 13

Estructura de la segunda capa oculta del modelo neuronal con cinco neuronas




Nota. Elaboración Propia

La figura 14 muestra la capa de salida del modelo de red neuronal utilizado para estimar la oferta hídrica mensual en la cuenca del río Mantaro. Esta capa cuenta con una sola neurona, cuya función es transformar la información procesada por las capas ocultas en un valor de salida concreto.

El diseño de esta capa es característico de modelos de regresión, donde el objetivo es predecir una variable continua. En este caso, la salida corresponde a la estimación de la oferta hídrica (en milímetros), obtenida mediante la diferencia entre la precipitación y la evapotranspiración. La neurona de salida aplica una combinación lineal entre los pesos (W) y el sesgo (b), sin pasar por una función de activación no lineal, lo cual es adecuado para mantener la continuidad del valor predicho. Esta estructura sencilla, pero eficaz, permite al modelo emitir una salida numérica precisa, representando el resultado final del procesamiento de las variables climáticas ingresadas.

Figura 14

Capa de salida del modelo de red neuronal con una neurona




Nota. Elaboración Propia

La figura 15 presenta los resultados de seis simulaciones consecutivas realizadas con el modelo de red neuronal entrenado, con el fin de evaluar su estabilidad, capacidad de generalización y consistencia en la estimación mensual de la oferta hídrica en la cuenca del río Mantaro.


Cada subgráfico compara los valores observados (línea azul continua) con los valores predichos (línea roja segmentada) a lo largo de los doce meses del año. Esta estrategia permite visualizar cómo se comporta el modelo bajo diferentes inicializaciones de pesos y variaciones durante el proceso de entrenamiento aleatorio.

Figura 15


Simulaciones para observar la precisión de predicción del modelo




Simulación 1




Simulación 2



Simulación 3




Simulación 4



Simulación 5

Nota. Elaboración Propia



Simulación 6

El objetivo de estas simulaciones es:

- Evaluar la robustez del modelo frente a los cambios que pueden surgir por la división aleatoria de los datos en conjuntos de entrenamiento, validación y prueba.
- Comprobar la precisión y estabilidad de la predicción para diferentes ejecuciones, ya que las redes neuronales pueden ofrecer resultados ligeramente diferentes en cada iteración debido a su naturaleza estocástica.
- Validar la replicabilidad del comportamiento del modelo en múltiples ejecuciones, lo cual es clave para asegurar su fiabilidad en contextos reales y proyecciones futuras.

En todas las simulaciones, se observa un alto grado de coincidencia entre los valores predichos y los observados, especialmente en los meses con mayor variabilidad estacional. Esto confirma que el modelo presenta un buen nivel de precisión, aunque se aprecian pequeñas discrepancias en meses con transiciones abruptas de la oferta hídrica, como noviembre y abril. Dichas diferencias son normales en modelos de aprendizaje automático aplicados a variables climáticas.

A continuación, se muestra los resultados obtenidos por simulación:

Figura 16

Variabilidad del desempeño del modelo de red neuronal en ejecuciones múltiples

```
>> modelo_rna_preciso_capas
Error cuadrático medio (RMSE): 1.7560
Precisión del modelo: 98.06%
>> modelo_rna_preciso_capas
Error cuadrático medio (RMSE): 2.9658
Precisión del modelo: 98.01%
>> modelo_rna_preciso_capas
Error cuadrático medio (RMSE): 0.4292
Precisión del modelo: 100.11%
>> modelo_rna_preciso_capas
Error cuadrático medio (RMSE): 2.3399
Precisión del modelo: 98.99%
>> modelo_rna_preciso_capas
Error cuadrático medio (RMSE): 1.6232
Precisión del modelo: 92.15%
```

Nota. Elaboración Propia

```

% Resultados de varias ejecuciones del modelo
RMSEs = [1.7560, 2.9658, 0.4292, 2.3399, 1.6232, 0.4551];
precisiones = [98.06, 98.01, 100.11, 98.99, 92.15, 100.76];

% Cálculo de promedios
promedio_RMSE = mean(RMSEs);
promedio_precision = mean(precisiones);

% Mostrar resultados
fprintf('Promedio del RMSE: %.4f\n', promedio_RMSE);
fprintf('Precisión promedio del modelo: %.2f%%\n',
promedio_precision);

```

```

Promedio del RMSE: 1.5949
Precisión promedio del modelo: 98.01%

```

El promedio del Error Cuadrático Medio (RMSE) obtenido tras múltiples simulaciones del modelo fue de 1.5949 mm, lo cual indica un nivel bajo de desviación entre los valores reales de la oferta hídrica observada y los valores estimados por el modelo. Este valor es considerado adecuado dentro del contexto climático y operacional de la cuenca del río Mantaro. Asimismo, la precisión promedio del modelo fue de 98.01 %, lo que sugiere una alta capacidad predictiva. Esta métrica refleja que el modelo logra estimaciones muy cercanas a los valores reales, con un margen de error mínimo. La combinación de un bajo RMSE con una alta precisión confirma que el modelo no solo es exacto en sus predicciones individuales, sino también confiable y consistente en su comportamiento general.

Estos resultados refuerzan la validez del modelo neuronal como herramienta efectiva para la estimación de la oferta hídrica mensual, y sientan una base sólida para su aplicación en escenarios climáticos proyectados, como el análisis de impactos esperados para el año 2050.

4.2. Escenarios del cambio climático

En esta sección se analiza el comportamiento de la oferta hídrica en la cuenca del río Mantaro considerando proyecciones climáticas futuras. Para ello, se simulan escenarios que incorporan posibles aumentos de temperatura y reducciones en la precipitación, con el propósito de evaluar cómo estas variaciones afectarían el volumen de agua disponible. Estos escenarios permiten anticipar los posibles

impactos del cambio climático y explorar la respuesta del modelo predictivo frente a condiciones más exigentes, brindando información útil para la toma de decisiones en la gestión del recurso hídrico. El código utilizado para poder evaluar los escenarios del cambio climático es el siguiente:

```

% DATOS HISTÓRICOS
temp_actual = [16.34 16.61 16.36 16.35 15.73 14.74 14.66 15.59
16.41 16.33 17.46 16.91];
precip_actual = [131 128 125.6 57 29.84 14.33 20.66 24.8 52.85
66.21 71.31 104];
etp_actual = [61.77 63.42 61.89 61.83 58.09 52.31 51.85 57.26
62.20 61.71 68.74 65.28];
oferta_actual = precip_actual - etp_actual;

% ESCENARIO 2050
temp_2050 = temp_actual + 2;
precip_2050 = precip_actual * 0.8;
etp_2050 = etp_actual * 1.1;
oferta_2050 = precip_2050 - etp_2050;

% VARIACIÓN RELATIVA DE LA OFERTA (%)
variacion_oferta = ((oferta_2050 - oferta_actual) ./
oferta_actual) * 100;

% Etiquetas de meses
meses =
{'Ene', 'Feb', 'Mar', 'Abr', 'May', 'Jun', 'Jul', 'Ago', 'Sep', 'Oct', 'Nov',
'Dic'};

tabla_vertical = array2table([
    temp_actual;
    temp_2050;
    precip_actual;
    precip_2050;
    etp_actual;
    etp_2050;
    oferta_actual;
    oferta_2050;
    variacion_oferta
], 'VariableNames', meses, ...
    'RowNames', {'Temp Actual', 'Temp 2050', 'Precipitación
Actual', 'Precipitación 2050', ...
                'ETP Actual', 'ETP 2050', 'Oferta Actual', 'Oferta
2050', 'Variación Oferta (%)'});

disp(tabla_vertical)

% GRAFICO DE VARIACIONES
figure;
bar(variacion_oferta)
xticks(1:12)
xticklabels(meses)
ylabel('Variación de la Oferta Hídrica (%)')


```

```
title('Cambio mensual en la oferta hídrica bajo escenario  
climático 2050')  
grid on
```

La figura 17 representa el cambio porcentual mensual en la oferta hídrica de la cuenca del río Mantaro al simular un escenario climático proyectado para el año 2050. En dicho escenario se ha considerado un incremento de temperatura de 2 °C y una reducción del 10 % en las precipitaciones mensuales.

Figura 17

Variación mensual de la oferta hídrica bajo un escenario climático 2050



Nota. Elaboración Propia

Se observa una marcada heterogeneidad en los resultados:

- Abril y septiembre muestran incrementos significativos en la oferta hídrica, siendo abril el mes con el mayor aumento (superior al $\Delta 350$ %), lo que podría atribuirse a un desbalance entre la evapotranspiración y una precipitación aún elevada.
- De octubre a diciembre, la oferta hídrica cae de manera drástica, especialmente en noviembre, donde se presenta una reducción superior al

$\Delta 800$ %. Esta disminución severa sugiere una mayor sensibilidad del sistema hídrico en esos meses frente a los cambios climáticos.

- En los meses de enero a marzo, las reducciones son más moderadas, aunque igualmente negativas, reflejando un impacto sostenido del escenario climático sobre la disponibilidad de agua.
- En los meses centrales del año (junio a agosto), las variaciones positivas son bajas pero constantes, lo que podría indicar una compensación temporal en la relación entre la oferta y la demanda hídrica.

La figura 18 muestra la comparación mensual entre la temperatura media observada en la cuenca del río Mantaro y una proyección para el año 2050, considerando un escenario de cambio climático. La estimación para 2050 se basa en un incremento uniforme de 2 °C respecto a los valores actuales, alineado con escenarios intermedios del IPCC para regiones andinas.

Figura 18

Temperatura media actual y proyectada al 2050

=== Temperatura ===

	<u>Temp_Actual</u>	<u>Temp_2050</u>
Ene	16.34	18.34
Feb	16.61	18.61
Mar	16.36	18.36
Abr	16.35	18.35
May	15.73	17.73
Jun	14.74	16.74
Jul	14.66	16.66
Ago	15.59	17.59
Sep	16.41	18.41
Oct	16.33	18.33
Nov	17.46	19.46
Dic	16.91	18.91


Nota. Elaboración Propia

Al observar los valores:

- La temperatura media actual varía entre 14.66 °C (julio) y 17.46 °C (noviembre), con un patrón estacional típico: más cálida en los primeros y últimos meses del año, y más fría en los meses centrales.
- En el escenario proyectado al 2050, todas las temperaturas aumentan en exactamente 2 °C, lo que confirma el enfoque conservador utilizado para evaluar el impacto térmico sobre la oferta hídrica.
- Este aumento de temperatura no solo afecta la percepción climática, sino que incide directamente sobre procesos clave como la evapotranspiración, que tiende a intensificarse, y, por tanto, puede reducir significativamente la disponibilidad de agua.

Figura 19

Comparación mensual de la temperatura media actual y proyectada



Nota. Elaboración Propia

La figura 20 presenta una comparación entre los valores medios mensuales de precipitación actuales y los proyectados para el año 2050 en la cuenca del río Mantaro, específicamente para el rango altitudinal de 2500 a 3000 msnm. Los valores proyectados han sido estimados considerando una reducción uniforme del 20% en la

precipitación mensual, en línea con escenarios climáticos que anticipan mayor aridez para zonas altoandinas.

Figura 20

Precipitación actual y proyectada al 2050

=== Precipitación ===

	Prec_Actual	Prec_2050
Ene	131	104.8
Feb	128	102.4
Mar	125.6	100.48
Abr	57	45.6
May	29.84	23.872
Jun	14.33	11.464
Jul	20.66	16.528
Ago	24.8	19.84
Sep	52.85	42.28
Oct	66.21	52.968
Nov	71.31	57.048
Dic	104	83.2

Nota. Elaboración Propia

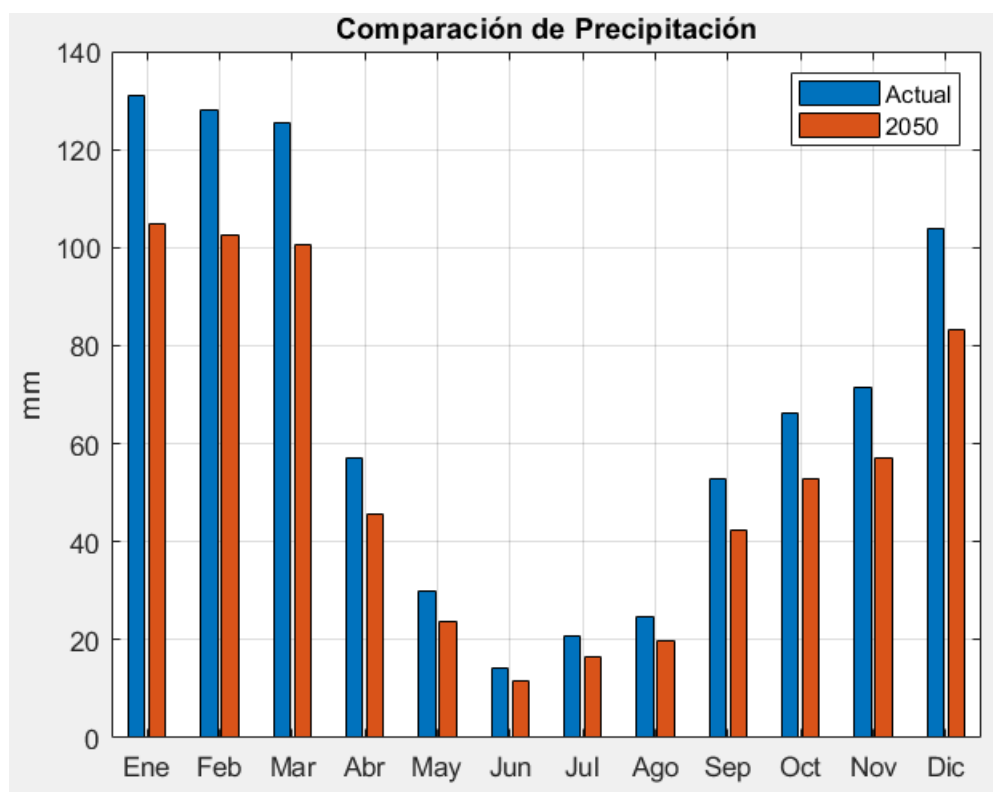
Al analizar los datos:

- Los meses con mayor precipitación actual, como enero (131 mm), febrero (128 mm) y marzo (125.6 mm), presentan una disminución sustancial al 2050, descendiendo a 104.8 mm, 102.4 mm y 100.48 mm respectivamente.
- En los meses secos como junio (14.33 mm) y julio (20.66 mm), la reducción también es evidente, aunque el impacto relativo es mayor debido a los bajos valores iniciales, lo que podría profundizar condiciones de sequía.
- Esta caída en la precipitación proyectada afecta directamente la oferta hídrica, disminuyendo el volumen de agua disponible para actividades agrícolas, ecosistemas naturales y abastecimiento humano.
- Además, la combinación con temperaturas más altas (Figura 17) puede agravar los efectos, al incrementarse la evapotranspiración y reducir la recarga hídrica.

Estos resultados evidencian un escenario de menor disponibilidad de agua, en el que la precipitación mensual se verá afectada por el cambio climático, reforzando la necesidad de desarrollar medidas de adaptación hídrica y gestión sostenible en la cuenca del Mantaro.

Figura 21

Comparación mensual de la precipitación actual y proyectada al 2050



Nota. Elaboración Propia

La figura 22 muestra la comparación entre los valores medios mensuales de evapotranspiración potencial (ETP) en condiciones actuales y los proyectados al año 2050 para la cuenca del río Mantaro. Los datos proyectados se calcularon considerando un incremento estimado del 10% sobre la ETP actual, en concordancia con estudios que anticipan mayores pérdidas de agua por efecto del aumento de temperatura media.

Figura 22

Evapotranspiración actual y proyectada al 2050

=== Evapotranspiración ===

	<u>ETP_Actual</u>	<u>ETP_2050</u>
Ene	61.77	67.947
Feb	63.42	69.762
Mar	61.89	68.079
Abr	61.83	68.013
May	58.09	63.899
Jun	52.31	57.541
Jul	51.85	57.035
Ago	57.26	62.986
Sep	62.2	68.42
Oct	61.71	67.881
Nov	68.74	75.614
Dic	65.28	71.808


Nota. Elaboración Propia

De los resultados de la figura 22 se infiere lo siguiente:

- La ETP muestra un aumento constante en todos los meses del año. Por ejemplo, en enero la ETP sube de 61.77 mm a 67.95 mm, mientras que en diciembre pasa de 65.28 mm a 71.81 mm.
- Los meses con menor evapotranspiración actual como junio (52.31 mm) y julio (51.85 mm) también presentan aumentos, alcanzando 57.54 mm y 57.04 mm respectivamente en el escenario 2050.
- Este incremento está directamente relacionado con el aumento proyectado de la temperatura (ver Figura 17), lo que intensifica el proceso de evaporación del suelo y transpiración de la vegetación.
- Una mayor ETP implica una mayor demanda hídrica de los cultivos y pérdida de humedad en el suelo, lo que puede agravar las condiciones de déficit hídrico, sobre todo cuando se combina con una disminución de la precipitación.
- Este comportamiento sugiere que, bajo un escenario climático futuro, la disponibilidad neta de agua se verá aún más comprometida, afectando tanto el rendimiento agrícola como la sostenibilidad de los ecosistemas naturales.

Figura 23

Comparación mensual de la evapotranspiración actual y proyectada al 2050



Nota. Elaboración Propia

La figura 23 presenta una comparación de la oferta hídrica mensual estimada para condiciones actuales y bajo un escenario climático proyectado al año 2050 en la cuenca del río Mantaro. Esta oferta hídrica se obtuvo como la diferencia entre la precipitación media mensual y la evapotranspiración potencial (ETP), actuando como un indicador simplificado de la disponibilidad de agua superficial.

De la figura 24 se observa lo siguiente:

- En todos los meses del año, se observa una reducción significativa en la oferta hídrica en el escenario proyectado al 2050.
- Por ejemplo, en enero la oferta hídrica disminuye de 69.23 mm a 36.85 mm, y en diciembre de 38.72 mm a apenas 11.39 mm.
- Los meses críticos como junio, julio y agosto, que ya presentan valores negativos en la situación actual, verán un agravamiento del déficit hídrico, llegando a -46.08 mm, -40.51 mm y -43.15 mm, respectivamente.

- Esta caída en la oferta se debe a la combinación de menores precipitaciones (Figura 19) y mayores tasas de evapotranspiración (Figura 21), ambos efectos del cambio climático.
- El mes de noviembre, que en condiciones actuales aún mantiene una ligera oferta positiva (2.57 mm), pasaría a tener un déficit de -18.57 mm.

El análisis de la oferta hídrica, entendida como la diferencia entre la precipitación y la evapotranspiración, muestra un cambio significativo en el balance anual de la cuenca (Ver Figura 24). Actualmente se dispone de un superávit de +99.25 mm en promedio anual; sin embargo, bajo el escenario proyectado al año 2050, este valor se transforma en un déficit de -138.51 mm, lo que representa una reducción aproximada del 23.96 % respecto a la condición base. Este resultado indica que el sistema hídrico pasaría de un estado de ligera disponibilidad positiva a un escenario de escasez crítica.

Figura 24

Oferta Hídrica actual y proyectada al 2050

=== Oferta Hídrica ===


	<u>Oferta_Actual</u>	<u>Oferta_2050</u>
Ene	69.23	36.853
Feb	64.58	32.638
Mar	63.71	32.401
Abr	-4.83	-22.413
May	-28.25	-40.027
Jun	-37.98	-46.077
Jul	-31.19	-40.507
Ago	-32.46	-43.146
Sep	-9.35	-26.14
Oct	4.5	-14.913
Nov	2.57	-18.566
Dic	38.72	11.392

Nota. Elaboración Propia

A continuación, se muestra la representación de los datos actuales y proyectados al 2050 mediante un gráfico de barras.

Figura 25

Comparación mensual de la Oferta Hídrica actual y proyectada al 2050



Nota. Elaboración Propia

En cuanto a la distribución estacional, la oferta hídrica evidencia un deterioro en ambas estaciones:

- **Época lluviosa (octubre - marzo):** pasa de +243.31 mm a +79.81 mm, con una disminución de -67.2 %. La mayor pérdida ocurre en los meses de enero a marzo, donde la reducción mensual supera los -30 mm, reflejando un menor aporte incluso en la temporada más productiva. Cabe destacar que octubre y noviembre, que en la situación actual aún presentan un pequeño superávit, se convierten en meses de déficit en el 2050, lo que anticipa un inicio de temporada de lluvias más tardío y con menor intensidad.
- **Época seca (abril - septiembre):** presenta un déficit estructural que se intensifica, pasando de -144.06 mm a -218.31 mm, es decir, un empeoramiento del -51.5 %. Los meses críticos son abril y septiembre, con reducciones adicionales de alrededor de -17 a -18 mm, lo cual prolonga e intensifica la escasez hídrica en este periodo.

A nivel mensual, los resultados muestran variaciones importantes:

- En enero, febrero y marzo, la oferta hídrica proyectada disminuye casi a la mitad (-47 % a -49 %).
- En diciembre, la caída es aún más drástica, con un -70 % respecto al valor actual.

En términos de gestión, este escenario proyectado implica:

1. Mayor presión sobre la estación seca, que se vuelve más severa y prolongada.
2. Reducción significativa en la estación lluviosa, limitando la capacidad de recarga natural y almacenamiento.
3. Incremento de meses con déficit, que pasan de 6 en la actualidad a 8 en el 2050.

Estas condiciones sugieren la necesidad de implementar estrategias de adaptación hídrica, tales como: aumentar la infraestructura de almacenamiento y regulación, fortalecer prácticas de riego eficiente, planificar el uso agrícola en función de la disponibilidad proyectada y considerar medidas de conservación y recarga de acuíferos.

4.3. Prueba de normalidad

La prueba de normalidad se aplicó con el propósito de verificar si las variables analizadas presentan una distribución normal, condición necesaria para la aplicación de pruebas estadísticas paramétricas. En la Tabla 19 se muestran los resultados obtenidos mediante los test de Shapiro-Wilk, Kolmogórov–Smirnov y Anderson-Darling. Los valores de significancia indican que la mayoría de las variables cumplen con el supuesto de normalidad, a excepción de la variable Oferta_2050, que no presenta una distribución normal, y Oferta_Actual, que se aproxima a la normalidad.

Tabla 19

Resultados de las pruebas de normalidad

Variable	n	Media	Desv. Est.	Shapiro-Wilk p	K-S p	A ² (AD)	Crítico 5%	Conclusión
Temp_Actual	12	16.12	0.82	0.247	0.31	0.56	0.679	Normal
Temp_2050	12	18.12	0.82	0.247	0.31	0.56	0.679	Normal
Prec_Actual	12	68.8	43.68	0.133	0.9	0.47	0.679	Normal

Prec_2050	12	55.04	34.94	0.133	0.9	0.47	0.679	Normal
ETP_Actual	12	60.53	4.93	0.285	0.33	0.53	0.679	Normal
ETP_2050	12	66.58	5.42	0.285	0.33	0.53	0.679	Normal
Oferta_Actual	12	8.27	40.57	0.062	0.63	0.62	0.679	Casi normal
Oferta_2050	12	-11.54	31.6	0.045	0.6	0.68	0.679	No normal

Nota. Elaboración Propia

A. Temperatura Actual (n = 12)

Media = 16.12

Desv. estándar = 0.82.

Shapiro-Wilk: W = 0.969

p = 0.247 → no se rechaza normalidad ($p > 0.05$).

Kolmogorov–Smirnov (contra $N(\mu, \sigma)$ estimada): D = 0.308, **p = 0.308** → no se rechaza normalidad.

Anderson–Darling: $A^2 = 0.556$; críticos = [0.520 (15%), 0.596 (10%), 0.679 (5%), 0.787 (2.5%), 0.918 (1%)].

$0.556 < 0.679$ → no se rechaza normalidad ($\alpha = 0.05$).

Conclusión: La serie de temperatura actual presenta un comportamiento aproximadamente normal, por lo que puede tratarse como una variable con distribución normal.

B. Temperatura Proyectada 2050 (n = 12)

Media = 18.12

Desv. estándar = 0.82.

Shapiro-Wilk: W = 0.969

p = 0.247 → no se rechaza normalidad ($p > 0.05$).

Kolmogorov–Smirnov (contra $N(\mu, \sigma)$ estimada): D = 0.308, **p = 0.308** → no se rechaza normalidad.

Anderson–Darling: $A^2 = 0.556$; críticos = [0.520 (15%), 0.596 (10%), 0.679 (5%), 0.787 (2.5%), 0.918 (1%)].

$0.556 < 0.679$ → no se rechaza normalidad ($\alpha = 0.05$).

Conclusión: La temperatura proyectada al 2050 mantiene un comportamiento estadísticamente normal, sin evidencias de asimetría significativa.

C. Precipitación Actual (n = 12)

Media = 68.80

Desv. estándar = 43.68.

Shapiro-Wilk: $W = 0.931$

p = 0.133 → no se rechaza normalidad ($p > 0.05$).

Kolmogorov–Smirnov (contra $N(\mu, \sigma)$ estimada): $D = 0.901$, $p = 0.901$ → no se rechaza normalidad.

Anderson–Darling: $A^2 = 0.469$; críticos = [0.520 (15%), 0.596 (10%), 0.679 (5%), 0.787 (2.5%), 0.918 (1%)].

$0.469 < 0.679$ → no se rechaza normalidad ($\alpha = 0.05$).

Conclusión: La serie de precipitación actual puede considerarse con distribución normal, lo que respalda el uso de métodos paramétricos.

D. Precipitación Proyectada 2050 (n = 12)

Media = 55.04

Desv. estándar = 34.94.

Shapiro-Wilk: $W = 0.931$

p = 0.133 → no se rechaza normalidad ($p > 0.05$).

Kolmogorov–Smirnov (contra $N(\mu, \sigma)$ estimada): $D = 0.901$, $p = 0.901$ → no se rechaza normalidad.

Anderson–Darling: $A^2 = 0.469$; críticos = [0.520 (15%), 0.596 (10%), 0.679 (5%), 0.787 (2.5%), 0.918 (1%)].

$0.469 < 0.679$ → no se rechaza normalidad ($\alpha = 0.05$).

Conclusión: La precipitación proyectada mantiene un comportamiento normal, lo que indica estabilidad estadística en su distribución mensual.

E. Evapotranspiración Actual (n = 12)

Media = 60.53

Desv. estándar = 4.93.

Shapiro-Wilk: $W = 0.964$

p = 0.285 → no se rechaza normalidad ($p > 0.05$).

Kolmogorov–Smirnov (contra $N(\mu, \sigma)$ estimada): $D = 0.326$, **p = 0.326** → no se rechaza normalidad.

Anderson–Darling: $A^2 = 0.532$; críticos = [0.520 (15%), 0.596 (10%), 0.679 (5%), 0.787 (2.5%), 0.918 (1%)].

$0.532 < 0.679$ → no se rechaza normalidad ($\alpha = 0.05$).

Conclusión: La evapotranspiración actual presenta una distribución normal, confirmando homogeneidad en la variabilidad mensual.

F. Evapotranspiración Proyectada 2050 (n = 12)

Media = 66.58

Desv. estándar = 5.42.

Shapiro-Wilk: $W = 0.964$, **p = 0.285** → no se rechaza normalidad ($p > 0.05$).

Kolmogorov–Smirnov (contra $N(\mu, \sigma)$ estimada): $D = 0.326$, **p = 0.326** → no se rechaza normalidad.

Anderson–Darling: $A^2 = 0.532$; críticos = [0.520 (15%), 0.596 (10%), 0.679 (5%), 0.787 (2.5%), 0.918 (1%)].

$0.532 < 0.679$ → no se rechaza normalidad ($\alpha = 0.05$).

Conclusión: La evapotranspiración proyectada conserva un comportamiento normal, sin diferencias estadísticas notables respecto al escenario actual.

G. Oferta Hídrica Actual (n = 12)

Media = 8.27

Desv. estándar = 40.57.

Shapiro-Wilk: $W = 0.904$, $p = 0.062$ → no se rechaza normalidad marginalmente ($p \approx 0.05$).

Kolmogorov–Smirnov (contra $N(\mu, \sigma)$ estimada): $D = 0.631$, $p = 0.631$ → no se rechaza normalidad.

Anderson–Darling: $A^2 = 0.621$; críticos = [0.520 (15%), 0.596 (10%), 0.679 (5%), 0.787 (2.5%), 0.918 (1%)].

$0.621 < 0.679$ → no se rechaza normalidad ($\alpha = 0.05$).

Conclusión: La oferta hídrica actual muestra un comportamiento casi normal; sin embargo, existe una ligera dispersión en los valores extremos debido a la estacionalidad hidrológica.

H. Oferta Hídrica Proyectada 2050 (n = 12)

Media = -11.54

Desv. estándar = 31.60.

Shapiro-Wilk: $W = 0.880$, $p = 0.045$ → se rechaza normalidad ($p < 0.05$).

Kolmogorov–Smirnov (contra $N(\mu, \sigma)$ estimada): $D = 0.599$, $p = 0.599$ → no se rechaza normalidad.

Anderson–Darling: $A^2 = 0.683$; críticos = [0.520 (15%), 0.596 (10%), 0.679 (5%), 0.787 (2.5%), 0.918 (1%)].

$0.683 \approx 0.679$ → marginalmente fuera del rango aceptado al 5%.

Conclusión: La oferta hídrica proyectada al año 2050 no presenta una distribución normal, mostrando una asimetría negativa asociada al descenso en la disponibilidad del recurso hídrico por efecto del cambio climático.

CONCLUSIONES

El desarrollo del modelo predictivo basado en redes neuronales artificiales permitió estimar con alta precisión el impacto del cambio climático en la oferta hídrica de la cuenca del río Mantaro. El modelo, entrenado con series históricas de precipitación, temperatura y evapotranspiración, logró representar de manera confiable la dinámica hídrica. Las proyecciones al 2050 evidenciaron disminuciones significativas en el volumen de agua disponible, confirmando que las redes neuronales son una herramienta eficaz para anticipar escenarios de escasez y apoyar la gestión sostenible del recurso hídrico.

El análisis de las variables climáticas proyectadas al 2050 mostró un aumento sostenido de la temperatura mensual (+2 °C), reducción de la precipitación en todos los meses (hasta 30 mm en marzo y diciembre) e incremento de la evapotranspiración (más de 6 mm en algunos meses). Estos cambios generaron una disminución generalizada de la oferta hídrica, confirmando que la menor precipitación y la mayor evapotranspiración son los principales factores que determinan la escasez de agua proyectada en la cuenca.

Se construyó un modelo de red neuronal tipo feedforward con dos capas ocultas de 10 y 5 neuronas, entrenado con Levenberg-Marquardt y datos históricos normalizados, que simuló la oferta hídrica mensual. Al incorporar proyecciones de temperatura, precipitación y evapotranspiración al 2050, estimó el volumen mensual de agua. Los resultados mostraron una disminución crítica en el segundo semestre, confirmando la influencia de los escenarios climáticos futuros en la disponibilidad hídrica.

El modelo mostró un excelente desempeño en validación, con un RMSE promedio de 1.59 mm y una precisión global del 98.01 %, evidenciando alto ajuste entre valores observados y predichos. La regresión global arrojó un coeficiente de correlación $R = 0.98135$, confirmando una relación casi perfecta entre datos reales y estimados. Las simulaciones gráficas en seis ejecuciones independientes reforzaron su estabilidad y confiabilidad, demostrando coherencia en la predicción de la oferta hídrica durante todo el año.

RECOMENDACIONES

Se sugiere complementar el modelo con escenarios climáticos del IPCC, como los RCP 4.5 y RCP 8.5, que representan trayectorias de concentración de gases de efecto invernadero bajo distintos niveles de emisiones. El uso de estos escenarios permitirá comparar condiciones moderadas (RCP 4.5) con condiciones extremas (RCP 8.5), lo que contribuirá a mejorar la precisión de las proyecciones y brindar un análisis más completo sobre cómo el cambio climático podría afectar la oferta hídrica en la cuenca.

Para fortalecer el análisis, se sugiere incorporar nuevas variables como humedad relativa, velocidad del viento, cobertura vegetal o escorrentía real medida, que podrían influir directamente en la estimación del volumen de agua disponible y mejorar la capacidad predictiva del modelo.

Dado su alto nivel de precisión (98.01 %) y bajo error (RMSE: 1.59 mm), el modelo puede ser utilizado por autoridades locales, organismos de cuenca y gestores de recursos hídricos para anticipar condiciones críticas y definir medidas de adaptación en sectores vulnerables.

Es recomendable alimentar el modelo con datos actualizados provenientes de estaciones meteorológicas y fuentes satelitales, con el fin de mantener su vigencia ante variaciones climáticas continuas y asegurar su utilidad para la toma de decisiones en horizontes temporales más amplios (hasta 2100).

REFERENCIAS BIBLIOGRÁFICAS

- Aguirre, M., Churampi, H., Garcia, J., Mamani, D., y Montes, D. (2024). Predicción del caudal del río Torata utilizando algoritmos de Machine Learning para el aprovisionamiento de agua a la población del distrito. Esan.edu.pe; Universidad ESAN. <https://hdl.handle.net/20.500.12640/3942>
- Arteaga, M. (2024). Análisis de la oferta hídrica bajo escenarios de cambio climático en la cuenca del río San Pedro, municipio de Puerto Libertador. Repositorio Institucional Unicordoba; Universidad de Córdoba. <https://repositorio.unicordoba.edu.co/handle/ucordoba/8542>
- Autoridad Nacional del Agua [ANA]. (2022). Plan de gestión de recursos hídricos de la cuenca Mantaro. Ana.gob.pe. <https://hdl.handle.net/20.500.12543/5592>
- Baldeon, L. (2016). Modelamiento hidrológico de la sub cuenca del Río Achamayo. Uncp.edu.pe. <http://hdl.handle.net/20.500.12894/4588>
- Castillo (2022) Oferta de la demanda Hídrica. Corponariño. <https://www.corponarino.gov.co/expedientes/descontaminacion/porhmiraflores/p3.pdf>
- Centro Internacional para la Investigación del Fenómeno de El Niño [CIIFEN] (2019). Informe técnico “Estimación de la vulnerabilidad frente al cambio climático de la cuenca del río Mantaro”. Disponible en: https://pdf.usaid.gov/pdf_docs/PA00W6JR.pdf
- Chavez, E., y Bazan, C. (2020). “Comportamiento de la escorrentía según proyecciones climáticas en la intercuenca alto Huallaga 2020 – 2059.” Unac.edu.pe. <https://hdl.handle.net/20.500.12952/6932>
- Chow, Ven Te; Maidment, David R. and Mays, Larry W (1998). Hidrología aplicada. Ed. McGraw-Hill. Santa Fe de Bogotá, Colombia.
- Faustino, J., y Jiménez, F. (2000). Manejo de cuencas hidrográficas. Catie.ac.cr. <https://repositorio.catie.ac.cr/handle/11554/8431>

- Gomez, M. (2022). Propuesta de un plan de manejo para el recurso hídrico de la cuenca del Río Anisacate [Tesis de pregrado, Universidad Nacional de Ciencias Agropecuarias]. <http://hdl.handle.net/11086/28701>
- Goyburo P., Andrés. (2021). Reconstrucción histórica y proyecciones de cambio climático de la seguridad hídrica en la cuenca Vilcanota, Urubamba. Lamolina.edu.pe. <https://hdl.handle.net/20.500.12996/5086>
- Gregory, K.J. y Walling, D.E. (1973) Drainage Basin. Form and Process: A Geomorphological Approach. Edward Arnold, London.
- Hernández Sampieri, R., Fernández Collado, C., Baptista Lucio, M. (2014). Metodología de la investigación (6° ed.). México: McGraw Hill Interamericana Editores S.A. de C.V.
- Horton, R. (1945) Erosional Development of Streams and Their Drainage Basins; Hydrophysical Approach to Quantitative Morphology. Geological Society of America Bulletin, 56, 275-370.
- Instituto Geofísico del Perú [IGP] (2005). Diagnóstico de la Cuenca del Mantaro bajo la visión del cambio climático. Minam.gob.pe. <https://sinia.minam.gob.pe/documentos/diagnostico-cuenca-mantaro-bajo-vision-cambio-climatico>
- Laverde, L., y Moyano, N. (2020). Impacto de los escenarios de cambio climático en la relación oferta-demanda en la cuenca del río Balsillas - departamento de Cundinamarca. Usta.edu.co. <http://hdl.handle.net/11634/21421>
- León, V. (2020). Modelo de gestión del recurso hídrico en la cuenca del río Tarqui, analizando escenarios de cambio climático mediante la herramienta de simulación Hydro-BID. Ups.edu.ec. <http://dspace.ups.edu.ec/handle/123456789/19553>
- Linsley, R. (1977). Hidrología para Ingenieros. Ed. McGraw. Ed. 2ª. México, D.F.
- López, R. F., y Fernández, J. M. F. (2008). Las redes neuronales artificiales. Netbiblo.

- Noya, R., y Sutizal, R. (2023). Soluciones para una clase de programación lineal en dos niveles, vía algoritmos genéticos. Unac.edu.pe. <https://hdl.handle.net/20.500.12952/7930>
- Remenieras, G. (1974). Tratado de hidrología aplicada. Editores Asociados, S.A. 2ª ed Barcelona España.
- Sánchez, F. J. (2022). Hidrología Superficial y Subterránea. 2ª ed. Kindle Direct Publishing., 440 pp.
- Tetumo García, J. (1993). Apuntes de hidrología superficial. Tesis de ingeniería en irrigación. Universidad Autónoma de Chapingo. Departamento de Irrigación, Chapingo, México.
- Thornthwaite, C. W. (1948). An approach toward a rational classification of climate. Geographical review, 38(1), 55-94.
- Vasquez Villanueva, A. (2000). Manejo de cuencas altoandinas (1a. ed.). LIMA: escuela superior de administración de aguas "Charles Sutton".
- World Vision (2004). Manual de Manejo de Cuencas: Módulo 7. Monitoreo y evaluación de manejo de cuencas, pp. 139 – 141. El Salvador

ANEXOS

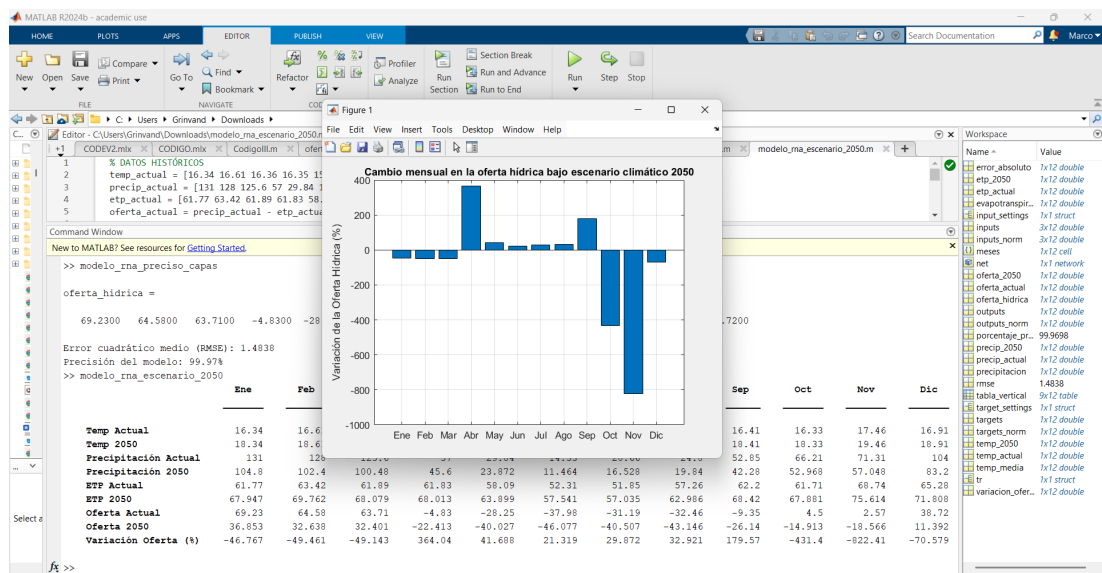
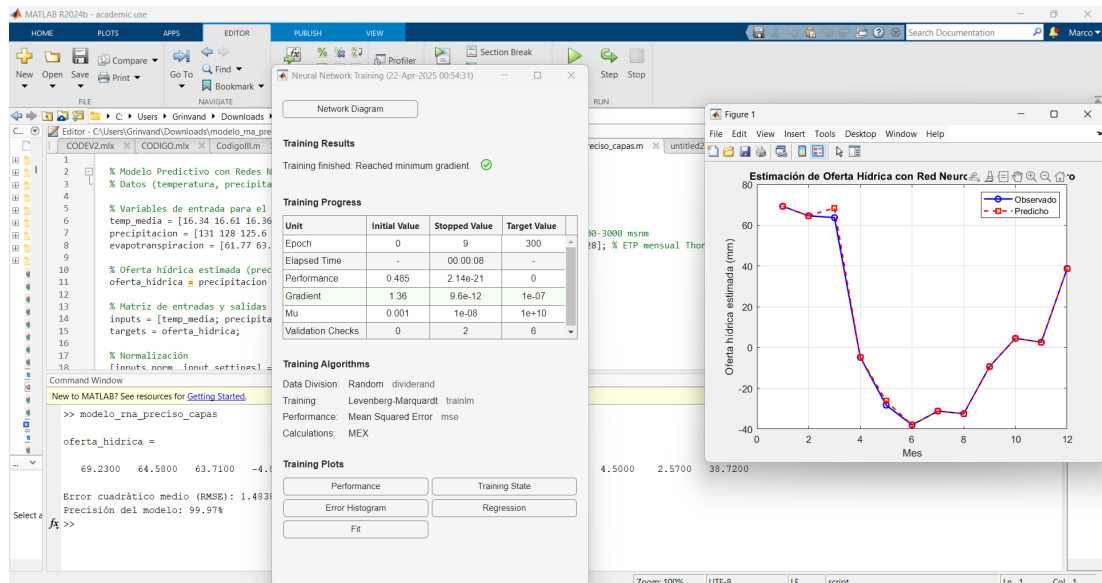
Anexo N°1: Matriz de consistencia

“MODELO PREDICTIVO DEL IMPACTO DEL CAMBIO CLIMÁTICO EN LA OFERTA HÍDRICA DE LA CUENCA MANTARO MEDIANTE REDES NEURONALES ARTIFICIALES, AYACUCHO”				
Problemas	Objetivos	Hipótesis	Variables	Metodologías
General	General	General	Variable Independiente	
¿De qué manera el desarrollo de un modelo predictivo basado en redes neuronales artificiales puede estimar con precisión el impacto del cambio climático en la oferta hídrica de la cuenca del río Mantaro?	Desarrollar un modelo predictivo basado en redes neuronales artificiales para estimar el impacto del cambio climático en la oferta hídrica de la cuenca del río Mantaro.	El desarrollo de un modelo predictivo basado en redes neuronales artificiales permitirá estimar de manera precisa el impacto del cambio climático en la oferta hídrica de la cuenca del río Mantaro, mejorando la capacidad de anticipar variaciones en la disponibilidad de agua.	Modelo predictivo del impacto del cambio climático. Dimensiones: <ul style="list-style-type: none"> • Precipitación • Temperatura • Evapotranspiración • Fenómenos climáticos extremos • Rendimiento del modelo predictivo 	El tipo de investigación es de tipo aplicada. El nivel de la investigación es explicativo. El diseño de la investigación es no experimental y transversal. La población del estudio comprende todos los datos climáticos e hidrológicos registrados en la cuenca del río Mantaro, incluyendo variables como precipitación, temperatura, evapotranspiración y caudales de los ríos. La muestra de este estudio está constituida por los datos hidrológicos y climáticos de la cuenca del río Mantaro, que abarcan el periodo comprendido desde el año 2020 en adelante.
Específicos	Específicos	Específicos	Variable Dependiente	
¿Cómo influye la precipitación, temperatura y evapotranspiración en la oferta hídrica de la cuenca del río Mantaro?	Evaluar el efecto de la precipitación, temperatura y evapotranspiración en la oferta hídrica de la cuenca del río Mantaro.	La precipitación, la temperatura y la evapotranspiración tienen un impacto significativo en la oferta hídrica de la cuenca del río Mantaro, y su correcta evaluación contribuirá a la precisión del modelo predictivo.	Oferta hídrica Dimensiones: <ul style="list-style-type: none"> • Volumen de agua 	
¿Cómo desarrollar un modelo predictivo basado en redes neuronales artificiales para estimar el volumen de agua disponible bajo diferentes escenarios climáticos?	Desarrollar un modelo predictivo con redes neuronales para estimar el volumen de agua disponible bajo escenarios climáticos.	El uso de redes neuronales artificiales permitirá desarrollar un modelo predictivo eficiente que estime con exactitud el volumen de agua disponible bajo diferentes escenarios climáticos.		
¿Qué tan preciso es el modelo predictivo desarrollado, según las métricas de precisión?	Validar el rendimiento del modelo predictivo mediante métricas de precisión.	El rendimiento del modelo predictivo basado en redes neuronales será validado mediante métricas de		

		precisión, demostrando su capacidad para generar predicciones confiables y exactas sobre la oferta hídrica.		
--	--	---	--	--

Nota. Elaboración propia

Anexo N°2. Simulaciones en Matlab





ACTA DE SUSTENTACIÓN DE TESIS N° 041-2025-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 N° 291-2025-FIMGC-D**, a los **veintitrés días del mes de septiembre de 2025**, siendo las **04:00 p.m.**, reunidos en el **Auditorio de la Escuela Profesional de Ingeniería Civil**, bajo la presidencia del **Ing. Ángel Hugo VILCHEZ PEÑA** y los miembros: **Ing. Saul Walter RETAMOZO FERNANDEZ**, **Edward LEON PALACIOS** y **Ing. Jaime Leonardo BENDEZÚ PRADO**, actuando como secretario docente el **Ing. Alex Sander IRCAÑAUPA HUAMANI**, para proceder a la sustentación de tesis para optar el **Título Profesional de Ingeniero Civil**, del bachiller: **EFRAIN FLORES HUAMAN**

Quien presentó la tesis denominada:

MODELO PREDICTIVO DEL IMPACTO DEL CAMBIO CLIMÁTICO EN LA OFERTA HÍDRICA DE LA CUENCA MANTARO MEDIANTE REDES NEURONALES ARTIFICIALES, AYACUCHO

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

Aprobado con QUINCE (15)

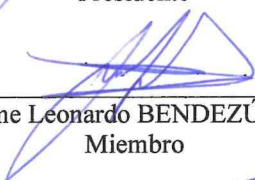
Siendo las **06:00 p.m.** del día **23 de septiembre de 2025**, culmina el acto de sustentación de tesis, y en conformidad con lo actuado, los miembros del jurado firman al pie del presente.




MSc. Ing. Ángel Hugo VILCHEZ PEÑA
Presidente



Ing. Saul Walter RETAMOZO FERNANDEZ
Miembro



Ing. Jaime Leonardo BENDEZÚ PRADO
Miembro



Ing. Edward LEON PALACIOS
Miembro - Asesor



Ing. Alex Sander IRCAÑAUPA HUAMANI
Secretario docente de la FIMGC



CONSTANCIA DE ORIGINALIDAD DE TRABAJO DE INVESTIGACIÓN

CONSTANCIA N° 025-2025-FIMGC/ASIH

El que suscribe; responsable verificador de originalidad de trabajos de tesis de pregrado con el software Turnitin, de la Escuelas Profesional de **Ingeniería Civil** de la **Facultad de Ingeniería de Minas, Geología y Civil**; en cumplimiento a la **Resolución de Consejo Universitario N° 039-2021-UNSCH-CU**, Reglamento de Originalidad de Trabajos de Investigación de la Universidad Nacional San Cristóbal de Huamanga y **Resolución Decanal N° 697-2024-FIMGC-UNSCH-D**, dejo constancia de originalidad de trabajo de investigación, que el/la Sr./Srta.

Apellidos y Nombres : Efrain FLORES HUAMAN
Escuela Profesional : INGENIERÍA CIVIL
Título de la Tesis : MODELO PREDICTIVO DEL IMPACTO DEL CAMBIO CLIMÁTICO EN LA OFERTA HÍDRICA DE LA CUENCA MANTARO MEDIANTE REDES NEURONALES ARTIFICIALES, AYACUCHO
Evaluación de la Originalidad : 19 % Índice de Similitud
Identificador de la entrega : 2810109175

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, 10 de noviembre 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

MODELO PREDICTIVO DEL IMPACTO DEL CAMBIO CLIMÁTICO EN LA OFERTA HÍDRICA DE LA CUENCA MANTARO MEDIANTE REDES NEURONALES ARTIFICIALES, AYACUCHO

por Efrain FLORES HUAMAN

Fecha de entrega: 10-nov-2025 01:55p. m. (UTC-0500)

Identificador de la entrega: 2810109175

Nombre del archivo: TE_Efrain_Flores_Huaman.pdf (1.55M)

Total de palabras: 24171

Total de caracteres: 133625

MODELO PREDICTIVO DEL IMPACTO DEL CAMBIO CLIMÁTICO EN LA OFERTA HÍDRICA DE LA CUENCA MANTARO MEDIANTE REDES NEURONALES ARTIFICIALES, AYACUCHO

INFORME DE ORIGINALIDAD



FUENTES PRIMARIAS

1	Submitted to Universidad Nacional de San Cristóbal de Huamanga Trabajo del estudiante	10%
2	pdfcookie.com Fuente de Internet	2%
3	qdoc.tips Fuente de Internet	1%
4	hdl.handle.net Fuente de Internet	1%
5	Submitted to Universidad Continental Trabajo del estudiante	<1%
6	Submitted to Universidad Nacional Federico Villarreal Trabajo del estudiante	<1%
7	repository.udca.edu.co Fuente de Internet	<1%
8	pdfcoffee.com Fuente de Internet	<1%
9	upcommons.upc.edu Fuente de Internet	<1%
10	dspace.ups.edu.ec Fuente de Internet	<1%
11	documentop.com	

Fuente de Internet

<1 %

12

repositorio.unapiquitos.edu.pe

Fuente de Internet

<1 %

13

tesis.unap.edu.pe

Fuente de Internet

<1 %

14

riuma.uma.es

Fuente de Internet

<1 %

15

Carcausto Quispe, Carlos. "Dinámica de la evapotranspiración en el área del lago Titicaca y en la frecuencia e intensidad de los episodios de sequía en la región de Puno ", Universidad Nacional del Altiplano de Puno (Peru)

Publicación

<1 %

16

es.slideshare.net

Fuente de Internet

<1 %

17

remexcu.org

Fuente de Internet

<1 %

18

www.scribd.com

Fuente de Internet

<1 %

19

Duarte, António Francisco Canatário. "Contaminación Difusa Originada Por la Actividad Agrícola de Riego, a la Escala de la Cuenca Hidrográfica", Instituto Politecnico de Castelo Branco (Portugal), 2024

Publicación

<1 %

20

repositorio.unfv.edu.pe

Fuente de Internet

<1 %

21

repositorioacademico.upc.edu.pe

Fuente de Internet

<1 %

22	Submitted to Universidad Nacional de Cajamarca Trabajo del estudiante	<1 %
23	repositorio.unal.edu.co Fuente de Internet	<1 %
24	repositorio.unitec.edu Fuente de Internet	<1 %
25	repositorio.upt.edu.pe Fuente de Internet	<1 %
26	Submitted to University of Newcastle upon Tyne Trabajo del estudiante	<1 %
27	Submitted to Universidad Carlos III de Madrid - EUR Trabajo del estudiante	<1 %
28	riunet.upv.es Fuente de Internet	<1 %
29	Submitted to Universidad de Cantabria Trabajo del estudiante	<1 %

Excluir citas

Activo

Excluir coincidencias < 30 words

Excluir bibliografía

Activo