

**UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL
DE HUAMANGA**

**FACULTAD DE INGENIERÍA DE MINAS GEOLOGÍA Y CIVIL
ESCUELA PROFESIONAL DE CIENCIAS FÍSICO MATEMÁTICAS**



TESIS:

**“Modelado de balance hídrico de la presa Cuchoquesera -
Ayacucho, mediante un algoritmo de machine learning”**

Para optar el título profesional de:
**LICENCIADO EN CIENCIAS FÍSICO MATEMÁTICAS.
ESPECIALIDAD DE FÍSICA**

PRESENTADO POR:
Bach. Marco Antonio CORDERO MANCILLA

ASESOR:
Mg. Wilmer MONCADA SOSA

AYACUCHO - PERÚ

2025

Dedicatoria

Dedico este trabajo primeramente a Dios,
por estar siempre presente en cada paso que doy,
y guiar mi camino en todo el paso de la Universidad.

A mis padres,
que fueron un apoyo en este camino y motivarme a no rendirme.

A mi asesor,
por orientarme y guiarme para el desarrollo de este trabajo de investigación

A mi familia y amigos,
quienes también me apoyaron y motivaron siendo una fuente de inspiración

Agradecimientos

A mis queridos docentes de la escuela profesional de Ciencias Físico Matemáticas y docentes en general de la Universidad Nacional de San Cristóbal de Huamanga, quienes, en cada paso de la vida universitaria, fueron un apoyo e inspiración, por el conocimiento que me brindaron en el trayecto para mejorar y aportar en la ciencia, y para mejorar en la sociedad.

Agradezco al Mg. Wilmer Moncada Sosa, por asesorarme y guiarme a realizar este proyecto de tesis, quien también me brindo su apoyo y conocimiento.

A los trabajadores de la Presa Cuchoquesera, por recibirnos amablemente a un viaje guiado a la presa, y quienes me proporcionaron los datos de la estación Cuchoquesera y Sunilla.

Al Ing. Dante Muchari Navarrete y al Ing. Jesús Cárdenas Rojas de la oficina de Operaciones y Mantenimiento OPEMAN del gobierno Regional de Ayacucho, quienes me recibieron amablemente y me brindaron los datos de la estación Cuchoquesera y Sunilla.

A mis padres, hermanos y familia, quienes me brindaron motivación a no rendirme y ser fuente de inspiración,

A mis queridos amigos y compañeros de la E.P. Ciencias físico matemáticas, quienes me apoyaron y me motivaron en todo este transcurso a los que siempre estaré agradecido.

Resumen

La presa Cuchoquesera es de gran importancia para la población dentro de la cuenca del río Cachi. Provee agua a la agricultura, ganadería, industria y consumo poblacional. La presente investigación tiene como objetivo desarrollar un modelo de balance hídrico mediante un algoritmo de Machine Learning, en la presa Cuchoquesera de la región Ayacucho. Para simular el Caudal de salida (Q_s), se tienen en cuenta el comportamiento natural del caudal de entrada (Q_{en}) y los parámetros hidrometeorológicos (PHM) de la estación Sunilla. Para ello se realiza un análisis de datos utilizando TensorFlow (Tf), que es un interfaz muy potente para realizar gráficos y predicciones en series temporales, de los PHM, Q_{en} y Q_s de la presa. Los resultados muestran un modelo del caudal simulado significativo con respecto al caudal observado, con fuertes indicadores de validación NSE (0.87), NSE-Ln (0.83), Pearson (0.94), R^2 (0.87); con errores de incerteza RMSE (0.24), Bias (0.99), RVB (0.01), NPE (0.01) y PBIAS (0.14). Por lo tanto, las pérdidas por evaporación e infiltración desde el 2019 hasta el 2023, presentan un crecimiento significativo con tendencia positiva, donde el Q_{en} es ligeramente mayor que el Q_s simulado.

Palabras Clave: Balance hídrico, Parámetros hidrometeorológicos, Machine Learning, TensorFlow, Caudal de salida, Cuchoquesera.

Abstract

The Cuchoquesera dam is of great importance for the population within the Cachi river basin. It provides water for agriculture, livestock, industry and population consumption. The present research aims to develop a water balance model using a Machine Learning algorithm in the Cuchoquesera dam in the Ayacucho region. To simulate the outflow (Q_s), the natural behavior of the inflow (Q_{en}) and the hydrometeorological parameters (PHM) of the Sunilla station are taken into account. For this purpose, a data analysis is performed using TensorFlow (Tf), which is a very powerful interface to perform graphs and time series predictions of the PHM, Q_{en} and Q_s of the dam. The results show a significant simulated flow model with respect to the observed flow, with strong validation indicators NSE (0.87), NSE-Ln (0.83), Pearson (0.94), R2 (0.87); with uncertainty errors RMSE (0.24), Bias (0.99), RVB (0.01), NPE (0.01) and PBIAS (0.14). Therefore, evaporation and infiltration losses from 2019 to 2023, present a significant growth with positive trend, where Q_{en} is slightly higher than the simulated Q_s .

Key words: Water balance, Hydrometeorological parameters, Machine Learning, TensorFlow, Outflow, Cuchoquesera.

Índice

Dedicatoria.....	i
Agradecimientos	ii
Resumen.....	iii
Abstract.....	iv
Índice.....	v
Índice de tablas	x
Índice de Figuras.....	xi
INTRODUCCIÓN	1
I. Planteamiento del Problema	4
1.1. Descripción de la situación problemática.	4
1.2. Formulación del problema	5
1.2.1. Problema General.	5
1.2.2. Problemas específicos.	6
1.3. Formulación de objetivo	6
1.3.1. Objetivo General.....	6
1.3.2. Objetivos Específicos	6
1.4. Justificación (teórica, práctica y metodológica).....	7
1.4.1. Justificación teórica.	7
1.5. Justificación práctica.....	8

1.5.1. Justificación metodológica.	8
II. Marco Teórico.....	10
2.1. Antecedentes	10
2.2. Bases teóricas	13
2.2.1. Machine Learning	13
2.2.2. Tipos de aprendizaje de Machine Learning.	14
2.2.3. Ciclo Hidrológico	17
2.2.4. Sistema Hidrológico.	19
2.2.5. Parámetros Hidrológicos.	20
2.3. Bases conceptuales.....	29
2.3.1. Balance hídrico	29
2.3.2. Redes Neuronales Artificial (RNA)	33
2.3.3. Construcción e implementación de las RNA	34
2.3.4. TensorFlow	45
III. Hipótesis y Variables	48
3.1. Formulación de hipótesis	48
3.1.1. Hipótesis generales.	48
3.1.2. Hipótesis específicas.	48
3.2. Variables	48
3.2.1. Variable independiente:	48
3.2.2. Variable dependiente:	49

3.3. Operacionalización de variables	50
IV. Metodología.....	52
4.1. Tipo y nivel de investigación	52
4.1.1. Tipo de investigación.	52
4.1.2. Nivel de investigación.....	52
4.2. Ubicación Geográfica.....	52
4.3. Métodos.....	54
4.3.1. Método de investigación.	54
4.4. Diseño de investigación	58
4.5. Población y muestra	58
4.5.1. Universo.	58
4.5.2. Población.....	58
4.5.3. Muestra.	58
4.6. Técnicas e instrumentos	58
4.6.1. Técnicas.....	58
4.6.2. Instrumentos.....	59
4.6.3. Fuentes.	60
4.7. Validez y confiabilidad de instrumentos.....	60
4.8. Técnicas de procesamiento de datos	60
4.9. Aspectos éticos.....	61
V. Resultados y discusión.....	63

5.1. Comportamiento de los parámetros climáticos e hidrológicos medidos en la estación hidrometeorológica que influyen en el embalse de la presa Cuchoquesera.	63
5.1.1. Descripción del comportamiento temporal de la Precipitación en la Presa Cuchoquesera.....	65
5.1.2. Descripción del comportamiento temporal de la Velocidad de viento en la Presa Cuchoquesera.	74
5.1.3. Descripción del comportamiento temporal de la Evaporación de tanque de agua en la Presa Cuchoquesera.....	77
5.1.4. Descripción del comportamiento temporal de la Humedad Relativa en la Presa Cuchoquesera.....	86
5.1.5. Descripción del comportamiento temporal de la Nubosidad en la Presa Cuchoquesera.....	93
5.1.6. Descripción del comportamiento temporal de la Temperatura mínima en la Presa Cuchoquesera.	101
5.1.7. Descripción del comportamiento temporal de la Temperatura máxima en la Presa Cuchoquesera.	109
5.1.8. Descripción del comportamiento temporal de la Temperatura ambiente en la Presa Cuchoquesera.	117
5.1.9. Descripción del comportamiento temporal del Caudal de entrada en la Presa Cuchoquesera.....	125
5.1.10. Descripción del comportamiento temporal del Caudal de salida en la Presa Cuchoquesera.....	134

5.2. Modelo de simulación del balance hídrico mediante un algoritmo de Machine Learning, en la presa Cuchoquesera.....	144
5.3. Tendencia mensual y anual del caudal de entrada y salida en el embalse de la presa Cuchoquesera, a partir del modelo de balance hídrico mediante el algoritmo de Machine Learning.....	156
5.4. Estimación de la pérdida de embalsamiento de la presa Cuchoquesera, a partir del Balance Hídrico.	158
Discusión de resultados.....	160
Conclusiones.....	163
Recomendaciones	164
Referencia bibliografica.....	165
Lista de abreviaturas	170
Anexo A.....	171
Matriz de consistencia.....	171
Anexo B	173
Código para construcción de series temporales estructurales con Tensor Flow	173
Anexo C	1739
Código para construcción del Balance Hídrico.....	179
Anexo D.....	183

Índice de tablas

Tabla 1. Estimación de valores de la nubosidad	27
Tabla 2. Puntos de Coordenadas de la ubicación de la Presa Cuchoquesera.....	54
Tabla 3. Datos de los parámetros hidrometeorológicos ordenados por día	64
Tabla 4. Caudales de entrada diarios registrados en el mes de enero del 2020	125
Tabla 5. Caudales de salida diarios de la Presa Cuchoquesera registrados en el mes de junio del 2015.....	134
Tabla 6. Resultados de correlaciones y errores para el caudal simulado con el observado	154

Índice de Figuras

Figura 1. Esquema generalizado sobre Machine Learning.....	17
Figura 2. Ciclo hidrológico del agua.....	18
Figura 3. Sistema del ciclo hidrológico	19
Figura 4. Ciclo de esorrentía	21
Figura 5. Limnmetro	23
Figura 6. Válvula Howell Bunger.....	23
Figura 7. Caseta de válvulas para el control de descarga del embalse	24
Figura 8. Sensor de temperatura	26
Figura 9. Esquema del balance hídrico en una determinada región	31
Figura 10. Esquema de balance hídrico para la presa Cuchoquesera	33
Figura 11. Esquema del funcionamiento de un perceptrón.....	36
Figura 12. Esquema de funcionamiento de ADALINE	37
Figura 13. Gráfico de descenso de gradiente.....	38
Figura 14. Diagrama de una red neuronal multicapa.....	41
Figura 15. Interacción de las capas neuronales.....	45
Figura 16. Ubicación geográfica de la Presa Cuchoquesera.....	53

Figura 17. Diagrama de flujo metodológico del proceso de simulación del Balance Hídrico.....	57
Figura 18. Planilla de los parámetros hidrometeorológicos de la presa Cuchoquesera	59
Figura 19. Estación de Sunilla, ubicado 200 m de la presa Cuchoquesera.....	61
Figura 20. Series temporales diaria de todos los parámetros hidrometeorológicos medidos en la estación meteorológica Cuchoquesera	65
Figura 21. Serie temporal de los datos diarios de entrenamiento de la precipitación desde el año 2013 al 2021	66
Figura 22. Minimización de la perdida variacional diarios de la precipitación.....	67
Figura 23. Minimización de la perdida variacional mensuales de la precipitación	68
Figura 24. Minimización de la perdida variacional anuales de la precipitación.....	68
Figura 25. Predicción de la precipitación diario de la presa Cuchoquesera	69
Figura 26. Tendencia y estacionalidad diarios de la precipitación	70
Figura 27. Predicción de la precipitación de la presa Cuchoquesera mensuales	71
Figura 28. Tendencia y estacionalidad mensuales de la precipitación	72
Figura 29. Predicción de la precipitación de la presa Cuchoquesera anuales.....	73
Figura 30. Tendencia y estacionalidad anuales de la precipitación	74
Figura 31. Minimización de la perdida variacional de la precipitación.....	75
Figura 32. Predicción de la Velocidad de viento de la presa Cuchoquesera por día ...	76

Figura 33. Tendencia y estacionalidad diarios de la velocidad de viento.....	77
Figura 34. Minimización de la perdida variacional diarios de la Evaporación	78
Figura 35. Minimización de la perdida variacional mensuales de la Evaporación.....	79
Figura 36. Minimización de la perdida variacional anuales de la Evaporación	79
Figura 37. Predicción de la Evaporación de la presa Cuchoquesera por día	80
Figura 38. Tendencia y estacionalidad diarias de la Evaporación de agua.....	81
Figura 39. Predicción de la Evaporación de la presa Cuchoquesera por Mes	82
Figura 40. Tendencia y estacionalidad mensuales de la Evaporación de agua.....	83
Figura 41. Predicción de la Evaporación de la presa Cuchoquesera por Año	84
Figura 42. Tendencia y estacionalidad Anuales de la Evaporación de agua	85
Figura 43. Minimización de la perdida variacional diarios de la humedad relativa. ...	86
Figura 44. Minimización de la perdida variacional mensuales de la humedad relativa	87
Figura 45. Minimización de la perdida variacional anuales de la humedad relativa...	87
Figura 46. Predicción de la Humedad Relativa de la presa Cuchoquesera por día	88
Figura 47. Tendencia y estacionalidad diarios de la Humedad Relativa	89
Figura 48. Predicción de la Humedad Relativa de la presa Cuchoquesera por mes....	90
Figura 49. Tendencia y estacionalidad mensuales de la Humedad Relativa	91
Figura 50. Predicción de la Humedad Relativa de la presa Cuchoquesera por año.....	92

Figura 51. Tendencia y estacionalidad anuales de la Humedad Relativa	93
Figura 52. Minimización de la perdida variacional diarios de la Nubosidad	94
Figura 53. Minimización de la perdida variacional mensuales de la Nubosidad.....	95
Figura 54. Minimización de la perdida variacional anuales de la Nubosidad	95
Figura 55. Predicción de la Nubosidad de la presa Cuchoquesera por día	96
Figura 56. Tendencia y estacionalidad diarios de la Nubosidad.....	97
Figura 57. Predicción de la Nubosidad de la presa Cuchoquesera por mes	98
Figura 58. Tendencia y estacionalidad mensual de la Nubosidad	99
Figura 59. Predicción de la Nubosidad de la presa Cuchoquesera por año	100
Figura 60. Tendencia y estacionalidad anual de la Nubosidad	101
Figura 61. Minimización de la perdida variacional diarios de la temperatura mínima	102
Figura 62. Minimización de la perdida variacional mensuales de la temperatura mínima	103
Figura 63. Minimización de la perdida variacional anuales de la temperatura mínima	103
Figura 64. Predicción de la Temperatura mínima de la presa Cuchoquesera por día	104
Figura 65. Tendencia y estacionalidad diarios de la temperatura mínima.....	105
Figura 66. Predicción de la Temperatura mínima de la presa Cuchoquesera por mes	106

Figura 67. Tendencia y estacionalidad mensuales de la temperatura mínima	107
Figura 68. Predicción de la Temperatura mínima de la presa Cuchoquesera por año	108
Figura 69. Tendencia y estacionalidad anuales de la temperatura mínima.....	109
Figura 70. Minimización de la pérdida variacional diarios de la temperatura máxima	110
Figura 71. Minimización de la pérdida variacional mensuales de la temperatura máxima	111
Figura 72. Minimización de la pérdida variacional anuales de la temperatura máxima	111
Figura 73. Predicción de la Temperatura máxima de la presa Cuchoquesera por día	112
Figura 74. Tendencia y estacionalidad diarios de la temperatura máxima	113
Figura 75. Predicción de la Temperatura máxima de la presa Cuchoquesera por mes	114
Figura 76. Tendencia y estacionalidad mensuales de la temperatura máxima	115
Figura 77. Tendencia y estacionalidad anuales de la temperatura máxima	116
Figura 78. Tendencia y estacionalidad anuales de la temperatura máxima	117
Figura 79. Minimización de la perdida variacional diarios de la temperatura ambiente	118

Figura 80. Minimización de la pérdida variacional mensuales de la temperatura ambiente.....	118
Figura 81. Minimización de la pérdida variacional anuales de la temperatura ambiente	119
Figura 82. Predicción de la Temperatura ambiente de la presa Cuchoquesera por día	120
Figura 83. Tendencia y estacionalidad diarios de la temperatura ambiente	121
Figura 84. Predicción de la Temperatura ambiente de la presa Cuchoquesera por mes	122
Figura 85. Tendencia y estacionalidad mensuales de la temperatura ambiente	123
Figura 86. Predicción de la Temperatura ambiente de la presa Cuchoquesera por año	124
Figura 87. Tendencia y estacionalidad anuales de la temperatura ambiente	125
Figura 88. Minimización de la pérdida variacional diarios del caudal de entrada.. ..	127
Figura 89. Minimización de la pérdida variacional mensuales del caudal de entrada	128
Figura 90. Minimización de la pérdida variacional anuales del caudal de entrada. ..	128
Figura 91. Predicción del caudal de entrada a la presa Cuchoquesera por día	129
Figura 92. Tendencia y estacionalidad diarios del caudal de entrada.....	130
Figura 93. Predicción del caudal de entrada a la presa Cuchoquesera por mes.....	131

Figura 94. Tendencia y estacionalidad mensuales del caudal de entrada	132
Figura 95. Predicción del caudal de entrada a la presa Cuchoquesera por año	133
Figura 96. Tendencia y estacionalidad anuales del caudal de entrada	134
Figura 97. Minimización de la pérdida variacional diario del caudal de salida	136
Figura 98. Minimización de la pérdida variacional mensual del caudal de salida	137
Figura 99. Minimización de la pérdida variacional anual del caudal de salida	138
Figura 100. Predicción del caudal de salida de la presa Cuchoquesera por día.....	139
Figura 101. Tendencia y estacionalidad diarios del caudal de salida	140
Figura 102. Predicción del caudal de salida de la presa Cuchoquesera por mes	141
Figura 103. Tendencia y estacionalidad mensuales del caudal de salida	142
Figura 104. Predicción del caudal de salida de la presa Cuchoquesera por año.....	143
Figura 105. Tendencia y estacionalidad anuales del caudal de salida	144
Figura 106. Diagrama de flujo del funcionamiento del MLP	146
Figura 107. Resultados del algoritmo con Machine Learning para el modelado del Balance Hídrico en la presa Cuchoquesera.....	152
Figura 108. Tendencia lineal del Caudal Simulado (Qsim) vs Caudal observado (Qobs)	154
Figura 109. Tendencia mensual del caudal de entrada y caudal de salida simulada en la presa Cuchoquesera mediante serie temporales.....	156

Figura 110. Tendencia anual del caudal de entrada vs el caudal de salida simulado en la presa Cuchoquesera mediante serie temporales	157
Figura 111. Perdida de embalsamiento de agua de la presa Cuchoquesera del caudal simulado y observado con el caudal de entrada	158
Figura 112. Visita guiada a la presa Cuchoquesera	183
Figura 113. Instrumentos de medición deteriorados.....	184
Figura 114. Caseta de válvulas, para monitorear el paso del caudal de salida	185
Figura 115. Sala de control de la presa Cuchoquesera	186
Figura 116. Sala de control para dar paso al agua por compuertas.....	186
Figura 117. Mapa guía de la presa Cuchoquesera	187
Figura 118. Estación de Sunilla	188
Figura 119. Tanque de evaporación.....	189
Figura 120. Control automatizado para datos hidrometeorológicos.....	190
Figura 121. Caseta para proteger los termómetros de temperatura mínima y máxima	191

INTRODUCCIÓN

En el presente trabajo de investigación, se utiliza conceptos físicos fundamentales relacionados con el comportamiento del flujo hídrico, desde su captación hasta su recorrido final al embalse de la presa, para lo cual es primordial desarrollar un modelo de balance hídrico de la presa Cuchoquesera mediante un algoritmo de Machine Learning (Dashti Latif et al., 2021).

El modelo es alimentado mediante datos de entrada registrados en la estación hidrometeorológica Sunilla ubicada en la zona circundante a la presa Cuchoquesera. Los datos registrados en la estación Sunilla corresponden a la evaporación, nubosidad, precipitación, temperatura máxima y mínima, velocidad, dirección del viento, volumen de almacenamiento inicial y final en la presa; y el caudal de entrada y salida a la presa Cuchoquesera desde el año 2013 al 2023.

El uso de las técnicas de Machine Learning (López-Tapia et al., 2021; Melo et al., 2022), permite desarrollar un balance de masa en el embalse de la presa Cuchoquesera, a la vez que se llega observar como el comportamiento de los parámetros hidrometeorológicos, caudal de entrada y caudal de salida de la presa, para desarrollar un análisis sobre el volumen de almacenamiento, para realizar una proyección futura del comportamiento del caudal de salida para efectos de los próximos años, así como la estimación de las pérdidas de agua. Los resultados logrados en esta investigación generarán la fundamentación científica necesaria para afrontar el problema de escasez del agua en los próximos años en la zona influyente a la presa Cuchoquesera.

Para construir el modelo de balance hídrico es preciso alimentarlos con datos medidos in situ o basados en la detección remota, con componentes claves derivados a través de algoritmos de Machine Learning, lo que proporciona nuevos conocimientos sobre el ciclo

hidrológico, contribuyendo a una mejor gestión del agua (Qian et al., 2024). Con la finalidad de lograr los objetivos propuestos, se usa softwares libres como Python y R, para un análisis profundo de datos a través de librerías integradas para implementar Redes Neuronales Artificiales (RNA) y TensorFlow (TF).

Algunos modelos de balance hídrico incluyen módulos, como el de optimización de asignación de agua y pronóstico de los componentes del suelo, además del uso de algoritmos genéticos para la identificación de tasas óptimas de aplicación de agua al cultivo en función del tipo de cultivo, etapa de crecimiento y sensibilidad al estrés hídrico (Hassan-Esfahani et al., 2015).

Sin embargo, la problemática abordada en el presente investigación requiere la optimización de agua suministrada al embalse en épocas de lluvias, y además del análisis de datos provenientes de la estación hidro-meteorológica Sunilla, para la identificación de tasas óptimas de aplicación en el caudal de salida; por otro lado, las pérdidas por evaporación e infiltración y sus efectos futuros sobre el embalse en diferentes escenarios, tienen la finalidad de evitar riesgos y desastres como la escasez de agua, que afectarían a zonas agrícolas, ganaderas, consumo humano, centros poblados e infraestructuras ubicadas aguas abajo de la misma, que se consideran eventos catastróficos y perjudiciales tanto en la economía como pérdidas humanas, consolidándose el agua como el recurso natural más valioso de la Tierra que desempeña un papel fundamental en el desarrollo socioeconómico de los seres humanos en todo el mundo.

Por otro lado, el cambio climático afecta a las diferentes temporadas del ciclo del agua a través de los años, por ello es importante mencionar como el ciclo hidrológico afecta al modelar el balance hídrico, mayormente se debe a que los parámetros de estudio varían en diferentes estaciones del año (primavera, otoño, verano e invierno). Mediante el presente

trabajo de investigación, se busca que los datos registrados por la estación hidro-meteorológica sean confiables y precisos para realizar un análisis de fundamentos físicos e interpretación de gráficos de tendencia temporal, es decir, por la variedad de las temporadas climáticas marcadas por la humedad y climas secos.

En ese sentido, las herramientas de Machine Learning en las últimas décadas, se han aplicado ampliamente a diversos campos relacionados a la gestión de los recursos hídricos, de los cuales, mostraron resultados prometedores y para mejorar los sistemas de apoyo a la toma de decisiones en diversos sectores como las aguas subterráneas, la previsión del caudal de los ríos, embalses, sistemas de distribución de agua, calidad del agua, tratamiento de las aguas residuales, demanda y consumo de agua, la energía hidroeléctrica y marina, los sistemas de drenaje de agua; la gestión y defensa contra las inundaciones, entre otros (Ahmed et al., 2024).

Con el objetivo de desarrollar un modelo de balance hídrico mediante un algoritmo de Machine Learning, en la presa Cuchoquesera de la región Ayacucho, es preciso realizarlo a través de las siguientes etapas: primero se asigna los datos de la estación hidro-meteorológica de Sunilla al modelo como desembalse de la presa o caudal de salida, el caudal de entrada, la precipitación y evaporación, etc, de los cuales para el entrenamiento se usa (ejemplo, los años 2013 al 2019). Segundo, para la prueba del se utiliza los años restantes (por ejemplo, los años 2022 y 2023). Tercero, se escogen una de las funciones de transferencia como log-sigmoide, tan-sigmoide y pure-line de la RNA del modelo. Por último, se escoge la cantidad de capas ocultas y las neuronas basándose en el índice de rendimiento del error; de esta manera se logra obtener los resultados de caudal de salida simulados mediante el cálculo del balance de masas utilizando las RNA.

I. Planteamiento del Problema

1.1. Descripción de la situación problemática.

La presa Cuchoquesera, se encuentra ubicado en el distrito de Chuschi, de la provincia de Cangallo en la región de Ayacucho, que proviene de la cuenca del río Cachi (Apacheta, Choccoro y Chicllarazo), siendo una de las más importantes a nivel de la sierra peruana, y principalmente de la región de Ayacucho, dado que esta presa provee el consumo de agua potable en la provincia de Huamanga y demás anexos, y la agricultura en las comunidades cercanas a la presa.

El almacenamiento de esta presa, registra en temporada de lluvias y por el aumento de caudal de los ríos, un volumen máximo hasta 80 millones de m³; y mientras que en periodos de estiajes y sequias hasta 39,5 millones de m³, estos datos son reportados por la Autoridad Nacional del Agua (ANA).

La presa tiene más de 20 años desde su construcción y funcionamiento, por ende, esta propenso a sufrir deterioros por la antigüedad de la misma de la cual se requiere una inversión para su mantenimiento; y, por otro lado, el agua almacenada de la presa, es distribuida la mayor parte para la agricultura en los distritos de Acocro, Chiara, Vinchos, Cangallo y Chuschi, siendo en el año 2023 que se llega a destinar un estimado de 42 millones de m³; y 18 millones de m³ para el consumo de agua en la provincia de Huamanga y demás anexos aproximadamente, siendo un total de 60 millones de m³ estimada para la distribución de este recurso vital, además que para mayo del año 2024 OPEMAN reporto que el almacenamiento fue de 79 millones de m³.

La presa Cuchoquesera es de vital importancia para la población inmersa en la cuenca del río Cachi, hasta la fecha no hay estudios ni investigaciones realizadas para la estimación de las proyecciones de caudal de entrada y salida a partir de un balance de masa, por lo que es

necesario conocer las características meteorológicas e hidrológicas de la presa como, precipitación, caudal de entrada y salida, evaporación, transpiración e infiltración en los canales y depósitos de agua subterránea, que influyen en la permanencia del embalse óptimo de la presa. Por esta razón, un balance de masa en la presa Cuchoquesera permite evaluar la disponibilidad espacial y temporal del agua y su proyección futura en diferentes escenarios climáticos, resultando útil para la gestión, asignación y control de flujo de agua disponible para consumo poblacional, industrial, irrigación de áreas agrícolas y ganaderas (Cavero, 2013).

En ese sentido, se puede construir un modelo de balance hídrico a partir de los datos que se registran en la presa, haciendo uso de nuevas metodologías como son las técnicas de Machine Learning para la mejora de la información y visualización de manera inmediata de los problemas que ocurren por la falta de agua o por derrumbes en canales hídricos que están vinculados a la presa, entre otros aspectos ligados al buen desempeño de la presa.

Teniendo en cuenta el comportamiento temporal de los datos de caudal, precipitación, almacenamiento, temperatura máxima y mínima del aire y la evaporación del espejo de agua, es conveniente realizar un Balance Hídrico en la presa Cuchoquesera en la región Ayacucho, mediante algoritmos de Machine Learning para la realización de un modelado hídrico del comportamiento del embalse, con la construcción de escenarios futuros y pronósticos de volumen de agua almacenado.

1.2. Formulación del problema

1.2.1. Problema General.

- ¿En qué medida un algoritmo de Machine Learning permite el desarrollo de un modelo de balance hídrico de la presa Cuchoquesera, en la región Ayacucho?

1.2.2. Problemas específicos.

- ¿Cuál es el comportamiento de los parámetros climáticos e hidrológicos, medidos en la estación hidro-meteorológica Sunilla, que influyen en el embalse de la presa Cuchoquesera?
- ¿Cuál es el algoritmo de Machine Learning que permite la construcción idónea de un modelo de balance hídrico en la presa Cuchoquesera?
- ¿Cuál es la tendencia anual del caudal de entrada y salida en el embalse de la presa Cuchoquesera, a partir del modelo de balance hídrico mediante un algoritmo de Machine Learning?
- ¿Cuánto es la pérdida de embalsamiento de la presa Cuchoquesera, a partir del Balance hídrico?

1.3. Formulación de objetivo

1.3.1. Objetivo General.

- Desarrollar un modelo de balance hídrico mediante un algoritmo de Machine Learning, en la presa Cuchoquesera de la región Ayacucho.

1.3.2. Objetivos Específicos

- Determinar el comportamiento de los parámetros climáticos e hidrológicos medidos en la estación hidro-meteorológica Sunilla que influyen en el embalse de la presa Cuchoquesera.
- Construir un modelo de simulación del balance hídrico mediante un algoritmo de Machine Learning, en la presa Cuchoquesera.
- Estimar la tendencia anual del caudal de entrada y salida en el embalse de la presa Cuchoquesera, a partir del modelo de balance hídrico mediante el algoritmo de Machine Learning.

- Estimar la pérdida de embalsamiento de la presa Cuchoquesera, a partir del Balance Hídrico.

1.4. Justificación (teórica, práctica y metodológica)

1.4.1. Justificación teórica.

Actualmente, el problema del agua a nivel mundial, según (Osso Rodríguez et al., 2017); manifiesta que en cada año existe escasez de agua entre otros problemas inmersos, y que sin este recurso importante se podría llegar al desarrollo de una guerra para la dominación de este recurso, por ello, se busca alternativas de soluciones para controlar y resolver problemas de este recurso, el mismo autor en su artículo menciona que en diferentes países utilizan modelos de balance hídrico, que vienen dando buenos resultados.

Asimismo, Van Dam y Feddes (2000), citados por Osso Rodríguez et al. (2017), explican “que la infiltración, evaporación y el flujo de agua subterránea pueden ser evaluados y cuantificados, teniendo en cuenta el volumen de agua y los sedimentos que afectan el comportamiento del flujo” (p. 232), empleando el diseño de modelamiento de balance hídrico con la simulación de Monte Carlo en Colombia. Esta metodología de balance hídrico permite conocer el comportamiento del flujo de aguas superficial y subsuperficial, realizando un monitoreo constante de la disponibilidad de agua, la misma que se puede aplicar en la presa Cuchoquesera, entrenando los datos de caudal de entrada y salida con Machine Learning.

La inteligencia artificial (IA), está revolucionando a nivel mundial en diferentes rubros de la sociedad como tecnología, mercados, empresas, en la ciencia físicas y biomédicas, etc. para desarrollar procesos críticos de manera más eficiente como el análisis de datos y obtener predicciones cerca a la realidad, con la finalidad de mejorar significativamente dicha capacidad.

Sin embargo, Alonso (2021) menciona que “el machine learning es un subconjunto de la IA para reconocer patrones basados en datos y hacer predicciones” (párr. 17). También conocido en español como máquina de aprendizaje, esta característica ayuda a los ordenadores con algoritmos a que puedan resolver mediante el aprendizaje automático de los errores y resolver cosas sin que las tengan programadas explícitamente.

1.5. Justificación práctica.

Al conocer el embalse, mediante el caudal de salida y el almacenamiento volumétrico de la presa Cuchoquesera mediante el modelado de balance hídrico, se logrará también el de prevenir eventos de riesgo futuros como la prevención sobre la escasez de agua, o si se debería ponerse en mantenimiento por el embalse de crecida, para evitar la destrucción de la presa, y ayudar al buen uso medido y equilibrado para la parte de irrigación de campos de agricultura cerca de la presa por los pobladores.

Al prevenir estos eventos, se beneficiará a la población cercana de los pueblos aledaños a la presa como a la población de la provincia de Huamanga y sus diferentes distritos para que el recurso de agua potable permanezca en el tiempo.

1.5.1. Justificación metodológica.

El modelado de balance hídrico de la presa Cuchoquesera mediante técnicas de Machine Learning, se pretende que:

- Trabajos e investigaciones futuras aplicadas a la física, se desarrollen mediante nuevos métodos basados en inteligencia artificial, con la finalidad de adentrarse en la aplicación con estas técnicas y desarrollar un avance científico de nuestra carrera que beneficien al estudiante que quieran adentrarse en este tema y desarrollar artículos científicos para el conocimiento y ayuda a nuestra sociedad.

- La presente investigación de balance hídrico, se desarrolla un modelo predictivo del comportamiento de caudal de entrada y salida, y volumen de almacenamiento de la presa, y que sean de ayuda para investigaciones relacionados a la parte del estudio hidrológico y sea aplicada en otros campos.

II. Marco Teórico

2.1. Antecedentes

Al respecto con la investigación y aplicaciones de balance hídrico que se realizaron en el ámbito nacional e internacional aplicando las diferentes técnicas incluidas las de machine learning con uso de redes neuronales, se tiene:

Osso Rodríguez et al. (2017), emplearon un modelo de balance hídrico utilizando la técnica de simulación de Montecarlo, afirmando que es el método más adecuado para proporcionar agua potable a la ciudad de Tunja, Colombia, alrededor de un periodo aproximado de 40 años. Este modelo permite ajustar variables como la precipitación, la infiltración, la escorrentía, la evapotranspiración y el caudal subterráneo y de extracción, convirtiéndole en variables aleatorias. De esta manera, se pueden modelar los flujos de entrada y salida como variables estocásticas¹. Los autores concluyen que el modelo utilizado puede servir como un método complementario al diseño de eventos, aumentando el grado de confiabilidad de las proyecciones de oferta de balance hídrico.

Fathian et al. (2019), utilizaron las series temporales y la Inteligencia artificial para mejorar la predicción del caudal mensual del río en las estaciones Branrford y Galt en Grand River, Canadá donde los datos usados son desde octubre de 1948 hasta septiembre de 2017. Se emplea el análisis de series temporales como el SETAR y GARCH, y por el lado de la inteligencia artificial el ANN, MARS y RF. También, utilizaron los modelos híbridos que son la combinación de las series temporales y la inteligencia artificial encontrando que tienen mejor rendimiento a comparación de los modelos independientes. Concluyen que el modelo de mejor

¹ Son variables que toman diferentes valores con ciertas probabilidades. Estas variables están definidas por el conjunto de valores posibles que puede tener (rango, conjunto de estados, espacio muestral, o espacio fásico) y una distribución de probabilidad asociada a estos valores. (Vaisman Bacall, 2007, p. 120)

rendimiento y precisión es RF-SETAR, y en la fase de prueba el mejor modelo es el MARS-SETAR.

Dashti Latif et al. (2021), utilizaron las redes neuronales para encontrar un modelo de previsión de pérdida de agua en las Presas de Malasia con los datos recopilados de Klang Gate desde 1997-2007 como el flujo de entrada, la afluencia, descarga de presa, almacenamiento inicial y final del reservorio. El modelo, predice o estima la pérdida de agua, el almacenamiento final y el nivel de agua para el futuro, por lo que se anticipa que la operación del embalse pueda mejorarse. Pero encontraron, que el modelo proporciona un pronóstico mensual con error cuadrático medio máximo de $\pm 20.07\%$, el error absoluto promedio del 23.47% y el error cuadrático medio de 26.15% , debido a la falta de datos y por error de estas mismas por las neuronas artificiales.

Hurtado Asto (2019), en su trabajo de investigación, desarrollo un análisis hidrológico y de disponibilidad hídrica con el objetivo de estimar las características y necesidades de una **presa de Relaves**² en Pataz, La Libertad. Inicialmente, identifiqué una ubicación adecuada para la presa, fuera de la zona poblacional, para evitar riesgos asociados con desechos mineros, para evitar riesgos asociados con desechos mineros y mantener el curso natural del agua.

Una vez seleccionada la ubicación de la presa de Relaves, analizo la red de la estación pluviométrica y meteorológica, para cuantificar los datos de entrada y salida, para luego realizar un tratamiento para los cálculos y análisis respectivos, obteniendo los parámetros de estudio como el caudal para un periodo de retorno de 100 años y la evapotranspiración potencial.

² Se utilizan para almacenar el agua y los desechos derivados del proceso de extracción como minería.

Los parámetros recopilados fueron ingresados en el modelo WEAP, con el cual obtuvo los caudales simulados correspondientes a la cuenca aportante. Finalmente; utilizando los datos obtenidos de la cuenca y considerando los procesos propios de la generación de relaves, realizó el balance hídrico, obteniendo que los volúmenes de entrada superan consistentemente a los volúmenes de salida en todos los meses, debido a las características climáticas y a las medidas de impermeabilización implementadas.

Luque Mamani (2018), para su investigación en recursos hídricos para pronósticos de variable hidrológicas y variables para reducir pérdidas tanto económicas y sociales, utiliza una red neuronal denominado Echo State Network (ESN), que a partir de ciertas propiedades algebraicas entrena los datos de la capa de salida del flujo del agua. El otro modelo que utilizo es la MEESN, que es la combinación de la red neuronal más un modelo de serie de tiempo, los resultados obtenidos de este último con la temperatura superficial del mar (TSM) que es una variable exógena, dando un mejor resultado.

Marín Vilca y Pineda Torres (2019), utilizaron redes neuronales de memoria a corto y largo plazo (Long Short Term Memory. LSTM), para desarrollar un sistema de alerta temprana (SAT) en la Presa de Aguada Blanca, gestionada por la Autoridad Autónoma de Majes (AUTODEMA). Entrenaron esta red neuronal utilizando datos de sensores que incluyen al volumen de agua efluente (caudal de descarga), evaporización, temperatura mínima, temperatura máxima y precipitación. Como resultado, obtuvieron un error cuadrático medio (RMSE) de 1.30, por lo que predice que es aceptable para la predicción del siguiente caudal de descarga.

2.2. Bases teóricas

2.2.1. *Machine Learning*

El Machine Learning que traducido en español se conoce como máquina de aprendizaje, tiene como finalidad de lograr que las máquinas puedan imitar al ser humano mediante el aprendizaje automático mediante algoritmos computacionales.

Por ello, es una ciencia de la computación dentro del ámbito de la inteligencia artificial, siendo utilizada en diferentes campos de la medicina, economía, mercados, física y química, y como menciona Brunton et al. (2020) “ofrece una técnica para extraer datos que pueden ser traducidos en conocimientos” (p. 477). Siendo este conocimiento continuo y ayudando a predecir lo que pasaría en el futuro, asociándolo con las probabilidades estadísticas, entonces podemos inducir que el machine learning se encuentra dentro del enfoque estadístico, como lo dice Marín Vilca & Pineda Torres (2019), también considerando el enfoque simbólico siendo estos los que trabajan en la enseñanza inductiva de descripción simbólica.

Vargas Crispin et al. (2021), destacan que la técnica de machine learning, llegó a revolucionar la interpretación, modelado y manejo de información. Este proceso abarca varias fases incluyendo la definición del objeto, recolección de datos, preprocesamiento de información, selección de algoritmo, entrenamiento del modelo y finalmente la predicción y estimación de parámetros (p. 58), al tener todo este proceso lo que se quiere encontrar es la precisión del modelo con un mínimo de error.

Las técnicas de Machine Learning, revolucionaron en la interpretación, modelado y manejo de información procesada. Por ello, este proceso, pasa por diferentes fases, la definición de etiquetas de los objetos, recolección de información, procesamiento de los datos, elección del algoritmo, entrenamiento del modelo y finalmente la predicción y estimación de datos

(Vargas Crispin et al., 2021). Al desarrollar todo este proceso, se desea encontrar la precisión del modelo con un mínimo de error.

El Machine Learning se pueden clasificar en 2 enfoques, según García (2014), citado en Vargas Crispin et al. (2021), se pueden clasificar dos enfoques: el enfoque simbólico, que se basa en un número finito de reglas para la manipulación de símbolos, y el enfoque subsimbólico que se centra en crear sistemas con capacidad de aprendizaje (p. 59). Las matemáticas dentro de la inteligencia artificial y el machine learning son tan importantes para conocer más a fondo del tema, y como lo menciona Zamora (2020), no es solo conocer las librerías para tener suficiente información, sino de conocer todo el fundamento de esta herramienta.

2.2.2. Tipos de aprendizaje de Machine Learning.

El aprendizaje automático se clasifica en 4 categorías más importantes que son:

2.2.2.1. Sistemas basados en reglas.

La metodología de machine learning utiliza una serie de reglas mediante las proposiciones lógicas relacionando a dos o más objetos del dominio, las premisas y la conclusión, en otras palabras, cumple la regla de Si premisa, entonces conclusión, acompañado de los operadores lógicos (AND, OR, NOT)

2.2.2.2. Aprendizaje supervisado.

El aprendizaje supervisado como explica Raschka y Mirjalilli (2019), implica que una máquina aprenda un modelo, a partir de datos de entrenamiento etiquetados. Estos datos permiten a la máquina predecir sobre información futura o no vista. El término “supervisado” se refiere a un conjunto de muestras donde las salidas deseadas, o etiquetas, ya son conocidas (p. 3).

El funcionamiento se debe a que mediante una entrada de valores de X para el aprendizaje automático se obtendrá una salida Y como una función se representaría $Y = g(X|\theta)$, donde la función $g(\dots)$ es el modelo y θ es el parámetro (Alpaydin, 2004). Al aprendizaje automático supervisado, desarrolla una comparación de dos conjuntos de datos uno dependiente del otro para clasificar, comparar, predecir y obtener nuevos datos con la finalidad de encontrar una función que se ajuste a las etiquetas.

2.2.2.3. Aprendizaje no supervisado.

El aprendizaje no supervisado, aprende modelos sin la necesidad de valores etiquetados (debido a la gran cantidad de datos), es decir el aprendizaje ya no se desarrolla con la intervención de las personas (conocido como supervisor), sino que, mediante algoritmos computacionales, se le pide a la máquina que pueda clasificar y tener predicciones de manera más rápida.

Raschka & Mirjalilli (2019), explican que las técnicas de aprendizaje sin supervisión permiten explorar la estructura de los datos y extraer información significativa sin la necesidad de una variable de resultado conocida o una función de recompensa (p. 51). Por ello, el uso de Machine Learning desarrolla un análisis profundo de datos.

Para Russell (2018), identifica varios algoritmos importantes de machine learning no supervisado que son:

- Agrupamiento (Clustering): como los métodos de k-means y el análisis de agrupamiento jerárquico.
- Machine learning de Asociación de Regla: con algoritmos como Eclat y A priori
- Visualización y reducción de dimensionalidad: como el Núcleo PCA, t-distributed PCA. Las cuales son utilizados para visualizar gráficos en 2D y 3D con los datos no etiquetados.

El aprendizaje no supervisado, aprende modelos sin la necesidad de valores etiquetados (debido a la gran cantidad de datos), es decir el aprendizaje ya no se desarrolla con la intervención un agente (conocido como supervisor), sino que, mediante algoritmos computacionales, se le pide a la máquina que pueda clasificar y tener predicciones de manera más rápida.

2.2.2.4. Aprendizaje por refuerzo.

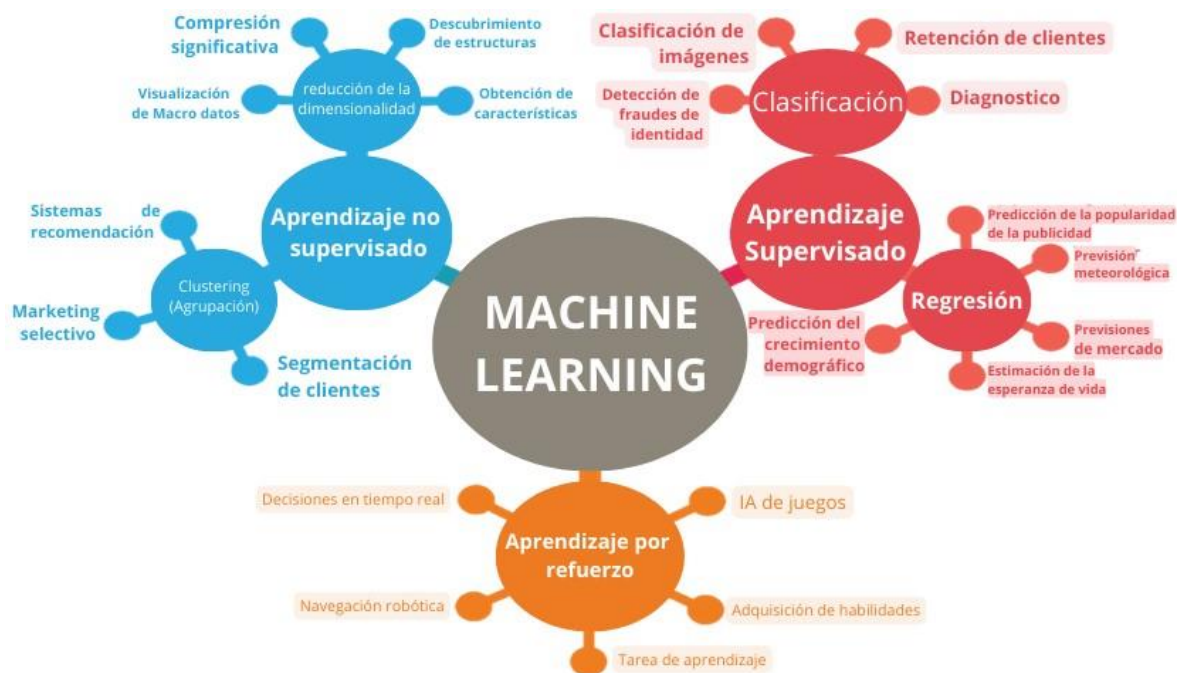
El aprendizaje de refuerzo, son el desarrollo de algoritmos para superar situaciones que las maquinas mediante errores puedan aprender. El aprendizaje por refuerzo “tiene como objetivos desarrollar un sistema (agente) que mejore su rendimiento basado en interacciones con el entorno” (Raschka & Mirjalilli, 2019, p.48). Es decir, el sistema de aprendizaje aprende a través de las pruebas y errores y que las maquinas por su propia cuenta puedan tomar decisiones por sí mismas y resolver de mejor manera los problemas que puedan acontecer (Hurwitz & Kirsch, 2018).

El aprendizaje por refuerzo es uno de los tres tipos de aprendizaje del Machine Learning, tal como se puede apreciar en la Figura 1. Otro de los tipos de aprendizaje de Machine Learning es el aprendizaje supervisado, que es un modelo que aprende a partir de un conjunto de datos etiquetado, es decir, cada entrada tiene una salida correspondiente (etiqueta). El objetivo es que el modelo sea capaz de predecir la salida para nuevas entradas basándose en patrones aprendidos. Ejemplos comunes son la clasificación (como predecir si un correo es spam o no) y la regresión (como predecir el precio de una casa). El último de los tipos es el aprendizaje no supervisado, que es un modelo que trabaja con datos no etiquetados. El objetivo es identificar patrones, estructuras o relaciones ocultas dentro de los datos sin la necesidad de etiquetas previas. El aprendizaje no supervisado se utiliza, por ejemplo, en la segmentación de clientes o en la reducción de la dimensionalidad. Ejemplos incluyen el clustering (agrupamiento) y el análisis de componentes principales (PCA).

A diferencia de los anteriores, el aprendizaje por refuerzo es un agente que aprende a tomar decisiones mediante la interacción con su entorno. Recibe recompensas o penalizaciones basadas en las acciones que toma, con el objetivo de maximizar las recompensas a largo plazo. Es el tipo de aprendizaje utilizado en problemas de toma de decisiones secuenciales, como en videojuegos, robots autónomos o sistemas de navegación.

Figura 1.

Esquema generalizado sobre Machine Learning.



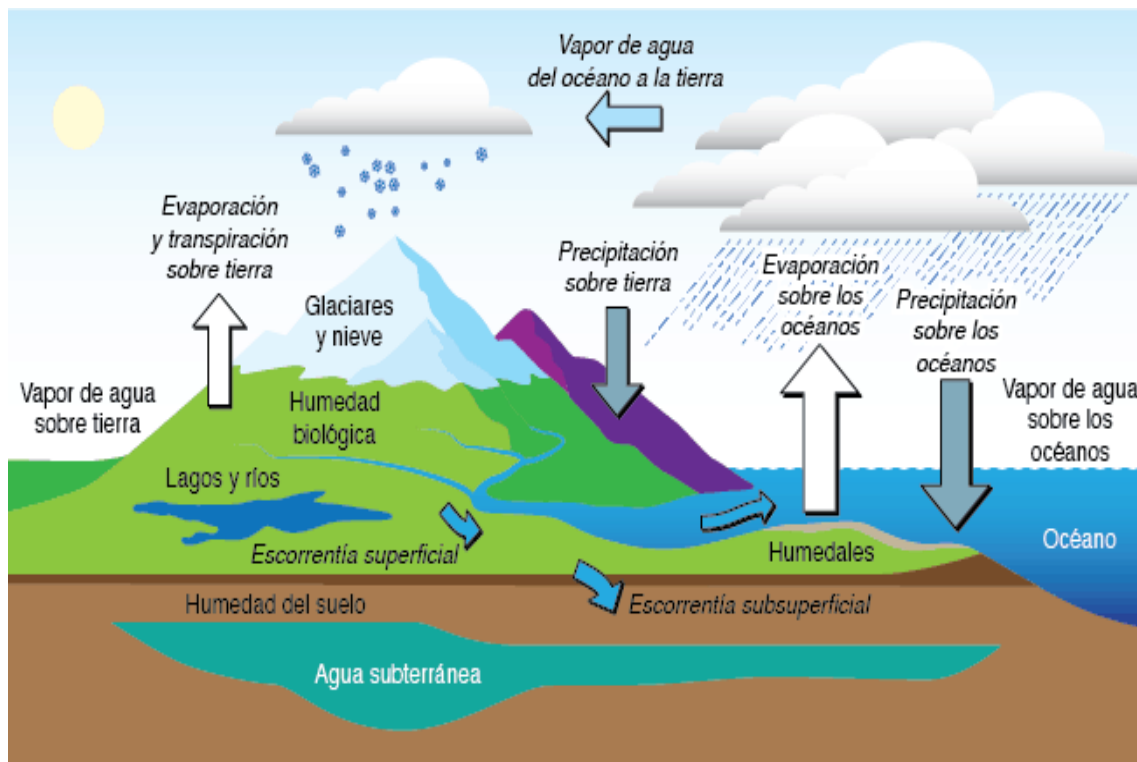
Fuente: <https://www.profesionalreview.com/2019/08/19/machine-learning-que-es/>

2.2.3. Ciclo Hidrológico.

El ciclo hidrológico se conoce como el cambio que experimenta el agua de manera natural en su forma superficial, subsuperficial y subterránea siguiendo una secuencia y obedeciendo las leyes físicas (Chereque (1989), citado en Ordoñez Gálvez, 2012, p.8-9), tal como se muestra en la Figura 2.

Figura 2.

Ciclo hidrológico del agua.



Fuente: <https://stem.guide/topic/ciclo-hidrologico/?lang=es>

El ciclo del agua empieza con la evaporización a partir de superficies de agua ascendiendo a la atmosfera, produciéndose la condensación en forma de nubes, dando lugar a la precipitación en forma líquida, granizo, nieve, garúa, volviendo a la atmosfera por evaporación de las gotas de lluvia; llegando a descender por la superficie terrestre.

Una parte se logra infiltrar hacia el subsuelo penetrando el suelo a diversas profundidades y reapareciendo en forma de manantiales o constituyendo la napa de agua subterránea como los bofedales, que luego pueden ser empleadas por el hombre. Otra parte considerable regresara a la atmosfera terrestre como consecuencia de la transpiración vegetal, evaporación y parte del agua que no se infiltra, conocido como agua precipitada, formándose con la parte del agua del subsuelo cursos de agua superficiales, comenzando así nuevamente el ciclo del hidrológico (UNESCO, 2006).

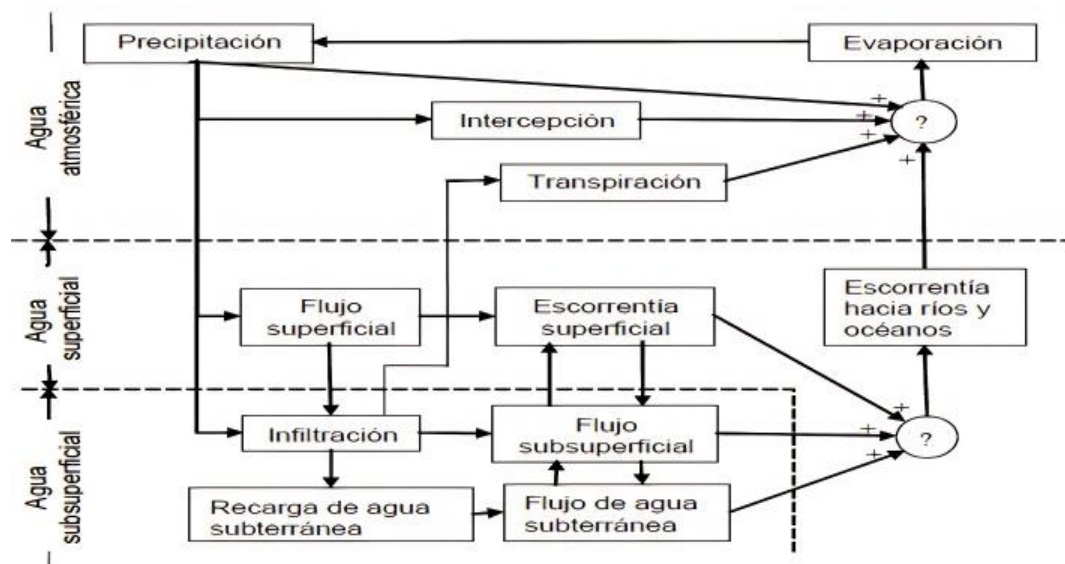
Se puede concluir que el ciclo hidrológico, es el proceso continuo que ocurre en la circulación de agua en sus 3 estados fundamentales (sólido, líquido y gaseoso), comenzando desde la radiación del sol a la superficie terrestre produciéndose la evaporización del agua, y ascendiendo en su forma gaseosa llegando a calentar la atmósfera terrestre, en la capa de la troposfera; donde se concentra la mayor cantidad de vapor de H₂O y otros gases como el ozono (O₃), produciendo de esta manera la condensación de agua, y llegando a descender nuevamente en forma de lluvia, nieve, etc., para así desembocar con el agua de la superficie terrestre e infiltrándose en los subsuelos.

2.2.4. Sistema Hidrológico.

Un sistema hidrológico, son procesos continuos que sigue un orden para que se desarrolle el ciclo del agua, se representa mediante el siguiente esquema de la Figura 3.

Figura 3.

Sistema del ciclo hidrológico.



Fuente: Ven te

2.2.5. Parámetros Hidrológicos.

2.2.5.1. Precipitación (Pp)

Se conoce como precipitación a la formación de agua en su estado sólido y líquido en las nubes, debido a las colisiones de las partículas de estas, la precipitación cae en forma de nieve que se acumula en las zonas montañosas más altas como el Nevado de Razuhuillca o el Abra de Apacheta los cuales almacenan agua congelada por mucho tiempo y al descongelarse estas desembocan en los ríos en dirección a los océanos por escorrentía superficial (ANA & MINAGRI, 2016).


La precipitación, se forma gracias a la radiación del sol y la elevación de grandes masas de aire hasta alturas de enfriamiento suficientes, donde el aire alcanza la saturación. Este proceso requiere la presencia de núcleos de condensación, que pueden ser productos de combustión, óxidos de nitrógeno o pequeñas partículas de sal. Después de este proceso, se forman diminutas gotas de 0.002 mm, se llegan a unir hasta los de 2 mm aproximadamente, para finalmente descender a la tierra debido a la gravedad (Chereque Morán, 1989).

2.2.5.2. Escorrentía (Esc).

El agua luego de descender por acción de la gravedad a la superficie terrestre en forma de lluvia o nieve por la precipitación, llega ser absorbida por los suelos mediante la infiltración o por las capas superiores del suelo, volviendo a los océanos por redes de drenaje, como se muestra en la Figura 4. A este proceso del recorrido del agua a través de los suelos y subsuelos hacia el océano se le conoce como escorrentía (ANA & MINAGRI, 2016).

Figura 4.

Ciclo de escorrentía.



Fuente: El ciclo hidrológico

Se considera 3 tipos escorrentía:

- Escorrentía superficial; se le conoce a la precipitación que no ha sido infiltrada por los subsuelos, moviéndose a través del terreno por una red de drenaje superficial hasta desembocar a los ríos.
- Escorrentía subterránea; es la parte infiltrada en los subsuelos hasta el nivel freático debido a la presencia de la vegetación e irregularidades del suelo. Este último es más lento que la escorrentía superficial y eso es debido a que el caudal fluye a mayor tiempo después de las últimas precipitaciones (Sánchez San Román, 2017).
- Escorrentía subsuperficial, es la que se encuentra entre la escorrentía superficial y subterránea, esta se infiltra en el suelo, moviéndose por los horizontes superiores para reaparecer en el transcurso del tiempo en la superficie como manantial e incorporarse a microsurcos superficiales que le conducirán a la red de drenaje para desembocar a los ríos (Universidad de Coruña, 2019).

2.2.5.3. Caudal (Q).

El caudal se define como la cantidad de volumen de agua a través de conductos naturales o artificiales en un tiempo determinado, siendo su unidad de medida es m^3/s . Los datos del caudal obtenidos de la estación hidrometeorológica de la presa Cuchoquesera son recopilados por un medidor hidrometeorológico de tipo Khafagi de registro continuo y automático.

El estudio del caudal permite determinar los regímenes de flujo adecuados para satisfacer las necesidades hídricas de los ecosistemas y humedales, mediante la variación natural estacional e interanual. Esto ayuda a mantener y mejorar la preservación de los humedales fundamentales y otras funciones esenciales. La construcción de una presa tiene la finalidad, de que se pueda aprovechar el agua modificando el caudal natural, y así pueda almacenar agua para periodos de sequía, para el uso agrícola, etc. (Secretaría de la Convención de Ramsar, 2010).

Por ello, el objetivo de captar los valores de caudal máximos para diferentes periodos, tiene un fin de diseño de prevención y planificación hidrológica (ANA, 2010, p. 14).

2.2.5.3.1. Caudal de entrada. (Q_{in}).

Para medir el caudal de entrada al embalse de la presa, se utiliza un limnómetro como se muestra en la Figura 5, la cual se encuentra al final del canal colector en Pampamarca.

Figura 5.

Limnómetro.



Fuente: TecnoEdu

2.2.5.3.2. Caudal de salida. (Q_s)

Para medir el caudal de salida al embalse de la presa, se utiliza un control de descarga denominada válvula esférica Howell Bunger, tal como se muestra en la Figura 6, con una capacidad máxima de descarga de hasta $10 \text{ m}^3/\text{s}$.

Figura 6.

Válvula Howell Bunger.



Fuente: INGESUR

Además, en el caso de que se dé alguna situación de sobre carga existen 2 compuertas de emergencia con una capacidad de descarga de $32 \text{ m}^3/\text{s}$, que son operados de manera manual o mediante sensores electromecánicos equipados en la caseta de control como se llega a mostrar en la Figura 7.

Figura 7.

Caseta de válvulas para el control de descarga del embalse.



Fuente: Elaboración propia (foto tomada en la sala de control para la salida de agua)

2.2.5.4. Temperatura.

Es el grado de medida de energía térmica del aire en un instante dado (en °C o °F) que se mide mediante un termómetro de máxima y de mínima depositados a 1,5 m desde el ras del suelo cubiertas por una caja de madera provista de persianas que permite el libre tránsito del aire y que además protege a los termómetros de los rayos solares, por lo que depende directamente de la radiación solar. Los parámetros para obtener el valor de la temperatura son la altitud, latitud y la proximidad al mar, que inciden al cambio de temperatura en la troposfera alrededor de 0.6 °C en promedio por cada 100 m de ascenso, a la cual se la denomina gradiente de temperatura (Chereque Morán, 1989).

2.2.5.4.1. Temperatura máxima. (T_{max})

La temperatura máxima, es captada con el termómetro de máxima, que al aumentar la temperatura, hace que la dilatación del mercurio en el bulbo venza la resistencia provocada por el estrechamiento. Cuando la temperatura desciende, la masa de mercurio se contrae, la columna se rompe por el estrechamiento y el extremo libre queda marcando la temperatura máxima registrada.


2.2.5.4.2. Temperatura mínima. ($T_{mín}$)

El termómetro de mínima registra la temperatura cuando esta disminuye. El líquido, generalmente alcohol, arrastra un índice integrado que no puede atravesar y se ve obligado a retroceder. Al aumentar nuevamente la temperatura, el líquido pasa fácilmente entre la pared del tubo y el índice, dejando este último marcando la temperatura mínima en el extremo más alejado del bulbo.

Dato: La temperatura máxima y mínima es captado por la estación hidrometeorológica en la presa mediante sensores de temperatura como se muestra en la Figura 8 y termómetros cubiertos por una caseta para protección de los rayos ultravioleta.

Figura 8.

Sensor de temperatura.



Fuente: Imagen tomada en la estación de Sunilla.

2.2.5.5. Nubosidad. (Nb)

Es la fracción del cielo que se estima que estará cubierta por nubes parciales o por todo tipo de nubes en el cielo denominado nubes totales, actualmente está ampliamente generalizada con el uso de métodos instrumentales, que determinan su valor en cada capa identificada y la nubosidad total en vista desde el punto de un observador, su estimación se redondea en octas que sí van de 0 a 8 octas significa que los cielos están despejados o densamente despejados y si la octa es a 9 significa que el cielo está completamente cubierta por las nubes generando oscuridad como se observa en la Tabla 1 de la escala para cifrar la nubosidad por OMM (2011) (Organización Meteorológica Mundial (OMM), 2014).

Tabla 1.*Estimación de valores de la nubosidad.*

Cifra de clave	Significado	
0	0	0
1	1 octa	1/10 o menos, pero no cero
2	2 octas	2/10 a 3/10
3	3 octas	4/10
4	4 octas	5/10
5	5 octas	6/10
6	6 octas	7/10 a 8/10
7	7 octas o más, pero no 8 octas	9/10 o más, pero no 10/10
8	8 octas	10/10
9	Cielo oscurecido por la niebla y/u otros fenómenos meteorológicos	
/	La cubierta de nubes no es discernible por razones diferentes de la niebla u otros fenómenos meteorológicos o no se ha hecho la observación	

Fuente: Organización Meteorológica Mundial (OMM)

- La nubosidad total, se refiere a la fracción de la bóveda celeste cubierta por todas las nubes visibles. Esta estimación consiste en evaluar la cantidad de la zona aparente total del cielo cubierta por nubes. Por otro lado, la nubosidad parcial, se refiere a la cantidad de cielo cubierta por cada tipo de nube o por nubes estratiformes, aparentando como un único tipo de nube en el cielo.
- Es importante mencionar que la suma de las nubosidades parciales puede exceder la nubosidad total, superando las 8 octas (OMM, 2014).

2.2.5.6. Viento (Vv)

Las mediciones del viento se realizan teniendo en cuenta que son magnitudes vectoriales con una dimensión tridimensional, la cual implica fluctuaciones aleatorias de pequeña escala tanto espacial como temporal, superpuesta a un flujo de mayor escala. Este método se usa principalmente para controlar la contaminación del aire y asistir en el aterrizaje de aviones.

En la estación meteorológica en la presa Cuchoquesera, las mediciones se limitan en 2 dimensiones: dirección y la velocidad. Las estadísticas climáticas en este caso suelen basarse en promedios recolectado a lo largo de diferentes horas del día y la noche (OMM, 2014).

Estas observaciones y mediciones son cruciales para monitorear y predecir el clima, estudiar los patrones de viento, y evaluar la probabilidad de daños debido a su intensidad. Además, se utilizan para evaluar la energía eólica y estimar los flujos de superficie. La dirección y velocidad del viento, se miden generalmente con una veleta o un anemómetro de cazoletas o de hélice, luego de registradas estas mediciones, se procesan para el calcular los promedios, desviación estándar y valores extremos (OMM, 2014).

2.2.5.7. Evaporación (Ev)

La evaporación es el proceso mediante el cual, el agua se transforma de líquido a gaseoso, transfiriéndose a la atmósfera en un intervalo de tiempo conocido como tasa de evaporación. La evaporación potencial se refiere a la cantidad de vapor agua que una superficie de agua pura, puede emitir por unidad de área y tiempo bajo las condiciones actuales (OMM, 2014, p. 336).

Para medir la evaporación, se emplean métodos indirectos usando instrumentos o sensores que realizan mediciones puntuales y otros cálculos que proporcionan resultados aceptables. Comúnmente se utilizan el atmómetro y tanques de evaporación, para medir la

perdida de agua en una superficie saturada estándar de agua. Sin embargo, los datos obtenidos suelen corregirse para obtener estimaciones precisas de la evaporación, uno de los métodos más apropiados es el balance hídrico (OMM, 2014).

2.3. Bases conceptuales

2.3.1. Balance hídrico

El balance hídrico es utilizado como un método de control y predicción con datos de entrada y salida del embalse, con el fin de gestionar, conocer y planificar los recursos de agua dulce tanto a nivel espacial como temporal (UNESCO, 2006).

Según Claro R., (1991), el balance hídrico formula la ley de conservación de la materia o masas aplicada al agua en un sistema dado. Este sistema puede variar de tamaño, desde volúmenes del suelo de una planta hasta una parcela cultivada, una cuenca hidrográfica, una región o incluso un país.²

Las leyes más importantes para el recurso hidrológico, con la finalidad de encontrar una estabilidad según los parámetros estudiados en el balance hídrico, menciona que este podría ser una las leyes más importantes para el recurso hidrológico, donde la ecuación se representa en una expresión simple, pero la cuantificación de sus términos llegan normalmente ser complicadas, debido por la falta de mediciones directas en campos y por la variación espacial de los parámetros hidrometeorológicos y de las variaciones del agua almacenada en una cuenca.

2.3.1.1. Cálculo del Balance hídrico.

La ecuación del balance hídrico se emplea como se distribuye el agua recibida por un sistema mediante la precipitación, incluyendo como se reparte través de la evapotranspiración, escorrentía e infiltración. Este método se fundamenta en el principio de conservación de la masa, que indica que el agua no se crea, ni se destruye, sólo se transforma. Utilizando esta

ecuación, se pueden relacionar las diferentes cantidades de agua que participan en el ciclo hidrológico (Campos, 1998).

$$\text{Entradas} - \text{Salidas} = \text{Cambio de almacenamiento} \quad (1)$$

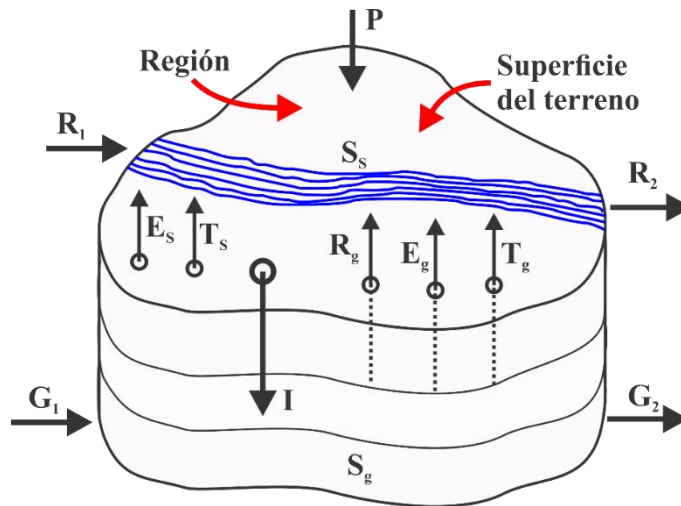
Aunque esta ecuación pueda ser simple, su aplicación es compleja debido a la falta de información disponible, la variabilidad de la evapotranspiración y las pérdidas de agua por infiltración hacia los acuíferos (Llorens, 2003).

La precipitación (P) que cae en un lugar específico puede volver a la atmósfera mediante la evaporación del suelo ($E = E_s + E_g$) o por la transpiración de la vegetación ($T = T_s + T_g$). En conjunto estos se conocen como evapotranspiración ($ET = E_s + E_g + T_s + T_g$), donde s y g representan las componentes superficial y subterránea, respectivamente.

Además, el agua se desplaza por la superficie a través de la escorrentía superficial de entrada ($Esc_{ent} + Esc_g$) y salida (Esc_{sal}), siendo la escorrentía total ($Esc = Esc_s + Esc_g - Esc_{sal}$) que fluye a los tributarios hasta llegar al cauce principal, desembocando en el mar. Parte del agua se infiltra en el suelo, uniéndose al sistema de agua subterránea de entrada (G_1) como el de salida (G_2) representando al escurrimiento subterráneo ($G = G_1 - G_2$). El agua también se puede infiltrar en acuíferos (I) y ser almacenadas (S), tal como se muestra en la Figura 9 (Campos, 1998).

Figura 9.

Esquema del balance hídrico en una determinada región.



Fuente: Elaboración Propia (realizado en Corel Draw 2019)

Estas magnitudes deben cumplir con el balance hídrico para la parte superficial:

$$P + R_1 + R_g - R_2 - E_s - T_s - I = \Delta S_s \quad (2)$$

La ecuación de balance hídrico para la parte subterránea es:

$$I + G_1 - G_2 - R_g - E_g - T_g = \Delta S_g \quad (3)$$

Sumando ambas ecuaciones obtendremos el balance hídrico

$$P - (R_2 - R_1) - (E_s + E_g) - (T_s + T_g) - (G_2 - G_1) = \Delta(S_s + S_g) \quad (4)$$

En forma más simplificada:

$$Pp - Esc - Ev - T - G = \Delta S \quad (5)$$

Donde:

Pp : Precipitación

Esc : Esgurrimento

Ev : Evaporación

T : Transpiración

G : Esguerrimiento subterráneo

S : Almacenamiento

Debido a los escasos datos de la transpiración (T) y del esguerrimiento subterráneo (G) en la presa Cuchoquesera por la estación Sunilla, estas variables tienden a 0, quedando la ecuación (6) como:

$$P - Esc - Ev = \Delta S \quad (6)$$

Donde consideramos en este caso que la esguerrencia viene dada por la diferencia del caudal de entrada (Q_{en}) y el caudal de salida (Q_{sa}) a la presa Cuchoquesera, quedando la ecuación (6) como:

$$P - (Q_{sal} - Q_{en}) - Ev = \Delta S \quad (7)$$

Dado que queremos estimar las pérdidas de agua en la presa Cuchoquesera, definiremos nuestra ecuación como:

$$\pm L = Q_s - Q_i + Ev - S_i + S_s \quad (8)$$

Donde:

S_i ; es el almacenamiento inicial en un tiempo determinado.


S_s ; es el almacenamiento final en un tiempo determinado.

L ; es la pérdida de agua en función del estado de almacenamiento inicial y del estado de almacenamiento final en un tiempo determinado.

En la Figura 10, se muestra los parámetros climáticos e hídricos que se registran en la presa Cuchoquesera, necesarios para la alimentación del modelo de balance de masa, requeridos para el algoritmo de Machine Learning.

Figura 10.

Esquema de balance hídrico para la presa Cuchoquesera.



Fuente: Elaboración Propia (realizado en corel Draw 2019)

Donde: si el valor de L es positivo significara que la presa está ganando, debido a que hay más ingreso de agua a la presa de la que sale debido por factores climáticos como la precipitación.

Si el valor L es negativo, significara que hay perdida de agua debido a diferentes factores climáticos entre ellos la infiltración y la evapotranspiración de agua.

2.3.2. Redes Neuronales Artificial (RNA)

Nuestro cerebro está compuesto de neuronas que nos ayudan percibir lo exterior a través de los sentidos o funciones de nuestros sistemas del cuerpo humano, viajando la información por redes eléctricas interconectadas entre las neuronas hacia el cerebro humano recibiendo la información percibida, para buscar una solución. Las redes neuronales artificiales, fueron

creados basándose en la interconexión de las neuronas del cerebro humano, para replicar su función mediante algoritmos computacionales con entradas de datos en las máquinas, y obtener datos de salida según el trabajo que se realice o se investigue.

Las Redes neuronales artificiales, tiene un enfoque general para interpretar datos complejos y procesarlos mediante algoritmos computacionales resultando ser muy eficaces y obteniendo resultados favorables, aproximando a funciones de objetivo de valor real, valor discreto y valor vectorial (Mitchell, 1997).

2.3.3. Construcción e implementación de las RNA

Las redes neuronales son un conjunto de algoritmos que siguen un proceso de aprendizaje mediante el entrenamiento de datos. Para entenderlo más al fondo, el aprendizaje automático profundo, que mediante algoritmos complejos, desarrolla varias capas de entrenamiento eficaces para las redes neuronales artificiales (Raschka & Mirjalilli, 2019).

2.3.3.1. Red neuronal de una capa.

La red neuronal de una sola capa, presenta algoritmos que son de baja complejidad computacional, donde normalmente se emplean técnicas de aprendizaje supervisado para la clasificación de etiquetas, utilizando modelos como el perceptrón y Adaptive Linear Neurone (Adaline), las cuales estos constituyen la base de las redes neuronales artificiales para abrir campo a otros métodos más complejos.

2.3.3.1.1. Entrenamiento de algoritmos de una red neuronal.

El concepto más formal de las neuronas artificiales se basa en la clasificación de números binarios para referenciar a 2 clases siendo 1 (clase positiva) y -1 (clase negativa).

Se define, la función de toma de decisiones ($\phi(z)$), de donde z es la entrada de red definida como una combinación lineal

$$z = w_1x_1 + w_2x_2 + \dots + w_nx_n \quad (9)$$

donde w se denomina vector peso y x los valores de entrada

$$w = \begin{bmatrix} w_1 \\ \vdots \\ w_n \end{bmatrix}, x = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} \quad (10)$$

Si se da el caso de que $x > \Theta$, donde Θ se le conoce como umbral, nos abocaremos a las clases 1 y -1 mediante la función escalonada, a esto se le conoce como algoritmo perceptrón.

$$\phi(z) = \begin{cases} 1 & \text{sí } z \geq 0 \\ -1 & \text{sí } z < 0 \end{cases}$$

Para simplificar los cálculos, el umbral Θ va al lugar izquierda de la ecuación y definimos un primer peso $w_0 = -\Theta$ y $x_0 = 1$, donde z será:

$$z = w_0x_0 + w_1x_1 + \dots + w_nx_n = \sum_{j=0}^n x_jw_j = w^T x \quad (11)$$

Donde para el umbral negativo se le conoce como sesgo o en inglés como bias.

2.3.3.1.2. Regla de aprendizaje del perceptrón.

La regla del perceptrón inicial de Rosenblatt viene dada por los siguientes pasos

- 1) Iniciar los pesos a 0 o a números aleatorios más pequeños.
- 2) Para cada muestra de entrenamiento $x^{(i)}$:
 - a) Calcular el valor de salida \hat{y} .
 - b) Actualizar los pesos.

De este resultado el valor de salida es la etiqueta de clase de los datos proyectados por la función escalón unitario y la actualización de los pesos está dada.

$$w_j := w_j + \Delta w_j \quad (12)$$

Donde

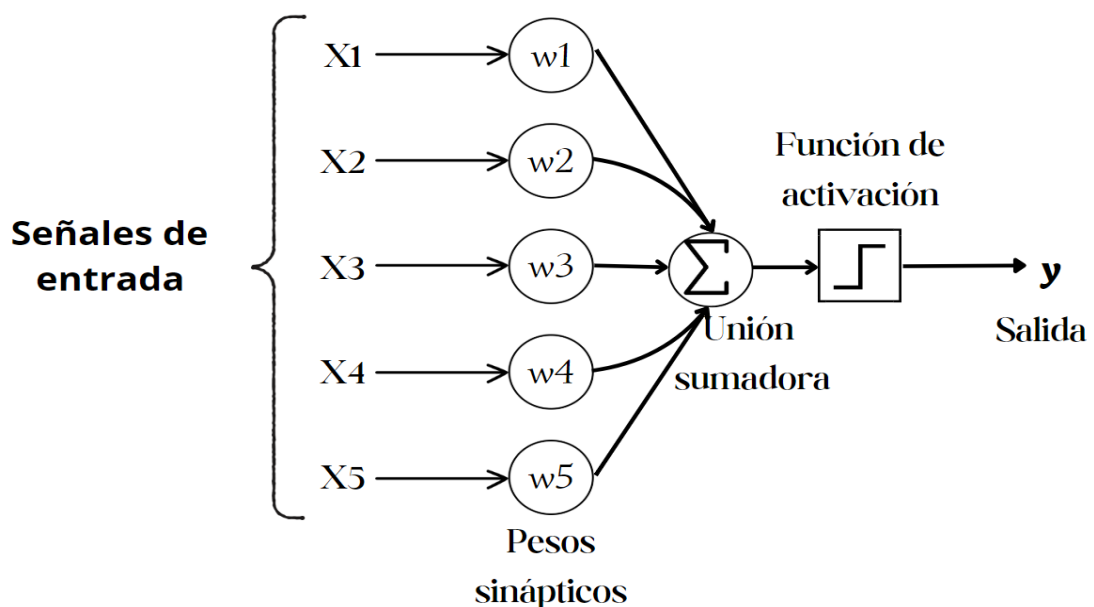
$$\Delta w_j = \eta (y^{(i)} - \hat{y}^{(i)}) x_j^{(i)} \quad (13)$$

Para $j = 0, \dots, n$, η conocido como rango de aprendizaje (normalmente constante 0 y 1), $y^{(i)}$ etiqueta de clase verdadera de la muestra de entrenamiento i y $\hat{y}^{(i)}$ es la etiqueta de clase de los datos proyectados.

En el diagrama de la Figura 11, se resume los modos funcionales del perceptrón dentro de una red neuronal.

Figura 11.

Esquema del funcionamiento de un perceptrón.



Fuente: https://www.juansensio.com/blog/023_mlp_backprop

El perceptrón si no puede separar dos clases por un hiperplano, los pesos no dejarían de actualizarse o a menos que se indique un límite.

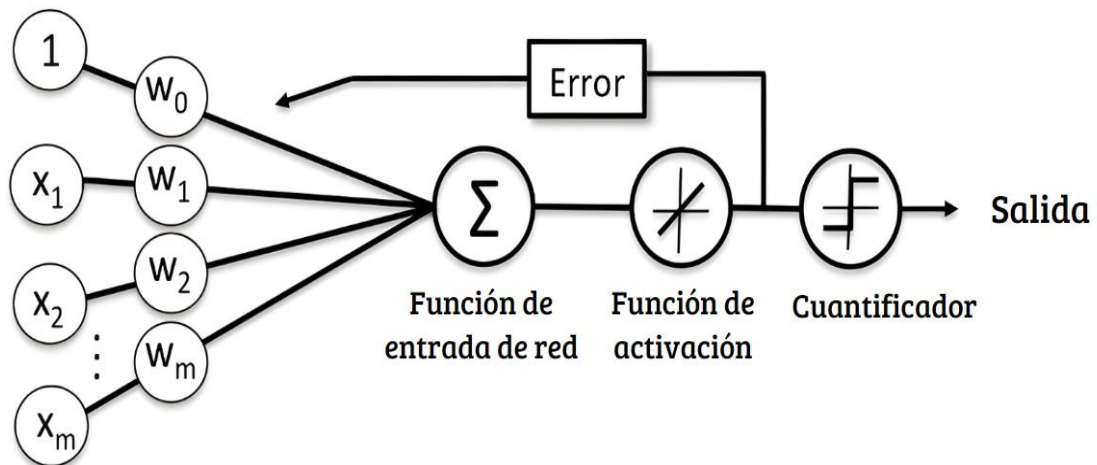
2.3.3.1.3. Neuronas lineales adaptivas y su convergencia de aprendizaje.

En el término inglés se le conoce como Adaptive Linear Neuron con las siglas de Adaline que fue publicado por Bernard Widrow y su alumno Ted Hoff.

En Adaline los pesos w se actualizan a través de una función de activación lineal $\phi(z)$ que es la función de identificación de la entrada de red definida para $\phi(z) = \phi(w^T x)$, la función umbral es parecida a la función escalón unitario del perceptrón, pero con la diferencia que Adaline compara las etiquetas de clases verdaderas con la salida de valores continuos de la función de activación lineal para calcular el error del modelo y actualizar los pesos (Raschka & Mirjalili, 2019). En la Figura 12, se muestra el diagrama de su funcionamiento.

Figura 12.

Esquema de funcionamiento de ADALINE.



Fuente: <https://es.linkedin.com/pulse/hito-2-red-adaline-emiliano-di-cola>

2.3.3.1.4. Descenso gradiente para cálculo de error.

Sea J definido como función de coste que representa la diferencia entre el valor de salida estimado con el valor real, para optimizar el error mediante el proceso de aprendizaje.

Entonces J aprende ajustar los pesos a través de la suma de errores cuadráticos (sum of squared errors, SSE, sigla en inglés).

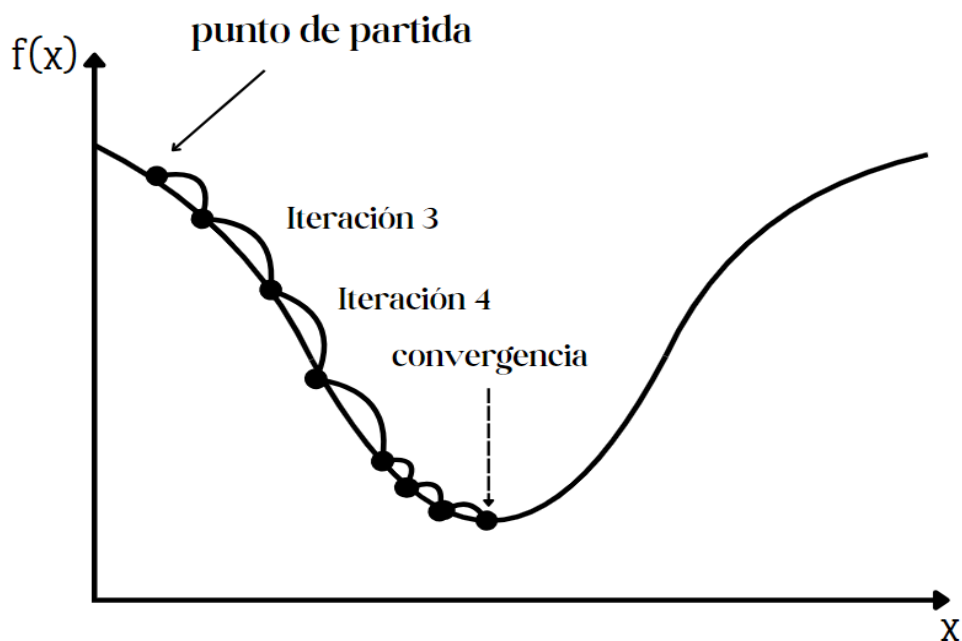
$$J(w) = \frac{1}{2} \sum_i^n (y^{(i)} - \phi(z^{(i)}))^2 \quad (14)$$

Dado que la función de coste utiliza una activación lineal continua, pasa a ser diferenciable y convexa, lo que permite aplicar el algoritmo de descenso de gradiente.

Como se observa en la Figura 13, la finalidad es descender la función de coste mediante iteraciones sucesiva, hasta optimizar el error a valor más mínimo posible.

Figura 13.

Gráfico de descenso de gradiente.



Fuente: https://www.cs.us.es/~fsancho/Blog/posts/Mejorando_Gradiente_Descendiente.md

Al aplicar el algoritmo de descenso de gradiente, se actualiza los pesos realizando un paso en la dirección opuesta del gradiente $\nabla J(w)$, la cual se expresa mediante la ecuación:

$$w := w + \Delta w \quad (15)$$

Donde Δw representa al cambio aplicado a los pesos, lo cual se calcula como:

$$\Delta w = -\eta \nabla J(w) \quad (16)$$

Siendo, η la tasa de aprendizaje y $\nabla J(w)$ la gradiente de la función de coste.

La derivada parcial de la función de coste con respecto a cada peso w_j , se define :

$$\frac{\partial J}{\partial w_j} = - \sum_i (y^{(i)} - \phi(z^{(i)})) x_j^{(i)} \quad (17)$$

Reemplazando a la ecuación (16)

$$\Delta w = -\eta \left(\frac{\partial J}{\partial w_j} \right) = \eta \sum_i (y^{(i)} - \phi(z^{(i)})) x_j^{(i)} \quad (18)$$

Este resultado es obtenido mediante la definición de J de la ecuación (14)

2.3.3.1.5. Mejora del descenso de gradiente mediante el escalado de características.

Para mejorar la eficiencia del descenso de gradiente, se utiliza el método escalado de características conocido como normalización. Este proceso proporciona a los datos la propiedad de distribución normal estándar, la cual facilita una convergencia más rápida. Para ello, se sustrae la media de la muestra μ_j , de cada valor de entrada correspondiente a la característica y se divide por la desviación estándar σ_j :

$$x_j = \frac{x_j - \mu_j}{\sigma_j} \quad (19)$$

Donde x_j son los valores de característica j en todas las muestras del conjunto de entrenamientos. Esta técnica de normalización se aplica a cada característica de j del conjunto de datos.

Al aplicar al entrenamiento de Adeline, se observa que converge después de un pequeño número de épocas, siempre que se utilice con un rango de aprendizaje adecuada η .

2.3.3.1.6. *Aprendizaje automático a gran escala y descenso de gradiente estocástico.*

El descenso de gradiente estocástico (SGD) es utilizado para grandes cantidades de conjunto de datos, que son muy amplios con millones de muestras, que ha diferencia de actualizar los pesos en base a la suma de los errores acumulados en todas las muestras $x^{(i)}$, como se muestra en la ecuación (18), el SGD efectúa que los pesos se actualicen de forma incremental para cada muestra de entrenamiento:

$$\eta \left(y^{(i)} - \phi(z^{(i)}) \right) x^{(i)} \quad (20)$$

Siendo, η la tasa de aprendizaje, $y^{(i)}$ el valor real, $\phi(z^{(i)})$ la salida del modelo, y $x^{(i)}$ el vector de características de la muestra i

Para que los resultados sean satisfactorios, se presenta los datos de entrenamiento en orden aleatorio en cada época. Además, es habitual mezclar los conjuntos de entrenamiento con el fin de evitar ciclos.

En implementaciones del descenso de gradiente estocástico, la tasa de aprendizaje η , se suele sustituir por un rango de aprendizaje adaptativo que disminuya en el tiempo, por ejemplo:

$$\frac{C_1}{[N^\circ \text{ de iteraciones}] + C_2} \quad (21)$$

Donde C_1 y C_2 son constantes de ajuste. Este método no alcanza el mínimo global, sino que suele estabilizarse en una región muy cercana al mínimo global, permitiendo conseguir un mayor recorrido hacía el coste mínimo.


2.3.3.2. Red neuronal multicapa.

La red neuronal multicapa también conocida el Perceptrón multicapa (MLP), consiste de conectar múltiples neuronas simples a una red neuronal prealimentada multicapa (feedforward).

La Figura 14, donde en el siguiente esquema se utiliza 3 capas de aprendizaje para encontrar los valores de salida. La capa de entrada está conectada con la capa oculta, y la capa de oculta está conectada con la capa se salida. Si la red tiene más de una capa oculta se le denomina red neuronal artificial profunda.

Figura 14.

Diagrama de una red neuronal perceptrón multicapa.



Fuente: Elaboración Propia

Se representó la unidad i de activación en la 1° capa como (a_1) . La capa de entrada se denota por in , mientras que la capa oculta por h y la capa de salida por out . Las capas de activación estarán representadas a_0 y b_0 que son las unidades de sesgo, cuyo valor es 1.

$$a^{(in)} = \begin{bmatrix} a_0 \\ a_1 \\ \vdots \\ a_m \end{bmatrix} = \begin{bmatrix} 1 \\ x_1^{(in)} \\ \vdots \\ x_m^{(in)} \end{bmatrix} \quad (22)$$

Cada unidad en la capa l está conectada a todas las unidades de la capa $l + 1$ mediante un coeficiente ponderado. Por ejemplo, la conexión entre la unidad k° en la capa l y la unidad j en la capa $l + 1$ que se denota como $w_{l+1(k,l)} = w_{k,l}^{l+1}$, la matriz ponderada que conecta la capa de entrada y salida se representa como $w_h = w^{(h)}$ y la matriz que conecta la capa oculta a la salida como $w_{out} = w^{(out)}$.

Este tipo de red neuronal nos permite realizar clasificación de multiclases mediante generalización de la técnica One-versus-All (OvA).

Los pesos que conectan la entrada y ocultas mediante la matriz $W^{(h)} \in \mathbb{R}^{m \times d}$, donde d es el número de capas ocultas y m es el número de unidades de entrada incluyendo el sesgo.

2.3.3.2.1. Activación de la red neuronal mediante la propagación hacia adelante.

Para activar al Perceptrón multicapa (MLP), se siguen 3 pasos fundamentales:

- I. De la capa de entrada, los patrones de los datos de entrenamiento se propagan hacia adelante a través de la red por las capas ocultas, para generar una salida.
- II. A partir de la salida generada, se calcula el error utilizando la función de coste con el objetivo de minimizarlo.
- III. Posteriormente, se propaga hacia atrás mediante el algoritmo de retropropagación. En este paso se calcula la derivada del error con respecto a cada peso de la red, permitiendo actualizar los parámetros del modelo por medio del descenso de gradiente.

Al repetir este proceso múltiples veces, se ajustan progresivamente los pesos del MLP, aplicando una función umbral, que permita obtener las etiquetas de clase correspondientes de los datos proyectados o estimados.

Siguiendo los pasos descritos, primero se calcula la unidad de activación de la capa oculta donde:

$$z_1^h = a_0 w_{0,1}^{(h)} + a_1 w_{1,1}^{(h)} + \dots + a_m w_{m,1}^{(h)} \quad (23)$$

Donde para $a_1 = \phi(z_1^h)$, siendo z_1^h la entrada de red y $\phi(\cdot)$. La función de activación, que debe ser diferenciable para aprender los pesos que conectan a las neuronas mediante el método del descenso de gradiente.

2.3.3.2.2. Entrenamiento de la red neuronal artificial multicapa.

El cálculo de la función de coste logístico, mide el error par aun conjunto de n muestras

La función estará definida como:

$$J(w) = - \sum_{i=1}^n y^i \log(a^{(i)}) + (1 - y^{(i)}) \log(1 - a^{(i)}) + L2 \quad (24)$$

Donde $a^{(i)}$ es la activación sigmoide de la muestra i en el conjunto de datos. El paso de la propagación este dado $a^{(i)} = \phi(z^{(i)})$, siendo la activación sigmoide de la muestra i , y $(z^{(i)})$ es la estrada lineal a la neurona para la muestra i . $L2 = \lambda ||w||_2^2 = \lambda \sum_{j=1}^m w_j^2$ termino de regularización, donde λ , es la constante de regularización que controla la magnitud de los pesos.

2.3.3.2.3. Propagación hacia atrás (Backward Propagation)

La propagación hacia atrás es un algoritmo que se emplea para el entrenamiento de redes neuronales el cual es muy eficaz en tareas de computación y análisis de datos. Su objetivo

principal es calcular las derivadas del error con respecto a los pesos de la red, con el fin de ajustar los coeficientes ponderados, y así, parametrizar una red neuronal multicapa que optimice su rendimiento.

El proceso se basa en el cálculo de derivadas mediante la regla de la cadena y el uso de la matriz Jacobiana, dentro del contexto del álgebra computacional. En este marco, se emplea la diferenciación automática hacia atrás, lo cual consiste en la multiplicación de una matriz por un vector. El resultado de cada operación es un nuevo vector, que se reutiliza como entrada para la siguiente multiplicación con la siguiente matriz.

Para el entrenamiento de la red neuronal, el error se propaga desde la capa de salida hacia las capas anteriores, es decir, de derecha a izquierda, comenzando con el vector de error en la capa de salida, el cual se calcula mediante la siguiente ecuación:

$$\delta^{(out)} = c^{(out)} - y \quad (25)$$

Donde y es el vector de etiquetas verdaderas y $c^{(out)}$ representa la salida estimada por la red. Posteriormente, se calcula el error de las capas ocultas, a través de la siguiente ecuación:

$$\delta^{(h)} = \delta^{(out)} (W^{(out)})^T \odot \frac{\partial \phi(z^{(h)})}{\partial z^{(h)}} \quad (26)$$

Donde:

z es la función sigmoidea

$W^{(out)}$ es la matriz de pesos que conecta la capa oculta con la capa de salida.

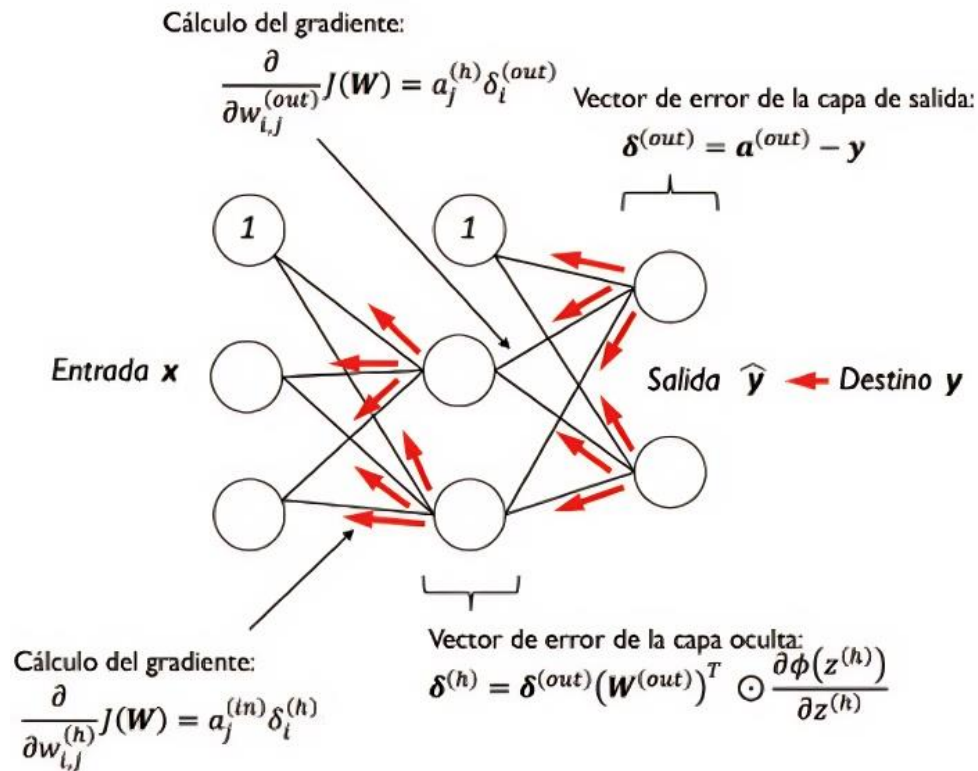
\odot es el producto Hadamard, que es una multiplicación elemento a elemento entre vectores.

$\frac{\partial \phi(z^{(h)})}{\partial z^{(h)}}$ es la derivada de la función de activación evaluada en la entrada ponderada $z^{(h)}$

La figura 15 sacado del libro de (Raschka & Mirjalilli, 2019), entenderemos mejor su aplicación.

Figura 15.

Interacción de la propagación hacia atrás de las capas neuronales.



Fuente: Raschka & Mirjalilli, (2019)

2.3.4. TensorFlow

TensorFlow (TF) es una interfaz versátil y escalable que facilita la implementación y ejecución de algoritmos de aprendizaje automático, incluyendo wrappers (envoltorios de alto nivel) preparados para el aprendizaje profundo. TensorFlow fue desarrollado y utilizado internamente por la compañía Google, y en el año 2015 fue lanzado como software de código abierto bajo licencia permisiva Apache 2.0.

TF puede ejecutarse tanto en CPU como en GPU, siendo esta última con mejor rendimiento para el aprendizaje profundo, la cual es habilitada por CUDA, plataforma

desarrollada por NVIDIA. Por otro lado, OpenCL permite el soporte para dispositivos en desarrollo o prueba, con la expectativa de ofrecer mejoras para mayor rendimiento en el futuro. El lenguaje de programación más utilizado con TF es Python, a través de su API (Interfaz de Programación de Aplicaciones), la cual es más completa y ha sido mejorada por programadores que desarrollaron TF. Los resultados obtenidos se basan en la construcción de un grafo dirigido para representar el flujo de datos. Al principio esta estructura puede parecer compleja, el uso de la API es más sencillo debido a que es un interfaz de alto nivel.

2.3.4.1. API de bajo nivel.

El TensorFlow está diseñado en torno a un grafo computacional conformado de múltiples nodos. Cada uno de estos nodos representa una operación con diversas entradas y salidas, donde los valores que fluyen a través de los bordes del grafo computacional se denominan tensores. Los tensores se clasifican en diferentes rangos: un tensor de rango 0 corresponde a un escalar; de rango 1, a un vector; de rango 2, a una matriz; y de rango 3, a matrices organizadas en una tercera dimensión. (*Qué es Tensorflow y su uso para el aprendizaje automático*, sf)

Para la entrada de la red neuronal, la entrada z que corresponde a un punto de muestra x , proveniente de un conjunto de datos de unidimensional con un peso w y un sesgo b , se define mediante la siguiente ecuación:

$$z = w \times x + b \quad (26)$$

Con esta definición, es posible utilizar una API de bajo nivel, donde permite implementar modelos como la regresión de mínimos cuadrados ordinarios o regresión lineal. De esta manera se puede definir la función de coste utilizando el error de cuadrático medio (MSE), con el objetivo de optimizar el rendimiento del modelo.

2.3.4.2. API de alto nivel.

Existen muchos tipos de API de alto nivel, lo cual nos enfocaremos en API Layers y API Keras.

2.3.4.2.1. API Layers de TensorFlow.

Para crear redes neuronales, se implementa un perceptrón multicapa a partir de un conjunto de datos, empleando en la capa oculta la función de activación de tangente hiperbólico (*tanh*). Esta API es muy útil para desarrollar prototipos de los distintos modelos y evaluar de manera inmediata los resultados.

2.3.4.2.2. API Keras de TensorFlow.

API Keras es una de las librerías más reconocidas de TensorFlow, que nos permite utilizar la GPU acelerando el entrenamiento de las redes neuronales. Una de las características más importantes es que es muy intuitiva y fácil de usar, la cual permite insertar pocas líneas de código.

III. Hipótesis y Variables

3.1. Formulación de hipótesis

3.1.1. *Hipótesis generales.*

- El modelo del balance hídrico se realiza de manera eficiente mediante técnicas de Machine Learning, en la presa Cuchoquesera de la región Ayacucho.

3.1.2. *Hipótesis específicas.*

- El comportamiento de los parámetros climáticos e hidrológicos medidos en la estación hidro-meteorológica Sunilla influyen de manera significativa en el embalse de la presa Cuchoquesera.
- La construcción de un modelo de balance hídrico resulta eficiente cuando se realiza mediante la aplicación de un algoritmo de Machine Learning, en la presa Cuchoquesera.
- La estimación de la tendencia anual del caudal de entrada y salida influye de manera significativa en el embalse de la presa Cuchoquesera, a partir del modelo de balance hídrico con Machine Learning.
- La estimación de la pérdida de embalsamiento de la presa Cuchoquesera, influye de manera significativa a partir del Balance Hídrico con Machine Learning.

3.2. Variables

3.2.1. *Variable independiente:*

- Técnicas de Machine Learning

Indicadores:

- Series temporales.
- Redes neuronales
- Tensor Flow.

3.2.2. *Variable dependiente:*

- Modelo de balance hídrico
- Indicadores:
- Precipitación
- Temperatura máxima y mínima del aire
- Evaporación de tanque
- Caudal de entrada y salida
- Velocidad del viento

3.3. Operacionalización de variables

Variable	Definición conceptual	Dimensiones	Indicadores	Tipo de variable	Escala de Medición	Instrumento
Independiente: Técnicas de Machine Learning	Se utilizará las técnicas de machine learning, para llegar a trascender en las interpretación, modelados y manejo de información mediante datos, implicando varias etapas, como definir el objeto, recolectar datos, preprocesamiento de la información, seleccionar el algoritmo adecuado, entrenar el modelo y finalmente, obtener predicciones y estimaciones de parámetros margen de error mínimo. (Vargas Crispin et al., 2021)	Hardware	Dispositivo para entrada y salida de datos.	Tecnológico	Rango	Computadora
		Software	Redes Neuronales	Cuantitativo	Rango	<ul style="list-style-type: none"> • Python • R-Studio
			TensorFlow	Cuantitativo	Rango	<ul style="list-style-type: none"> • Python • R-Studio

Variable	Definición conceptual	Dimensiones	Indicadores	Tipo de variable	Escala de Medición	Instrumento
Dependiente: Modelado de balance hídrico	Es el equilibrio entre la cantidad de agua que entra a la presa con respecto a la que sale de la misma en un determinado tiempo y así poder evaluar el grado de deterioro y conocer la disponibilidad real del recurso hídrico, que se desarrolla en cada polígono correspondiente a las Unidades de Respuesta Hidrológica (HRU), este enfoque relaciona dinámicamente la captación de agua con las características geohidrológicas específicas de la presa. (Planeación; Desarrollo y Recuperación Ambiental S.C.,2003)	Ciclo hidrológico	Precipitación	Cuantitativo	Intervalo	Estación hidrometeorológica
			Temperatura máxima y mínima del aire	Cuantitativo	Intervalo	Estación hidrometeorológica
			Evaporación de tanque	Cuantitativo	Intervalo	Estación hidrometeorológica
			Caudal de entrada y salida	Cuantitativo	Intervalo	Estación hidrometeorológica
			Velocidad del viento	Cuantitativo	Intervalo	Estación hidrometeorológica
			Almacenamiento del embalse en la presa Cuchoquesera	Cuantitativo	Intervalo	Estación hidrometeorológica
			Ecuación de balance de masa (o balance hídrico)	Cuantitativo	Intervalo	Ecuación

IV. Metodología

4.1. Tipo y nivel de investigación

4.1.1. Tipo de investigación.

La investigación es de manera aplicada, debido a que se desarrolla un modelo de balance hídrico mediante algoritmos de Machine Learning y se analiza los parámetros a través del de series temporales, utilizando redes neuronales y TF.

4.1.2. Nivel de investigación.

Es de nivel explicativa, debido que se desarrolla un profundo análisis de los gráficos y tablas que se llegan a encontrar.

4.2. Ubicación Geográfica

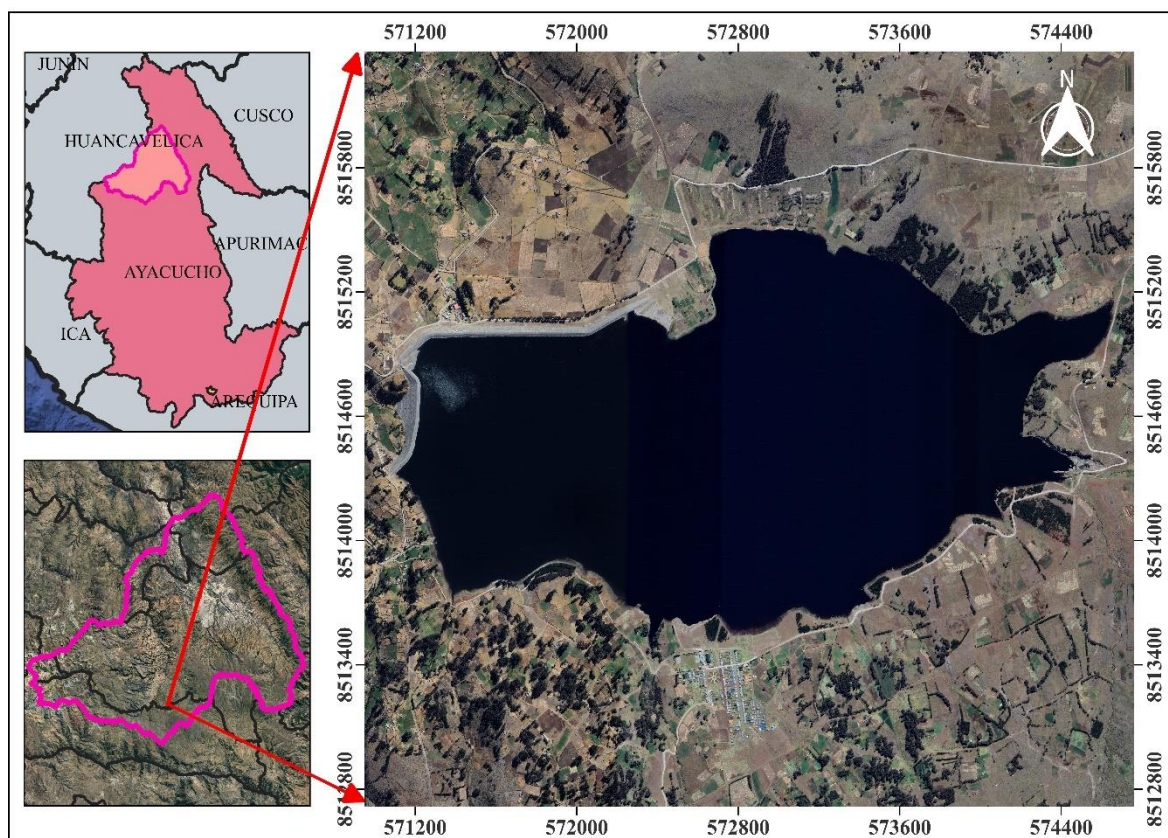
Geográficamente la presa Cuchoquesera se encuentra ubicada, por los centros poblados de Cuchoquesera y Pampamarca del distrito de Chuschi, provincia de Cangallo, departamento de Ayacucho, cuenca del río Mantaro, a una altitud de 3730 msnm, tal como se muestra en la Figura 16. La presa recibe aportaciones a través de un canal de la quebrada Churiac y de los ríos de Apacheta, Choccoro y Chicllarazo, a través de un canal que llegan a desembocar a la Presa, para posteriormente ser distribuida a los centros poblados y la población de Huamanga para el consumo hídrico.

Ubicación Política de la Presa Cuchoquesera.

Departamento :	Ayacucho
Provincia :	Cangallo
Distrito :	Chuschi
Anexo :	San Juan de Cuchoquesera

Figura 16.

Ubicación geográfica de la Presa Cuchoquesera.



Ubicación Hidrográfica

Vertiente : Océano Atlántico

Unidad Hidrográfica : Mantaro

Los puntos de coordenadas de la ubicación a la presa Cuchoquesera se muestra en la Tabla 2.

Tabla 2.

Puntos de Coordenadas de la ubicación de la Presa Cuchoquesera.

Presa	Coordenadas mapa UTM-WGS 84		Altitud (msnm)
	Norte (m)	Este (m)	
Cuchoquesera	8 514 474	570 911	3 730

4.3. Métodos

4.3.1. Método de investigación.

El presente estudio combina un método de investigación cualitativa y cuantitativa.

Es cualitativa, debido que la mayor parte del presente trabajo se describe el comportamiento de los parámetros hidrometeorológicos y de los caudales de entrada y salida. Mientras que es cuantitativa, debido que se realiza el análisis con datos recopilados por las estaciones hidrometeorológicas.

Los pasos a seguir del método cuantitativo del presente trabajo de investigación se detallan con los siguientes pasos a seguir.

1. Determinación de los parámetros climáticos e hidrológicos que influyen en el embalse de la presa Cuchoquesera.

Recolección de datos históricos: Obtención de los datos históricos desde los años 2013 al 2023, de la estación hidro-meteorológicas Sunilla, incluyendo temperatura, precipitación, evaporación, humedad, caudal de entrada y salida.

Análisis estadístico: Realización de análisis estadístico para identificar tendencias y patrones de los datos recolectados.

Datos Satelitales: Recopilación de datos satelitales periódicas en la presa Cuchoquesera para validar y complementar los datos históricos.

Identificación de Variables clave: Determinación de los parámetros más influyentes en el BH del embalse.

2. Construcción del Modelo de Simulación del Balance Hídrico.

Selección del Algoritmo: Identificación y selección del algoritmo de Machine Learning (ML) más adecuado para la simulación del BH, el modelo usado en el presente trabajo, es de Redes Neuronales de tipo Perceptrón Multicapa.

Preprocesamiento de datos: Limpieza y preparación de los datos climáticos e hidrológicos para su uso en el algoritmo de ML.

Entrenamiento del modelo: Dividir los datos en conjunto de entrenamiento y prueba, y entrenar el modelo utilizando el conjunto de entrenamiento.

Validación y Calibración: Evaluación del desempeño del modelo utilizando el conjunto de prueba y ajuste de los parámetros del modelo para mejorar su precisión.

Simulación: Ejecución del modelo para simular el BH del embalse bajo diferentes escenarios climáticos e hidrológicos.

3. Estimación de la Tendencia Anual del Caudal

Predicción del Caudal: Uso del modelo de BH para predecir el caudal de entrada y salida, en el embalse de la presa Cuchoquesera.

Análisis de Tendencias: Evaluación de las tendencias anuales del caudal estimado, identificando patrones estacionales y cambios a largo plazo.

Validación de Datos Reales: Comparación de las predicciones del modelo con datos reales del caudal para verificar su precisión y ajustar el modelo según sea necesario

4. Estimación de la Pérdida de Embalsamiento.

Cálculo de Pérdidas: Utilización del modelo del BH para estimar las pérdidas del embalsamiento debido a la evaporación, infiltración y otras fuentes de pérdida de agua.

Validación con Mediciones In Situ: Comparación de las estimaciones de pérdida con mediciones in situ para verificar la precisión del modelo.

Análisis de Impacto: Evaluación del impacto de las pérdidas de embalsamiento en la capacidad de almacenamiento y gestión del agua en la presa Cuchoquesera.

Los pasos a seguir del Método Cualitativo del presente trabajo de investigación se detallan con los siguientes pasos a seguir.

1. Participación con trabajadores y actores clave.

Recopilación de Percepciones: documentación de las percepciones sobre la precisión del modelo y su impacto en la gestión del embalse.

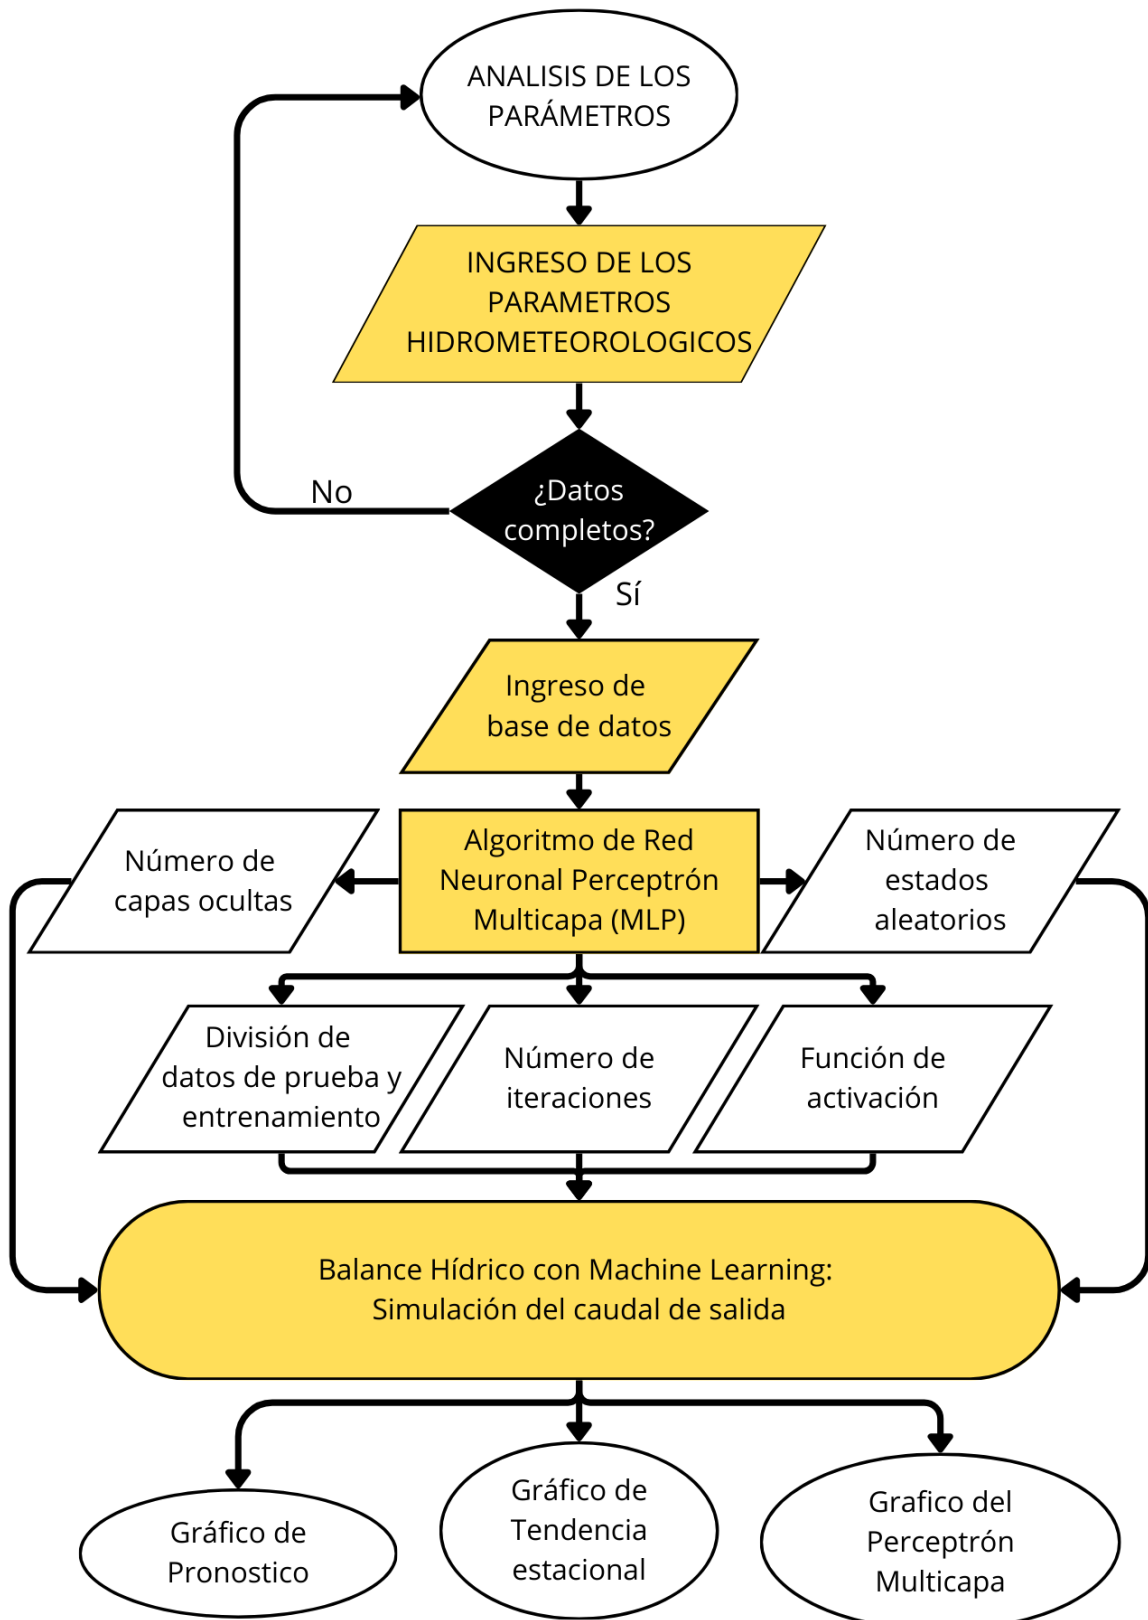
2. Evaluación de la implementación del Proyecto.

Integración de Resultados: Incorporación de los resultados cualitativos en la mejora continua del modelo para recomendaciones en la formulación política de gestión del agua

El esquema Metodológico empleado en el proceso de simulación del Balance Hídrico en la presa Cuchoquesera con Machine Learning se especifica detalladamente en la Figura 17.

Figura 17.

Diagrama de flujo metodológico del proceso de simulación del Balance Hídrico.



4.4. Diseño de investigación

Es de manera no experimental, debido que no se llega a realizar trabajos para recopilar datos, sino que fueron solicitados a la oficina de OPEMAN, realizando un viaje a la misma presa Cuchoquesera para tener conocimiento de la manera que se registra los datos en la Presa.

4.5. Población y muestra

4.5.1. Universo.

El universo está compuesto por la presa Cuchoquesera de la Región de Ayacucho, por ser el lugar de donde obtendremos los datos para realizar nuestro estudio de investigación.

4.5.2. Población.

La población está compuesta por los datos obtenidos de la estación hidrometeorológicas mediante sensores instalados en la presa Cuchoquesera, que son registrados por el equipo de servicio y mantenimiento de la misma Presa, en la región Ayacucho del 2013 al 2023.

4.5.3. Muestra.

La muestra será los datos que utilizaremos para entrenar los algoritmos de Redes Neuronales y TensorFlow para obtener las tablas y gráficos para nuestros análisis trazados en nuestros objetivos.

4.6. Técnicas e instrumentos

4.6.1. Técnicas.

- Se realiza una recopilación de los datos, de los parámetros hidrometeorológicos y del caudal de entrada y salida, solicitando a la oficina del OPEMAN.

- Programas de procesamiento de datos con el software Python y R-Studio.

4.6.3. Fuentes.

- Tesis de Grado.
- Revistas científicas
- Catálogos virtuales
- Páginas Web
- Libros y textos especializados

4.7. Validez y confiabilidad de instrumentos

- Validez: Los algoritmos de Machine Learning, mediante las RNA y TF son muy confiables para desarrollar un modelo de Balance Hídrico y obtener resultados confiables.
- Confiabilidad: Revisando fuentes bibliográficas, se encontró que hubo trabajos de datos hidrometeorológicos en modelos balances hídricos procesados mediante Redes Neuronales en el país y fuera del país, obteniendo una gran certeza de veracidad, siendo muy confiables los resultados obtenidos.

4.8. Técnicas de procesamiento de datos

Para poder conocer más de la presa y cómo funciona, se realiza un viaje guiado a la presa Cuchoquesera como se muestra en la Figura 19, donde nos recibieron amablemente llegando a brindarnos los datos que fueron solicitados a OPEMAN de los años del 2013 al 2020 de los parámetros hidrometeorológicos y los datos restantes del 2021 al 2023 fueron brindados en la Oficina de Archivos del GORE-Ayacucho, en las instalaciones de la oficina del OPEMAN. Después de haber obtenido los datos se procesaran mediante algoritmos de Machine Learning en RNA y TF, para simular el comportamiento de las estimaciones del cambio del flujo de agua en la presa entre los años 2013 al 2023 y estimar una predicción futura del embalse

y de los parámetros hidrometeorológicos, para prever las pérdidas de agua cada mes, y este procesos se llevara a cabo las siguientes etapas; el entrenamiento de datos introducidos a la Red que serán utilizados de los años 2016 al 2023.

Figura 19

Estación de Sunilla, ubicado 200 m de la presa Cuchoquesera.



Para el rendimiento y la fiabilidad del modelo se introducirán los datos desde 2013 al 2015, el tipo de red utilizado en el modelo es una red de base radial, y en cada capa de la red se utilizaran las funciones de transferencia como Log-Sigmoide, Tan-Sigmoide y Pure-Line, y la cantidad escogida de capas se basaran en el índice de rendimiento del error, donde estos datos ingresados transfieren información a través de estas capas para finalmente obtener los valores de salida, que seria los resultados finales de nuestro objetivos.

4.9. Aspectos éticos

El uso responsable de los datos de la estación hidrometeorológica de la presa Cuchoquesera se manejarán conforme al reglamento de la Oficina de Operaciones y Mantenimiento OPEMAN de la cuenca Cachi, quienes son los únicos autorizados para brindar

los permisos correspondientes para el procesamiento de los datos climatológicos e hidrológicos de la presa Cuchoquesera.

V. Resultados y discusión

5.1. Comportamiento de los parámetros climáticos e hidrológicos medidos en la estación hidrometeorológica que influyen en el embalse de la presa Cuchoquesera.

Para analizar los datos de los parámetros hidrometeorológicos de la presa Cuchoquesera, se recopilaron de las planillas de la primera estación ubicada en la misma presa del 2013 al 2018, Sin embargo, debido a la construcción del sistema de control de la presa, la estación fue trasladada a una ubicación cercana, actualmente conocida como la estación de Sunilla. En esta estación, los datos hidrometeorológicos procesados son del 2019 al 2023. La información utilizada en este estudio fue proporcionada por la oficina de OPEMAN y trabajadores de la presa Cuchoquesera, quienes, además ofrecieron un recorrido guiado por las instalaciones de la presa y la estación de Sunilla, permitiendo una mejor comprensión del sistema de monitoreo y recopilación de los datos.

Para el procesamiento de datos, las plantillas fueron ordenadas en un formato Excel según la fecha registrada, como se muestra en la Figura 18, con registros diarios. Se utiliza el interfaz de Google Colaboratory (Python, para desarrollar el algoritmo de programación. Mediante el uso de series temporales, redes neuronales y la biblioteca de TensorFlow, se llevó a cabo un análisis profundo de los datos hidrometeorológicos, obteniendo resultados mediante gráficos y tablas que permiten visualizar la evolución de estos parámetros a lo largo del tiempo proporcionando así una mejor interpretación de las tendencias y variaciones observadas. Los parámetros estudiados son:

- Precipitación
- Velocidad del viento
- Evaporación de tanque
- Humedad

- Nubosidad
- Temperatura mínima
- Temperatura máxima
- Temperatura ambiente

Siendo ordenados por día, como se muestra en la Tabla 3, ejecutado en el Colaboratory mediante el paquete de Numpy.

Tabla 3.


Datos de los parámetros hidrometeorológicos ordenados por día.

Fecha	Pp	Vv	Ev	HR	Nb	Tmin	Tmax	Tamb	Qi	Qs
01/01/2013	1.55	0.7	0	80	1	1.8	17.2	9.5	3.12	0
02/01/2013	0	0	0	76.1	2	3.8	17.4	10.6	2.76	0
03/01/2013	0.9	0	0.9	81.9	2	4.9	14.4	9.65	3.58	0
04/01/2013	1.3	0	1.3	73.1	3	5	17.2	11.1	3.98	0
05/01/2013	5.2	0	5.2	80.2	2	1.8	18.2	10	5.92	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
27/12/2023	0	0	0	89	5	2.1	17.5	9.8	1.41	1.01
28/12/2023	15.4	0	0	87	6	0.9	16.4	8.65	0.91	1.01
29/12/2023	1.8	0	0	91	7	3.1	16.2	9.65	5.35	1.01
30/12/2023	9.4	0	0	88	6	2	17.2	9.6	7.53	1.01
31/12/2023	5.9	0	0	90	6	3.1	18.3	10.7	9.95	1.01

En la Figura 20, se muestra la serie temporal diaria de todos los parámetros hidrometeorológicos mencionados anteriormente, correspondientes a la estación meteorológica Cuchoquesera.

Figura 20.

Series temporales diario de los parámetros hidrometeorológicos medidos en la estación meteorológica Cuchoquesera.



5.1.1. Descripción del comportamiento temporal de la Precipitación en la Presa Cuchoquesera.


Para el análisis de datos mediante series temporales de la precipitación (Pp) siendo su unidad de medida en mm, se toma en cuenta que los datos son tomados 2 veces al día en la estación y recopiladas como se muestra en la planilla de la Figura 18, los datos para realizar el procesamiento es la acumulación de los 2 datos tomados a las 19:00 horas más las 7:00 horas del día siguiente que son almacenados y recopilados para ser ejecutado como en la Tabla 3, para realizar las gráficas.

Para el desarrollo de series temporales, y mostrar el comportamiento y pronóstico de la Pp se toman los datos entre los años del 2013 hasta 2023, tomando los datos para el entrenamiento desde los años del 2013 al 2021, mientras que los datos de prueba para el pronóstico se toman los años del 2022 y 2023.

En la Figura 21, mostramos el comportamiento por día de los datos de entrenamiento de la Pp entre los años 2013 al 2021, donde se puede observar que existe una secuencia a través del tiempo mostrando a inicios de cada año mayor cantidad de precipitación en la presa Cuchoquesera, donde se espera recaudar los 80 millones de metros cubicos hasta finales de los meses de abril para la distribución de agricultura y consumo de la población de agua potable. En el año 2015 se observa que existio la mayor cantidad y constante de precipitación; y mientras que en el año 2018, se observa la mas baja cantidad de precipitación, siendo el año con poca temporadas de lluvia.

Figura 21.

Serie temporal de los datos diarios de entrenamiento de la precipitación desde enero del 2013 a diciembre del 2021.




5.1.1.1. Minimización de la pérdida variacional.

En la Figura 22, se muestra la minimización de la pérdida variacional del entrenamiento de datos diarios de la Pp, utilizando el optimizador Adam de TF, y teniendo en cuenta que el número de pasos variacional es de 500, mostrándonos en la curva que efectivamente desciende de 12000 a 9500 aproximadamente, estabilizándose y mejorando el entrenamiento del modelo.

Figura 22.

Minimización de la pérdida variacional diario de la precipitación.



En el caso de la minimización de los datos mensuales, se observa en la Figura 23, que muestra valores de 700 a 610 y los datos anuales en la Figura 24 que desciende de 85 a 60, se muestra pequeñas fluctuaciones debido, por la complejidad del análisis, la cantidad de datos y algún ruido en los datos de la Pp, el optimizador trata de estabilizar no alterando el resultado de los gráficos.

Figura 23.

Minimización de la pérdida variacional mensual de la precipitación.





Figura 24.

Minimización de la pérdida variacional anual de la precipitación.




5.1.1.2. Serie de tiempo estructurales para pronóstico con Tfp para la precipitación.

Se utiliza el paquete de TensorFlow probability, para pronosticar el comportamiento de la Precipitación (Pp), basándonos en los datos de los 2 últimos años para prever la Pp en el futuro, siendo estos denominados datos de prueba o pronóstico.

Se observa en la Figura 25, que los valores reales de la Pp, a los comienzos de cada año son abundantes. Sin embargo, al transcurso de la mitad de cada año, la Pp va disminuyendo gradualmente hasta alcanzar un mínimo, para volver aumentar, repitiendo este patrón en cada año.

Figura 25.

Predicción de la precipitación diario de la presa Cuchoquesera.



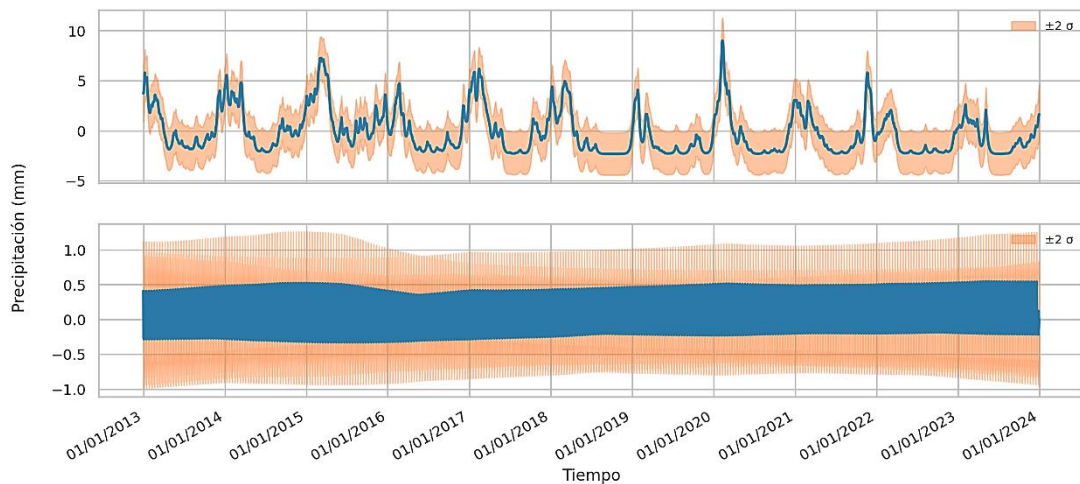
A partir de nuestro análisis con los datos de entrenamiento, el pronóstico por la línea anaranjada sugiere que la cantidad de lluvias pueda descender ligeramente para próximos años. Además, la zona sombreada de color anaranjado, muestra la incertidumbre en nuestra predicción, que a medida que transcurra el tiempo, la incertidumbre aumenta, lo que significa que la cantidad de lluvia realmente podría variar más de lo que inicialmente anticipamos,

debido a diferentes factores como la acumulación de incertidumbre de nuestro pronóstico o ruidos en nuestros datos por saltos de variación.

La Figura 26, se muestra los gráficos de la Tendencia y estacionalidad, donde se observa su evolución en el tiempo, donde las líneas azules muestran el comportamiento a largo del tiempo teniendo en cuenta el promedio global de referencia con valor de 0, de la cual nuestro gráfico fluctúa. Los datos positivos encima del valor de 0 muestran la abundancia de lluvias, mientras los valores debajo de 0, indica los días de escasez de lluvia.

Figura 26.

Tendencia y estacionalidad de la precipitación diario.




El área sombreada de anaranjado muestra la incertidumbre mediante la desviación estándar de los datos; los resultados que muestra es que en los primeros meses de cada año hay mayor intensidad de lluvias y a mediados de año disminuye hasta que nuevamente vuelve a ascender repitiendo ese ciclo, por otro lado la estacionalidad muestra una variabilidad constante de la precipitación en el transcurso del tiempo, teniendo un punto de referencia 0 que no afecta la estacionalidad, mostrando mayor varianza de Pp desde el año 2013 hasta el 2016, bajando esa varianza hasta mediados del 2016 y siendo constante en el tiempo hasta finales del 2023.

5.1.1.3. Serie de tiempo estructurales para pronóstico con Tfp para la precipitación mensual y anual.

La Figura 27, presenta un comportamiento y pronóstico mensual de la Precipitación (Pp), que se calcularon a partir de la acumulación de los datos registrados diariamente desde enero del 2013 hasta diciembre del 2023, obteniendo 132 datos mensuales. La serie temporal de la Pp nos muestra que llega a un máximo de 300 mm a inicios de los años 2015 y 2020 como se puede observar en los valores reales del gráfico.

Figura 27.

Predicción de la precipitación acumulada mensual de la presa Cuchoquesera.




El pronóstico refleja el comportamiento de los datos de entrenamiento, mostrando mayor precipitación en los primeros meses del año y disminuyendo hacia mediados de año, periodo en el cual se presentan meses con poca precipitación o días secos, sin embargo, esta tendencia se invierte en los últimos meses del año llegando a aumentar la Pp. El área sombreada en la gráfica representa la incertidumbre, la cual sigue el comportamiento del pronóstico a lo

largo de los años, de la cual, para años futuros, es probable que la Pp mantenga un comportamiento similar a los años analizados.

En la Figura 28, se observa la Tendencia y la estacionalidad mensual de la Pp. La Tendencia, registra una disminución en la precipitación de la presa Cuchoquesera a lo largo de los años, considerando el promedio global de referencia, se observa una abundancia de Pp hasta finales del año 2017, momento en la cual se aprecia un cambio significativo en los niveles de precipitación.

Figura 28.

Tendencia y estacionalidad de la precipitación acumulada mensual.




A partir del año 2019 a finales de 2023 la acumulación de la Pp fue constante debajo del promedio. La estacionalidad muestra un ciclo anual de la Pp, de la cual, a inicios de cada año se observa una abundancia de Pp, llegando a un mínimo a mediados de año, y finales de año vuelve ascender, para volver a repetir el ciclo. El área sombreada de anaranjado en ambos gráficos representa la incertidumbre, asociado al pronóstico de la precipitación en los años futuros tomando en cuenta la desviación estándar y la línea azul ilustra el comportamiento anual de la precipitación tomando en cuenta promedio global como punto de referencia.

La Figura 29, presenta el pronóstico anual de la precipitación mensual acumulada desde los años del 2013 hasta el 2023. Los valores reales indican un pico máximo de la Pp en 2015, alcanzando a 1500 mm, llegando a descender en años consecutivos, siendo en 2022 que se registró la menor Pp aproximadamente cerca de 500 mm, reflejando la variación en la precipitación cuando se compara el año 2023 con 2013.

Figura 29.

Predicción de la precipitación acumulada anual de la presa Cuchoquesera.




A partir de 2021, se estableció una línea de separación entre los datos de entrenamiento y los pronósticos, donde este último es representada por la línea anaranjada, que muestra una disminución de la precipitación en los siguientes años, no obstante, es importante destacar que existe una considerable incertidumbre en el gráfico, que es evidenciada por el área anaranjada, que indica las posibles variaciones de la Pp.

La Figura 30, nos muestra la Tendencia y la estacionalidad anual de la precipitación (Pp), siendo el promedio como punto de referencia. La Tendencia indica una disminución pronosticada en la precipitación, siendo esta más pronunciada desde el año 2019 hasta el 2023; la banda de incertidumbre refleja una mayor variabilidad en los extremos de los años 2013 al

2015 y desde el 2019 a 2023, evidenciando los cambios de la Pp a lo largo del tiempo. Además, la estacionalidad muestra los cambios de la Pp, tomando como referencia el promedio global, siendo los valores positivos encima del promedio estacional, que representan el aumento de lluvias, mientras que aquellos debajo del promedio, indican años con menor precipitación o años con escasez de lluvia, la banda de incertidumbre representa la variabilidad de los posibles cambios y la confiabilidad del pronóstico de la Pp.

Figura 30.

Tendencia y estacionalidad de la precipitación acumulada anual.



5.1.2. Descripción del comportamiento temporal de la Velocidad de viento en la Presa Cuchoquesera.


En los siguientes gráficos, se presentan el comportamiento pronosticado de la velocidad del viento diarios, con unidad de medida en m/s^2 , que van entre 2013 y 2023, sin embargo, los datos fueron registrados en los años 2016, 2019, 2020, 2022 y 2023, mientras que en los demás años no se han registrado datos. Por lo tanto, este parámetro no se redundará en profundo análisis dado que no será necesario para el desarrollo del balance hídrico por falta de datos.

5.1.2.1. Minimización de la pérdida variacional.

En la Figura 31, se ilustra la minimización de la pérdida variacional durante el entrenamiento de datos, utilizando el optimizador Adam de TF, y considerando que el número de pasos variacional es de 500, la curva demuestra un descenso de 8500 a 5500 aproximadamente, por lo que el modelo se estabiliza y mejora a medida que avanza el entrenamiento.

Figura 31.

Minimización de la pérdida variacional de la velocidad del viento.




5.1.2.2. Serie de tiempo estructurales para pronóstico con Tfp para la Velocidad de viento.

La Figura 32, presenta mediante los datos de entrenamiento desde enero 2013 hasta diciembre 2021, junto a los datos de previsión de los años 2022 y 2023,0 el comportamiento del pronóstico diarios de la velocidad de viento (Vv). Los valores reales por la línea azul reflejan fluctuaciones de la Vv a lo largo de los años, presentando una tendencia negativa por la línea anaranjada del pronosticó, Esta tendencia nos hace la referencia que habrá una

disminución en valores futuros de la Vv, no obstante, el área de incertidumbre de la serie temporal se amplía a medida que transcurre el tiempo implicando una mayor variabilidad del pronóstico, mientras más avance el tiempo.

Figura 32.

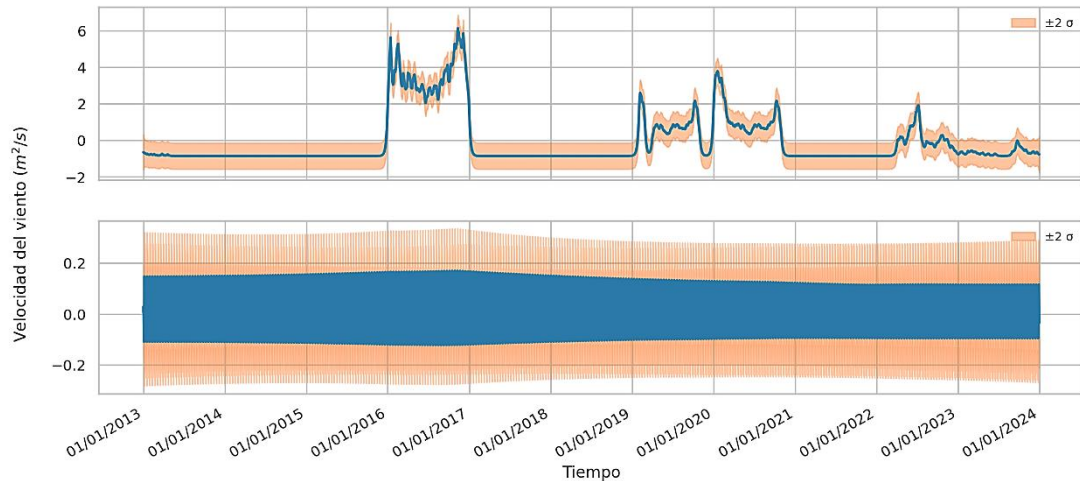
Predicción de la Velocidad de viento de la presa Cuchoquesera diario.



Por otro lado, la Figura 33, ilustra la Tendencia y estacionalidad utilizando como referencia el componente del promedio global de la Vv y desviación estándar para determinar la varianza de la banda de incertidumbre. La Tendencia presenta valores por encima de la línea de referencia, debido a la insuficiencia de datos registrados en ciertos periodos; asimismo, se observa valores debajo y cerca de la línea de referencia, correspondiente a los datos faltantes. Mientras que la estacionalidad, se observa un crecimiento notable de variaciones en el año 2016, siendo esta más pronunciada debido a la variabilidad diaria de la Vv en ese año en relación al promedio global, que se establece en 0. En los primeros años se observan variaciones más pronunciados debido a altas fluctuaciones registradas en 2016, disminuyendo posteriormente, mientras que la banda de incertidumbre es constante en el transcurso del tiempo, aunque muestra una ligera pronunciación en el año 2016 debido a la variabilidad en ese año.

Figura 33.

Tendencia y estacionalidad de la velocidad de viento diario.



5.1.3. Descripción del comportamiento temporal de la Evaporación de tanque de agua en la Presa Cuchoquesera.


Los datos del almacenamiento de tanque de agua se registran dos veces al día, y al restar estos valores, se obtiene los datos de evaporación (Ev), que se recopilan en las planillas y formato Excel de la presa Cuchoquesera, donde sumando estos datos se obtiene los gráficos de evaporación, siendo su unidad de medida en mm.

5.1.3.1. Minimización de la pérdida variacional.

En Figura 34, se muestra la minimización de la pérdida variacional del entrenamiento de los datos diarios de la Ev, empleando el optimizador Adam de Tf, y considerando 500 pasos variacional, la curva muestra que efectivamente desciende aproximadamente de 10500 a 8000, lo que indica que para los datos diarios de la Ev se estabiliza y mejora el entrenamiento del modelo.

Figura 34.

Minimización de la pérdida variacional diario de la Evaporación.



Por otro lado, en la Figura 35, se observa la minimización de los datos mensuales, donde la pérdida varía de 690 a 630; y de manera similar en la Figura 36 se observa la minimización de los datos anuales que varía de 78 a 64. En estos 2 gráficos se presentan fluctuaciones debido a complejidad del análisis, la cantidad de datos y el ruido presente en los datos de Ev; donde las fluctuaciones más pronunciadas se dan en los datos anuales, a lo que el optimizador busca estabilizar el modelo sin alterar los resultados gráficos.

Figura 35.

Minimización de la pérdida variacional mensual de la Evaporación.





Figura 36.

Minimización de la pérdida variacional anual de la Evaporación.




5.1.3.2. Serie de tiempo estructurales para pronóstico con Tfp para la Evaporación del tanque de agua.

La Figura 37, presenta las series temporales utilizando Tfp, siendo los datos de entrenamiento desde 01 de enero del 2013 hasta 31 de diciembre del 2021 y el pronóstico desde 01 de enero del 2022 hasta 01 de enero del 2024. El comportamiento del valor real de la evaporación (Ev) en mm, representada por las líneas azules ilustran los máximos y mínimos de los datos históricos diarios de la Ev. Se destaca que el año 2016 presenta mayor variabilidad de la Ev en la presa, mientras el 2020 muestra una notable estabilidad, sin cambios significativos.

Figura 37.

Predicción de la Evaporación diario de la presa Cuchoquesera.




En el pronóstico, se identifica una tendencia positiva de crecimiento representada por la línea anaranjada, mostrando que la Ev en la presa Cuchoquesera experimentara un aumento leve a lo largo del tiempo, teniendo en cuenta que el área de incertidumbre mostrada por la región anaranjada, muestra un incremento progresivo por posibles variaciones en eventos futuros.

Por otro lado, la Figura 38, presenta la Tendencia y estacionalidad de la Ev a través del tiempo en la presa Cuchoquesera. La Tendencia, en el periodo de 2013 al 2015 se observan fluctuaciones significativas que alcanzan picos por encima del promedio global, lo cual se relacionan con las altas temperaturas y otros factores ambientales; posteriormente, entre los años del 2018 al 2021, los valores tienden a estabilizarse situándose por debajo del promedio de referencia, lo que indica días con menor Ev debido a las condiciones frías en esos años.

Figura 38.

Tendencia y estacionalidad de la Evaporación diario.




La banda de incertidumbre se mantiene estrecha a lo largo de los años, sugiriendo estabilidad en la EV para años futuros, sin variaciones notables. La estacionalidad revela una mayor variabilidad de la Ev a inicios del 2013 disminuyendo hasta 2019, a partir de ese momento la variabilidad de la Ev se llega a estabilizar hasta el 2024. En esta fase, la banda de incertidumbre es amplia al comienzo de año, luego gradualmente se estrecha con el tiempo, lo que demuestra la confiabilidad y precisión del comportamiento representado en el gráfico para la predicción.

5.1.3.3. Serie de tiempo estructurales para pronóstico con Tfp para la Evaporación mensual y anual.

La Figura 39, mediante la línea azul que denota el comportamiento real de la evaporación mensual, siendo acumulada de los datos registrados diariamente desde enero del 2013 a diciembre del 2023. Se observa que la acumulación máxima es de 300 mm a inicios del 2015, tras la cual en años posteriores trata de estabilizarse; sin embargo, a partir de 2018, se llega a apreciar una disminución notable de la Ev llegando 0 mm en algunos meses hasta inicios de 2021. Posteriormente, la Ev se estabiliza nuevamente en torno a 100 mm desde mediados del 2021 hasta mediados del 2023.

Figura 39.

Predicción de la Evaporación acumulada mensual de la presa Cuchoquesera.




La línea anaranjada, representa al pronóstico, con una tendencia similar con algunos picos máximos de poca variación que oscila en torno a los 100 mm. El área sombreada que indica la incertidumbre se amplía a medida que transcurre los años, indicando mayor variación del pronóstico cuando más avanza en el tiempo.

Por otro lado, en la Figura 40, se muestra la tendencia de línea local mensual y la estacionalidad. El gráfico de tendencia nos muestra las variaciones de la Ev oscilando sobre el promedio global de referencia, donde los valores encima del promedio muestran los tiempos de mayor Ev siendo la más notable en los años de 2015 al 2017, mientras los debajo del promedio global, son meses de baja Ev, siendo la más prolongada a partir del 2018 al 2021. El área anaranjada de la tendencia lineal muestra un cambio estable de la Ev, siendo más anchas, en tendencias de poca variación, mostrando un excelente comportamiento de la variación de la Ev.

Figura 40.

Tendencia y estacionalidad de la Evaporación acumulada mensual.

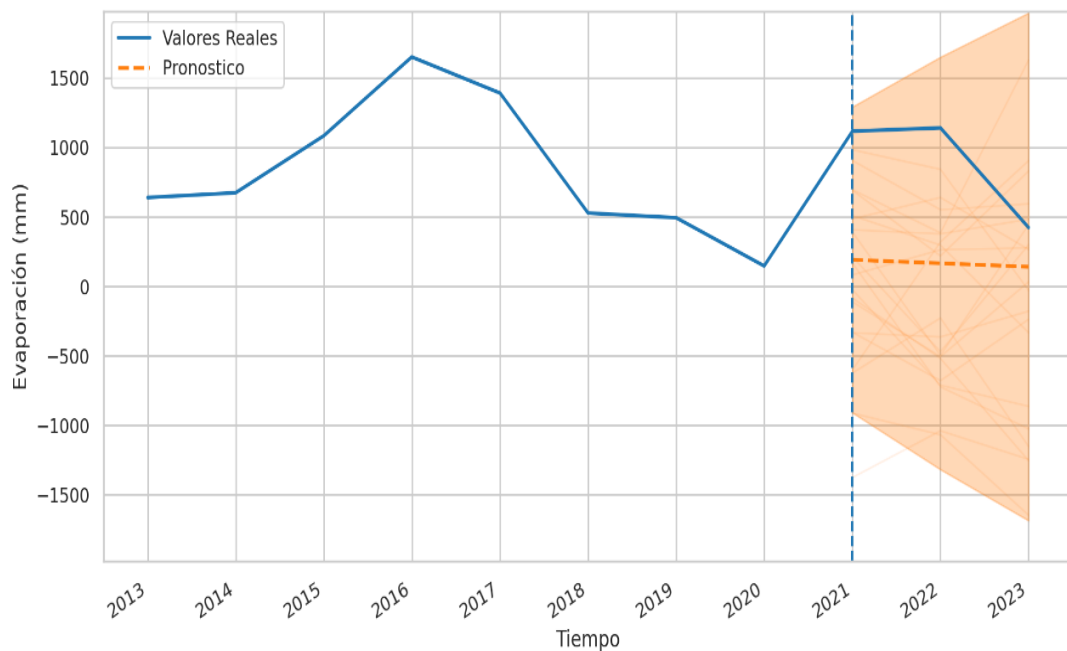


La estacionalidad muestra el ciclo de la Ev en cada año, mostrando a inicios de año con una Ev máxima, debido a que se encuentran en el tiempo de verano por temperaturas altas, mientras que a mediados de años estas descienden a su mínimo, por las temporadas de frío (estaciones de otoño e invierno), permaneciendo constante hasta el mes de diciembre de la cual vuelve a ascender empezando nuevamente para repetir el ciclo. La banda de incertidumbre nos muestra las posibles variaciones y la confiabilidad de la Ev a lo largo del tiempo.

La Figura 41, se observa el comportamiento de la evaporación representado por la línea azul, la cual utilizamos la acumulación de los datos mensuales de Ev para cada año. En los años del 2013 al 2016 la Ev presenta un crecimiento que podría deberse por el aumento de días secos y calurosos en esos años. A partir de 2016 al 2020, la Ev decrece hasta aproximadamente a 200 mm, que podría deberse por días húmedos y bajas temperaturas; para el 2021 la Ev asciende a 1100 mm, manteniéndose en ese nivel hasta el 2022, y disminuyendo a 450 mm para el 2023.

Figura 41.

Predicción de la Evaporación acumulada anual de la presa Cuchoquesera.




El pronóstico representado por la línea anaranjada, muestra una tendencia ligeramente negativa con un decrecimiento gradual para próximos años, mediante los datos de entrenamiento del 2013 al 2021; sin embargo, el área de incertidumbre también muestra un incremento a largo del transcurso del tiempo, reflejando la variabilidad y la confianza del modelo en sus predicciones.

Por otro lado, la Figura 42, presenta la Tendencia y la estacionalidad de los datos anuales. La Tendencia muestra valores encima del promedio global de referencia durante todo el periodo estudiado, esto es posible por la presencia de condiciones climáticas como ausencia de lluvias y bajas temperaturas en los años analizados; siendo la banda sombreada alrededor de la línea de tendencia, la incertidumbre de estas estimaciones, indicando las posibles variaciones a lo largo del tiempo.

Figura 42.

Tendencia y estacionalidad de la Evaporación acumulada Anual.



Mientras que la estacionalidad, sigue el comportamiento de la Ev, como punto de referencia al promedio estacional, donde los valores positivos en la gráfica, indican los años donde la Ev fue mayor al promedio específicamente en 2013, 2016, 2017, 2021 y 2022; mientras, que los valores negativos indican menor presencia de Ev comparado con el promedio estacional en 2014, 2018 y 2020; siendo la banda de incertidumbre más ancha que en el gráfico de la Tendencia, sugiriendo mayor variabilidad en los patrones estacionales.

5.1.4. Descripción del comportamiento temporal de la Humedad Relativa en la Presa Cuchoquesera.


Para los gráficos de la humedad relativa, siendo su unidad de medida en porcentaje, los datos registrados en la planilla son tomadas 3 veces al día, y el gráfico se realiza con el promedio de estos 3 datos. Para manejar las anomalías registradas, se realizó un filtro en estas anomalías utilizando el promedio de 5 datos anteriores y 5 datos posteriores a cada valor anómalo.

5.1.4.1. Minimización de la pérdida variacional.

En Figura 43, se muestra la minimización de la pérdida variacional del entrenamiento de los datos diarios de la humedad relativa (HR), empleando el optimizador Adam de TF, y considerando 500 pasos variacional, la curva muestra que efectivamente desciende aproximadamente de 15000 a 10000, lo que indica que para los datos diarios de la HR se estabiliza y mejora el entrenamiento del modelo.

Figura 43.

Minimización de la pérdida variacional diario de la humedad relativa.



Por otro lado, en la Figura 44, se observa la minimización de los datos mensuales, donde la pérdida varía de 530 a 460; y de manera similar en la Figura 45, se observa la minimización de los datos anuales que varía de 70 a 42.

Figura 44.

Minimización de la pérdida variacional mensual de la humedad relativa.





Figura 45.

Minimización de la pérdida variacional anual de la humedad relativa.




En estos 2 gráficos se presentan pequeñas fluctuaciones debido a la complejidad del análisis, la cantidad de datos y el ruido presente en los datos de HR; no alterando mucho el resultado de los gráficos, gracias a que el optimizador busca estabilizar el modelo.

5.1.4.2. Serie de tiempo estructurales para pronóstico con Tfp para la Humedad Relativa.

La Figura 46, se presenta el comportamiento de la Humedad Relativa (HR), utilizando los datos de entrenamiento desde enero de 2013 hasta diciembre de 2021 y los datos previsión desde enero del 2022 hasta finales del 2023. El comportamiento de los valores reales diarios de la HR, por la línea azul, muestran una oscilación mayormente alrededor del 80 %; siendo, en 2013 donde se registra en un prolongado periodo de tiempo del 100% de HR indicando que una humedad extremadamente alta, mientras que en 2018 se observan periodos con HR al 0 % en el año 2018, indicando que fue un año notablemente seco.

Figura 46.

Predicción de la Humedad Relativa diario de la presa Cuchoquesera.

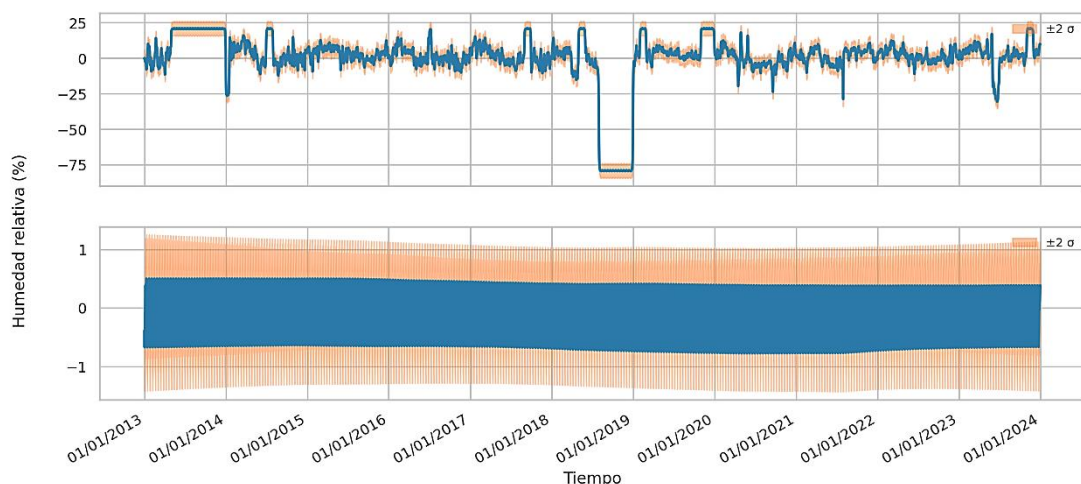


La línea de pronóstico de anaranjado muestra una tendencia de disminución gradual para eventos futuros, sugiriendo que habrá más días con menor presencia de HR conforme avance el tiempo. El área sombreada indica la incertidumbre a lo largo del tiempo refleja la variabilidad y la disminución de precisión a medida que nos alejamos de los datos de entrenamiento.

Por otro lado, la Figura 47, se presenta la Tendencia y la estacionalidad de la humedad relativa. La Tendencia, muestra las crecidas y descensos de la humedad relativa oscilando en el promedio global de referencia, variando notablemente en el año 2013 por estar encima del promedio referencial y a finales de 2018 por estar muy por debajo. La banda anaranjada alrededor de la línea azul indica la incertidumbre de la tendencia, mostrando una alta confiabilidad de las estimaciones a lo largo de los años

Figura 47.

Tendencia y estacionalidad diario de la Humedad Relativa.



La estacionalidad muestra las variaciones de la HR oscilando de -1 a 1, indicando que no hay cambios estacionales significativo; Sin embargo, en 2018 hasta 2021 se observa una


mayor variación. La banda de sombreada muestra un cierto grado de incertidumbre en los datos, reflejando la variabilidad estacional de la HR.

5.1.4.3. Serie de tiempo estructurales para pronóstico con Tfp para la Humedad Relativa mensual y anual.

La Figura 48, presenta el comportamiento mensual obtenidos del promedio diario de la Humedad Relativa (HR) del 2013 al 2023. Los datos de entrenamiento abarcan desde enero de 2013 hasta diciembre de 2021, mientras que los datos de previsión abarcan desde enero de 2022 hasta diciembre de 2023. Las líneas azules muestran los valores reales de los datos mensuales de la HR, indicando que hay meses que alcanzan al 100 %, especialmente en 2013, donde hubo más meses prolongados con alta humedad a comparación con otros años, mientras que el 2018 se presenta meses con niveles de HR del 0 %.

Figura 48.

Predicción de la Humedad Relativa media mensual de la presa Cuchoquesera.




La línea anaranjada que representa al pronóstico basadas en el entrenamiento de datos, muestra un comportamiento similar a los valores reales, oscilando alrededor del 85%. El área sombreada representa a la incertidumbre, que se amplía a través del tiempo, a lo que indica un incremento a la variabilidad y una disminución de la predicción a medida que avancemos más allá del periodo de entrenamiento.

Por otro lado, en la Figura 49, se presenta la Tendencia y la estacionalidad de la HR. La Tendencia, muestra los máximos y mínimos, teniendo como referencia al promedio global con valor de 0, donde los valores positivos indican meses con mayor humedad, siendo la más notable en 2013; mientras que los valores debajo de 0, señala meses de menor humedad siendo la más notable en 2018. La banda anaranjada alrededor de la línea azul indica la incertidumbre de la estimación de la tendencia, siendo estas estimaciones seguras y confiables a lo largo del tiempo.

Figura 49.

Tendencia y estacionalidad media mensual de la Humedad Relativa.




La estacionalidad nos muestra un ciclo que se repite cada año, indicando que a los inicios de año presentan mayores niveles HR, con pequeñas fluctuaciones que descienden

aproximadamente entre agosto a septiembre, para luego aumentar y repetir el ciclo anual. La banda anaranjada, muestra la incertidumbre de la estacionalidad, que nos proporciona confianza en el rango de variación de la HR en cada mes a lo largo del tiempo.

La Figura 50, muestra el comportamiento y la predicción anual de la HR en la presa Cuchoquesera. Para obtener los datos anuales se utilizó el promedio de los datos mensuales de cada año. La línea azul representa el comportamiento anual de la HR, indicando una estabilidad continua hasta 2018, año en que se observa la humedad más baja, llegando aproximadamente al 50 %. La línea anaranjada, representa al pronóstico basados a los datos de entrenamiento, indicando un decrecimiento muy lento en los niveles de la HR. El área sombreada que indica la incertidumbre, aumenta con el tiempo, sugiriendo una mayor variabilidad y una disminución en la precisión de la predicción a medida que avanzamos a lo largo de los años después del entrenamiento.

Figura 50.

Predicción de la Humedad Relativa media anual de la presa Cuchoquesera.




Por otro lado, la Figura 51, muestra la Tendencia y la estacionalidad de la HR anual. La Tendencia muestra una disminución lenta de la HR hasta llegar al promedio global en 2018,

tras lo cual se mantiene constante hasta el 2023. La banda de incertidumbre alrededor de la línea azul, indica la variabilidad de los datos y la confiabilidad de las estimaciones, con un rango de -20 a 20. La estacionalidad muestra los años con mayor HR por encima del promedio de referencia, destacando los años de 2013, 2016, 2019, 2022 y 2023 con pequeñas desviaciones. En contraste, el 2018 se presentó la HR más baja, posiblemente a cambios climáticos abruptos. La banda anaranjada, indica la incertidumbre de la estacionalidad, que nos proporciona confianza en el rango de variación de la HR a lo largo del tiempo.

Figura 51.

Tendencia y estacionalidad de la Humedad Relativa media anual.



5.1.5. Descripción del comportamiento temporal de la Nubosidad en la Presa Cuchoquesera.


La nubosidad, se registra en una planilla 3 veces al día, utilizando el promedio de las mediciones, para elaborar los gráficos. Su unidad de medida es en octas, siendo los valores oscilantes de 0 a 8 octas, donde 0 indica un día completamente despejado, y 8 indica que el cielo está cubierta totalmente de nubes, captadas en la estación de Sunilla de la presa Cuchoquesera captadas por la estación de Sunilla.

5.1.5.1. Minimización de la pérdida variacional.

En Figura 52, se muestra la minimización de la pérdida variacional del entrenamiento de los datos diarios de Nubosidad (Nb), empleando el optimizador Adam de TF, y considerando 500 pasos variacional, la curva muestra que efectivamente desciende aproximadamente de 8000 a 6250, lo que indica que para los datos diarios de la Nb se estabiliza y mejora el entrenamiento del modelo.

Figura 52.

Minimización de la pérdida variacional diarios de la Nubosidad.



Por otro lado, en la Figura 53, se observa la minimización de los datos mensuales, donde la pérdida varía de 300 a 220; y de manera similar en la Figura 54, se observa la minimización de los datos anuales que varía de 50 a 20. En estos 2 gráficos se presentan pequeñas fluctuaciones debido a complejidad del análisis, la cantidad de datos y el ruido presente en los datos de Nb; no alterando mucho el resultado de los gráficos, gracias a que el optimizador busca estabilizar el modelo.

Figura 53.

Minimización de la pérdida variacional mensual de la Nubosidad.





Figura 54

Minimización de la pérdida variacional anual de la Nubosidad.




5.1.5.2. Serie de tiempo estructurales para pronóstico con Tfp para la Nubosidad.

La Figura 55, muestra el comportamiento diario y la predicción de la Nb en la presa Cuchoquesera. La línea azul, indica una variabilidad que va entre 0 y 8 octas en el periodo analizado. La línea anaranjada representa la predicción de la Nb, que muestra una tendencia positiva, sugiriendo un incremento de la Nb a lo largo del tiempo.

Figura 55.

Predicción de la Nubosidad diarios de la presa Cuchoquesera.




El área sombreada alrededor de la línea azul, indica la incertidumbre de las predicciones, donde la amplitud del área sugiere que hay una alta variabilidad y una menor precisión en las predicciones mientras más avance el tiempo y se aleje de los datos de entrenamiento.

Por otro lado, la Figura 56, presenta la Tendencia y la estacionalidad de la nubosidad. La Tendencia muestra la variación de la Nb a través del tiempo, con más valores por encima del promedio global de referencia, esto nos indica que hubo una gran cantidad de nubes considerables en la presa.

Figura 56.

Tendencia y estacionalidad diarios de la Nubosidad.




La banda de incertidumbre anaranjada, alrededor de la línea azul, no varía mucho, sugiriendo una mayor confiabilidad y precisión para pronosticar la Nb más adelante. Mientras que la estacionalidad muestra una variación continua y periódica a través del tiempo. La banda de incertidumbre de la línea estacional, proporciona una medida de confianza en las predicciones de la Nb en cada día, siendo estas un poco más anchas.

5.1.5.3. Serie de tiempo estructurales para pronostico con Tfp para la Nubosidad mensual y anual.

La Figura 57, muestra el comportamiento de la Nb en la presa Cuchoquesera. Los datos utilizados son el promedio de los datos diarios de cada mes desde 2013 hasta 2023, siendo los datos de entrenamiento desde enero 2013 hasta diciembre 2021 y los pasos de datos previsión desde enero del 2022 hasta finales del 2023. Líneas azules muestran los valores reales mensuales de Nb, donde se observan picos que alcanzan aproximadamente 6 octas a inicios de cada año, mientras entre los meses de junio y julio, los valores oscilan de 0 a 2 octas, indicando cielos despejados en la presa.

Figura 57.

Predicción de la Nubosidad media mensual de la presa Cuchoquesera.



La línea anaranjada del pronóstico basados en los datos de entrenamiento, muestra un comportamiento similar a los valores reales oscilando de manera consistente. El área de incertidumbre asociada a las predicciones, muestra una variabilidad de los datos y una menor precisión en las predicciones a medida que nos alejamos de los datos de entrenamiento.


Por otro lado, en la Figura 58, se presenta la Tendencia y la estacionalidad de la Nb, considerando el promedio global de los datos. La Tendencia muestra un aumento de la Nb entre los años de 2013 y 2015, tratando de estabilizarse con un pequeño decrecimiento a finales de 2018, logrando ascender nuevamente hasta el 2023. La banda de incertidumbre, indica la variabilidad de los datos, lo que sugiere una alta confiabilidad en las estimaciones futuras de la Nb.

Mientras la estacionalidad muestra un ciclo repetitivo cada año, donde se observa mayor presencia de nubes en los primeros meses del año, disminuyendo hasta un mínimo a mediados de año y volviendo a ascender a finales de año para repetir el ciclo. La banda

anaranjada en la gráfica de estacionalidad, indica la incertidumbre, proporcionando una medida de confianza en las variaciones estacionales de la nubosidad a lo largo del tiempo.

Figura 58.


Tendencia y estacionalidad de la Nubosidad media mensual.



La Figura 59, muestra el comportamiento anual de la nubosidad representada por la línea azul. Estos datos se obtuvieron al promediar los datos mensuales de cada año, de la cual se observa que el año 2014 con mayor Nb con un promedio de 4 octas, mientras que el menor fue el 2013 con un promedio de 2 octas. La línea anaranjada nos muestra un incremento gradual en la Nb. Mientras que la expansión del área de incertidumbre indica una creciente variabilidad y menor precisión en las predicciones a medida que avanzamos en el tiempo.

Figura 59.


Predicción de la Nubosidad media anual de la presa Cuchoquesera.



Por otro lado, la Figura 60, muestra la Tendencia y la estacionalidad de la Nb. La Tendencia indica que hubo un crecimiento en la Nb, siendo el año 2018 el punto de inflexión en el promedio global de referencia. Antes del 2018 la cantidad de nubes era menor que a partir de ese año se observa un incremento, con datos por encima del promedio global. La banda de incertidumbre es más ancha en los extremos y más delgada en el intermedio, indicando la variabilidad en los datos, como también la confiabilidad en las predicciones a largo plazo.

Figura 60.

Tendencia y estacionalidad de la Nubosidad media anual.



La estacionalidad, muestra el mismo comportamiento de la Figura 59 teniendo en cuenta que varía alrededor del promedio estacional como referencia; mostrando que, en los años 2014 y 2020 presentan niveles por encima del promedio estacional, que indica que hubo más concentración de nubes en ese periodo. Mientras en 2013, 2018 y 2023, muestran niveles debajo del promedio estacional indicando temporada con menos nubes.

Por último, en 2015, 2016, 2017, 2019, 2021 y 2022, muestran niveles de Nb cercana al promedio estacional, indicando la presencia de nubes moderada. La banda de incertidumbre sugiere una medida de variabilidad y confiabilidad de los datos para pronostico a largo plazo, teniendo en cuenta la variabilidad en los extremos.

5.1.6. Descripción del comportamiento temporal de la Temperatura mínima en la Presa Cuchoquesera.


En los siguientes gráficos, se muestra el comportamiento diario, mensual y anual de la temperatura mínima (T_{\min}), estos datos fueron tomados 3 veces al día en la estación de Sunilla y registrados en una planilla cada día por OPEMAN, siendo su unidad de medida grados Celsius °C.

5.1.6.1. Minimización de la pérdida variacional.

En Figura 61, se muestra la minimización de la pérdida variacional del entrenamiento de los datos diarios de Temperatura mínima ($T_{\text{mín}}$), empleando el optimizador Adam de TF, y considerando 500 pasos variacional, la curva muestra que efectivamente desciende aproximadamente de 12000 a 6800, lo que indica que para los datos diarios de la $T_{\text{mín}}$ se estabiliza y mejora el entrenamiento del modelo.

Figura 61.

Minimización de la pérdida variacional diarios de la temperatura mínima.



Por otro lado, en la Figura 62, se observa la minimización de los datos mensuales, donde la pérdida varía de 380 a 260; y de manera similar en la Figura 63 se observa la minimización de los datos anuales que varía de 55 a 26.

Figura 62.

Minimización de la pérdida variacional mensuales de la temperatura mínima.





Figura 63.

Minimización de la pérdida variacional anual de la temperatura mínima.




En estos 2 gráficos se presentan pequeñas fluctuaciones debido a complejidad del análisis, la cantidad de datos y el ruido presente en los datos de $T_{\text{mín}}$; no alterando mucho el resultado de los gráficos, gracias a que el optimizador busca estabilizar el modelo.

5.1.6.2. Serie de tiempo estructurales para pronóstico con Tfp para la Temperatura mínima.

La Figura 64 presenta el comportamiento y pronóstico diario de la temperatura mínima. Las líneas azules que representan a los valores reales de la $T_{\text{mín}}$ diaria, oscilan entre $-5\text{ }^{\circ}\text{C}$ y $13\text{ }^{\circ}\text{C}$ aproximadamente en cada año, observando que los valores máximos de la $T_{\text{mín}}$ se dan a principios de cada año, descendiendo hacia mediados de año. A partir del 2020 el valor máximo de la $T_{\text{mín}}$ descendió a $5\text{ }^{\circ}\text{C}$ oscilando hasta $-5\text{ }^{\circ}\text{C}$ en su mínimo.

Figura 64.

Predicción de la Temperatura mínima diario de la presa Cuchoquesera.




El pronóstico, muestra una tendencia de decrecimiento gradual a lo largo del tiempo, teniendo en cuenta que el área de incertidumbre alrededor de la línea de pronóstico, sugiere una alta variabilidad y una menor presión en las predicciones a través avance el tiempo

Por otro lado, La Figura 65 muestra la Tendencia y la estacionalidad diarios de la Tmín. La Tendencia, muestra la variación de la temperatura tomando como referencia al promedio global, siendo el 2013, 2018 y del 2020 hasta el 2023, años que estuvieron por debajo del promedio global, indicando la presencia de más temperaturas frías registradas debido a diferentes fenómenos climatológicos y ambientales; mientras que entre 2014 hasta enero de 2018, las Tmín estuvieron mayormente por encima del promedio global, lo que indica que las Tmín fueron relativamente altas con respecto al promedio global.

Figura 65.

Tendencia y estacionalidad de la temperatura mínima diarios.




La estacionalidad muestra la variación diaria de la Tmín siendo constante en los años del 2013 al 2023, con una pequeña desviación en 2018 y 2019. El área de incertidumbre en ambos gráficos proporciona una medida de la variabilidad y la confiabilidad de las predicciones, facilitando una planificación precisa y adaptativa mientras avance el tiempo.

5.1.6.3. Serie de tiempo estructurales para pronóstico con Tfp para la Temperatura mínima mensual y anual.

La Figura 66, muestra el comportamiento y pronóstico de la $T_{mín}$ mensual desde el 2013 al 2023, los datos utilizados se obtienen del promedió de los datos diarios de cada mes. La línea azul muestra un ciclo de máximos y mínimos, donde los máximos de la $T_{mín}$ se registraron a inicios de cada año, siendo el 2023 el año en que presenta en máximo valor registrado; mientras que mediados de cada año la temperatura disminuye, con $T_{mín}$ por debajo del 0°C siendo en 2013, 2021 y 2023 que alcanzan a -3°C , la línea vertical azul indica la separación de los datos de entrenamiento y prueba.

Figura 66.

Predicción de la Temperatura mínima media mensual de la presa Cuchoquesera.




El pronóstico de la gráfica, muestra un comportamiento similar a los datos de entrenamiento, oscilando entre 3 a 5°C . El área de incertidumbre asociada al pronóstico, crece en el tiempo, lo que sugiere una mayor variabilidad y menor precisión en las predicciones mientras más nos alejemos en el tiempo.

Por otro lado, la Figura 67, muestra la Tendencia y la estacionalidad mensual de la $T_{mín}$. La tendencia lineal muestra las oscilaciones de máximos y mínimos con relación al promedio global de referencia, donde los valores encima de la referencia indican las temperaturas moderadamente altas, siendo meses con una temperatura no tan fría, mientras los valores debajo de la referencia corresponden a meses más frío. La estacionalidad muestra el ciclo que se repite en cada año, siendo aproximadamente los meses de febrero a abril los valores más altos que se registran de la $T_{mín}$, que indican que las temperaturas menos frías, mientras que a mediados de cada año se registran las Temperaturas más frías. La banda de incertidumbre en ambos casos, proporciona una variabilidad y confiabilidad para poder predecir el comportamiento futuro de la $T_{mín}$.

Figura 67.

Tendencia y estacionalidad de la temperatura mínima media mensual.




La Figura 68 muestra el comportamiento y predicción anual de la $T_{mín}$, obtenidos a partir del promedio de los valores mensuales en cada año. Los valores reales por la línea azul, muestran que el 2014 se registró el valor máximo de la $T_{mín}$ de 6,5 °C aproximadamente, mientras en los años 2013 y 2018 se registraron los valores mínimos aproximadamente 1 °C cercano a 0 °C, en los años de 2020 hasta 2023 la $T_{mín}$ se ha mantenido constante cercano a 2

°C. El pronóstico sugiere una disminución lenta en próximos años. El área de incertidumbre crece con el tiempo después de los datos de entrenamiento sugiriendo una mayor variabilidad y una menor precisión para la predicción a lo largo que avance el tiempo.

Figura 68.

Predicción de la Temperatura mínima media anual de la presa Cuchoquesera.




Por otro lado, la Figura 69 muestra la Tendencia y estacionalidad de los datos anuales de la T mín. La tendencia lineal muestra una disminución lenta a lo largo de los años analizados, pero permanece muy cercana al promedio global de referencia; indicando que la Tmín no varía mucho a través de los años. La estacionalidad, muestra un comportamiento similar al de la Figura 68, tomando como referencia al promedio estacional. Los años 2013 y 2018 se encuentran por debajo del promedio estacional, indicando los años más fríos; mientras que los años del 2014 hasta 2017 y el 2019 están por encima del promedio, indicando años menos fríos. Los años de 2020 hasta el 2023, están cerca al promedio estacional, indicando estabilidad

climática. La banda de incertidumbre en ambos gráficos, proporciona una medida de variabilidad y confiabilidad para predicciones del comportamiento futuro de la Tmín.

Figura 69.

Tendencia y estacionalidad de la temperatura mínima media anual.



5.1.7. Descripción del comportamiento temporal de la Temperatura máxima en la Presa Cuchoquesera.


En los siguientes gráficos, se muestra la temperatura máxima. Este dato al igual que la temperatura mínima, es registrada 3 veces al día en la planilla de la estación de Sunilla, donde se utiliza el promedio de estos 3 registros para obtener los datos diarios para los gráficos. La unidad de medida es grados Celsius °C.

5.1.7.1. Minimización de la pérdida variacional.

La Figura 70, se muestra la minimización de la pérdida variacional del entrenamiento de los datos diarios de Temperatura máxima (Tmáx), empleando el optimizador Adam de TF, y considerando 500 pasos variacional, la curva muestra que efectivamente desciende aproximadamente de 12000 a 7200, lo que indica que los datos diarios de la Tmáx se estabilizan y mejoran el entrenamiento del modelo.

Figura 70.

Minimización de la pérdida variacional diarios de la temperatura máxima.



Por otro lado, en la Figura 71, se observa la minimización de los datos mensuales, donde la pérdida varía de 440 a 362; y de manera similar en la Figura 72, se observa la minimización de los datos anuales que varía de 50 a 25. En estos 2 gráficos se presentan pequeñas fluctuaciones debido a la complejidad del análisis, la cantidad de datos y el ruido presente en los datos de $T_{\text{máx}}$; no alterando mucho el resultado de los gráficos, gracias a que el optimizador busca estabilizar el modelo.

Figura 71.

Minimización de la pérdida variacional mensual de la temperatura máxima.





Figura 72

Minimización de la pérdida variacional anual de la temperatura máxima.




5.1.7.2. Serie de tiempo estructurales para pronóstico con Tfp para Temperatura máxima.

La Figura 73, muestra el comportamiento y el pronóstico de la T_{máx}. Los valores reales representada por la línea azul oscila alrededor de 16 °C en mayor parte del año, con un mínimo de 10 °C y un máximo 20 °C. En 2019, se observa un incremento de la T_{máx}, oscilando alrededor de los 25 °C. En algunos años la T_{máx} llegan a 0 °C registrando en un periodo prolongado de ese valor a finales del 2018, siendo una temperatura atípica.

Figura 73

Predicción de la Temperatura máxima diario de la presa Cuchoquesera.




La línea anaranjada del pronóstico muestra un crecimiento a lo largo del tiempo, empezando en 16 °C. El área de incertidumbre asociada al pronóstico, es considerablemente grande y se expande con el tiempo, sugiriendo una mayor variabilidad y menor precisión en las predicciones futuras.

Por otro lado, la Figura 74, muestra la Tendencia y la estacionalidad para los datos diarios de la T_{máx}. La Tendencia, oscila mayormente alrededor del promedio global de referencia, indicando temperaturas típicas o normales. Los valores debajo del promedio global, indican que la T_{máx} fue demasiado bajas, reflejando días con temperatura más frías, es decir, temperaturas atópicas. Mientras que los valores por encima del promedio global, indican días con temperaturas más altas de lo normal siendo el 2019 el más representativo.

Figura 74.

Tendencia y estacionalidad de la temperatura máxima diario.




La estacionalidad muestra la variabilidad de los datos diarios, registrando mayor variabilidad en los primeros años hasta 2016. El 2017 se observa un ajuste, posteriormente hubo un aumento mínimo en la variabilidad hasta el 2024. El área de incertidumbre en ambos gráficos, nos muestra la variabilidad y la confiabilidad de los datos, para poder realizar una Predicción de la T_{máx}.

5.1.7.3. Serie de tiempo estructurales para pronóstico con Tfp para la Temperatura máxima mensual y anual.

La Figura 75, muestra el comportamiento y pronóstico mensual de la T_{máx}, los datos utilizados son del promedio de los datos diarios de cada mes. La línea azul continua representa el comportamiento real de la T_{máx}, donde se observa meses a lo largo de los años de análisis con 0° C, siendo el 2018 en mayor tiempo ese nivel de temperatura atípica. Por otro lado, el 2019 presenta el valor máximo registrado, alcanzando 25 °C en la mayor parte del año.

Figura 75.

Predicción de la Temperatura máxima media mensual de la presa Cuchoquesera.




La línea anaranjada del pronóstico oscila alrededor de 18 °C, teniendo en cuenta que el área de incertidumbre es considerablemente grande y se expande mientras más avance el tiempo, indicando una mayor variabilidad y menor precisión en las predicciones futuras.

Por otro lado, la Figura 76, presenta la Tendencia y la estacionalidad para los datos mensuales de la T_{máx}. La Tendencia muestra las oscilaciones alrededor del promedio global

de referencia. Se observa que en 2018 los valores estuvieron muy por debajo del promedio global, indicando una temperatura atípica. Mientras que en 2019 registro los valores más alto. La estacionalidad, muestra el ciclo que sigue $T_{m\acute{a}x}$ en cada año.

Figura 76.

Tendencia y estacionalidad de la temperatura máxima media mensual.




Los valores máximos se registran aproximadamente entre los meses de febrero y abril. Por otro lado, los meses de octubre a noviembre presentan los valores más bajos en cada año. En ambos gráficos la banda de incertidumbre nos proporciona un rango de la variabilidad y precisión del pronóstico a lo largo del tiempo.

La Figura 77 utiliza el promedio de los datos mensuales de cada año en el análisis que va del 2013 al 2023 para mostrar el comportamiento anual y pronóstico de la $T_{m\acute{a}x}$. La línea azul muestra, un valor mínimo en 2018 con aproximadamente 7 °C, mientras que el máximo se observó en 2016 llegando a los 18 °C aproximadamente, y en los demás años no vario significativamente.

Figura 77.

Tendencia y estacionalidad de la temperatura máxima media anual.




El pronóstico de la $T_{máx}$, muestra una continuidad en los próximos años, con valores que se mantienen en rango similar al observado. El área de incertidumbre, muestra un crecimiento a través de los años, la precisión de las predicciones disminuye.

Por otro lado, la Figura 78, muestra la Tendencia y la estacionalidad para los datos anuales. La Tendencia, muestra una tendencia continua con respecto al promedio global, eso indica que cada año presento una $T_{máx}$ relativamente regulada. La estacionalidad muestra el comportamiento $T_{máx}$ en cada temporada anual, utilizando el promedio estacional como referencia. Se observa que los años 2016, 2020 y 2022 presentaron temperaturas más altas, mientras que en 2018 se tuvo el valor más bajo. Los demás años no varían mucho con respecto al promedio estacional, indicando en aquellos años que la $T_{máx}$ estuvo regulada y dentro de un rango esperado. En ambos gráficos la banda de incertidumbre es más ancha a inicios y finales del periodo analizado, mientras que en 2019 es angosta siendo un punto de quiebre, mostrando en ambos casos una medida de variabilidad y confiabilidad para las predicciones a través del tiempo.

Figura 78.

Tendencia y estacionalidad de la temperatura máxima media anual.



5.1.8. Descripción del comportamiento temporal de la Temperatura ambiente en la Presa Cuchoquesera.


Para los gráficos de la temperatura ambiente, se utiliza el promedio de los datos de la temperatura máxima y mínima registrada diariamente en la planilla de la estación de Sunilla.

5.1.8.1. Minimización de la pérdida variacional.

La Figura 79, se muestra la minimización de la pérdida variacional del entrenamiento de los datos diarios de Temperatura ambiente (T_{amb}), empleando el optimizador Adam de TF, y considerando 500 pasos variacional, la curva muestra que efectivamente desciende aproximadamente de 11000 a 6000, lo que indica que los datos diarios de la T_{amb} se estabilizan y mejoran el entrenamiento del modelo.

Figura 79.

Minimización de la pérdida variacional diario de la temperatura ambiente.



Por otro lado, en la Figura 80, se observa la minimización de los datos mensuales, donde la pérdida varía de 370 a 320; y de manera similar en la Figura 81 se observa la minimización de los datos anuales que varía de 50 a 25.

Figura 80

Minimización de la pérdida variacional mensual de la temperatura ambiente.





Figura 81

Minimización de la pérdida variacional anual de la temperatura ambiente.




En estos 2 gráficos se presentan fluctuaciones siendo el de los datos mensuales más pronunciados debido a la complejidad del análisis, la cantidad de datos y el ruido presente en los datos de Tamb; no alterando mucho el resultado de los gráficos, gracias a que el optimizador busca estabilizar el modelo.

5.1.8.2. Serie de tiempo estructurales para pronóstico con Tfp para la Temperatura ambiente.

La Figura 82 muestra el comportamiento diario y el pronóstico de la Tamb. Los valores reales por la línea azul, oscilan en la mayoría de los años alrededor de 10 °C, con un mínimo 8 °C y un máximo 13 °C. En 2018, se llegó a registrar temperaturas mínimas de 0 °C a finales de año, aproximadamente entre los meses de agosto y diciembre. Mientras, en 2019, se registró una temperatura máxima prolongada de aproximadamente 20 °C.

Figura 82.

Predicción de la Temperatura ambiente diario de la presa Cuchoquesera.




El pronóstico muestra una tendencia de crecimiento gradual a lo largo del tiempo, teniendo en cuenta que el área de incertidumbre crece con el tiempo, mostrando una mayor variabilidad y menos precisión en las predicciones mientras más se aleje del periodo de los datos de entrenamiento.

Por otro lado, la Figura 83, presenta la Tendencia y la estacionalidad de los datos diarios de la Tamb. La Tendencia muestra las oscilaciones diarias alrededor del promedio global de referencia. Los días por debajo del promedio global indican temperaturas frías. Mientras los días con valores por encima del promedio global, indican Temperatura más cálidas en la Presa Cuchoquesera, consideradas como temperaturas atípicas.

Figura 83.

Tendencia y estacionalidad de la temperatura ambiente diario.




La estacionalidad muestra la variación diaria a lo largo de los años analizados, donde se observa que entre los años 2013 y 2014 hubo variaciones más prolongadas de la temperatura ambiente. La banda de incertidumbre en ambos gráficos proporciona una medida de la variabilidad y la confiabilidad de las predicciones, para realizar una mejor planificación en el futuro.

5.1.8.3. Serie de tiempo estructurales para pronostico con Tfp para la Temperatura ambiente mensual y anual.

La Figura 84, muestra el comportamiento y pronostico mensual de la Tamb, utilizando los promedios de los datos diarios de cada mes desde el 2013 hasta 2023. Se observa de los valores reales que la mayoría de los meses oscilan a temperaturas muy cercanas a 10 °C, presentando en algunos meses 0 °C, siendo la más prolongada el 2018; y en 2019, se observó un valor máximo prolongado de 18 °C.

Figura 84.

Predicción de la Temperatura ambiente media mensual de la presa Cuchoquesera.



El pronóstico muestra un comportamiento continuo oscilando entre los 10 °C y 12 °C, teniendo en cuenta que el área de incertidumbre alrededor del pronóstico, crece con el tiempo indicando mayor variabilidad y menor precisión a medida que avanzamos.

Por otro lado, la Figura 85, presenta la Tendencia y la estacionalidad mensual de la T_{amb} . La Tendencia, muestra los meses con temperaturas decrecientes y crecientes en relación al promedio global de referencia. siendo el mínimo en 2018 y el máximo 2019, indicando meses con temperaturas frías y calidas.

Figura 85.

Tendencia y estacionalidad de la temperatura ambiente media mensual.




La estacionalidad muestra un ciclo anual de la Tamb, se observa que los primeros meses de cada año presentan un aumento en la temperatura, alcanzando su máximo entre los febrero y marzo; mientras que a finales de año un aproximado en el mes de noviembre, la temperatura desciende a su mínimo, para nuevamente subir y repetir el ciclo. La banda de incertidumbre en ambos gráficos proporciona una medida de la variabilidad y la confiabilidad de las predicciones, para realizar una mejor planificación en el transcurso del tiempo.

La Figura 86, muestra el comportamiento y pronostico anual de la Tamb, los datos utilizados se obtienen mediante el promedio de los 12 meses en cada año. El comportamiento de los valores reales muestra que los datos no alejándose de los 10 °C, a excepción del 2018, llegando a un mínimo de 5 °C.

Figura 86.

Predicción de la Temperatura ambiente media anual de la presa Cuchoquesera.




El pronóstico muestra una tendencia continua en 9 °C para próximos años. El área de incertidumbre crece a medida que el tiempo avanza indicando una mayor variabilidad y menos precisión en el pronóstico.

Por otro lado, el gráfico 87, muestra la Tendencia y la estacionalidad anual de la Tamb. La Tendencia muestra una línea casi recta a lo largo del promedio global de referencia. La estacionalidad muestra las variaciones a través del promedio estacional de referencia, donde se observa que la temperatura máxima se da a partir del 2014 a 2016 y la temperatura mínima en 2016. En ambos gráficos la banda de incertidumbre nos da una medida de variabilidad y confiabilidad del pronóstico de los datos en el futuro.

Figura 87.

Tendencia y estacionalidad de la temperatura ambiente media anual.



5.1.9. Descripción del comportamiento temporal del Caudal de entrada en la Presa Cuchoquesera.

El caudal de entrada es registrado en una planilla de Caudal como en la Figura 18, mediante el uso de un caudalímetro ubicado en la entrada de la presa Cuchoquesera; el caudal se mide 2 veces al día, por la mañana y la tarde, registrándose en la planilla que son pasadas en formato Excel como en la Tabla 4, para finalmente calcular el promedio de las dos mediciones y obtener un valor representativo en los gráficos.

Tabla 4.

Caudales de entrada diarios registrados en el mes de enero del 2020.

Día	Caudales (m ³ /s)		
	06.00 am.	05.00 pm	Media
1	0.218	0.218	0.218
2	0.218	0.189	0.204
3	0.444	0.349	0.397
4	0.297	1.312	0.805

5	1.018	0.297	0.658
6	1.915	0.484	1.200
7	0.149	0.000	0.075
8	0.660	1.406	1.033
9	3.343	3.343	3.343
10	3.481	3.573	3.527
11	3.032	3.032	3.032
12	4.452	3.906	4.179
13	3.120	3.343	3.232
14	2.903	3.120	3.011
15	7.420	5.632	6.526
16	5.973	5.916	5.945
17	6.680	6.501	6.591
18	6.923	6.501	6.712
19	5.632	5.916	5.774
20	6.089	9.404	7.747
21	10.833	9.613	10.223
22	9.754	0.386	5.070
23	10.833	10.833	10.833
24	10.108	10.833	10.471
25	10.468	10.108	10.288
26	9.404	8.521	8.962
27	8.060	7.930	7.995
28	8.060	7.737	7.898
29	7.108	6.801	6.955
30	6.801	0.264	3.533
31	6.985	6.801	6.893
Media			4.946


Fuente: OPEMAN

5.1.9.1. Minimización de la pérdida variacional.

La Figura 88, se muestra la minimización de la pérdida variacional del entrenamiento de los datos diarios del caudal de entrada (Q_{en}), empleando el optimizador Adam de TF, y considerando 500 pasos variacional, la curva muestra que efectivamente desciende aproximadamente de 9000 a 5000, lo que indica que los datos diarios de la T_{amb} se estabilizan y mejoran el entrenamiento del modelo.

Figura 88.

Minimización de la pérdida variacional diario del caudal de entrada.



Por otro lado, en la Figura 89, se observa la minimización de los datos mensuales, donde la pérdida varía de 360 a 230; y de manera similar en la Figura 90 se observa la minimización de los datos anuales que varía de 40 a 15.

Figura 89.

Minimización de la pérdida variacional mensual del caudal de entrada.





Figura 90.

Minimización de la pérdida variacional anual del caudal de entrada.




En estos 2 gráficos se presentan fluctuaciones debido a la complejidad del análisis, la cantidad de datos y el ruido presente en los datos de Qen; no alterando mucho el resultado de los gráficos, gracias a que el optimizador busca estabilizar el modelo.

5.1.9.2. Serie de tiempo estructurales para pronostico con Tfp para el Caudal de entrada.

La Figura 91, muestra el comportamiento y el pronóstico del caudal de entrada (Q_{en}), basados con los datos diarios registrados en las planillas de la estación, Los valores reales del comportamiento del caudal muestran que inicios de cada año aproximadamente entre los meses de enero y abril, presentan un mayor ingreso de agua, esto puede ser debido al incremento del caudal de los ríos que alimentan al Caudal de la presa Cuchoquesera, registrando este aumento a finales del año aproximadamente en los meses de octubre a diciembre. A mediados de año, aproximadamente entre mayo y octubre, el caudal disminuye.

Figura 91.

Predicción del caudal de entrada diario a la presa Cuchoquesera.




El pronóstico de la línea anaranjada muestra una tendencia de crecimiento del caudal a lo largo del tiempo, pero teniendo en cuenta que el área de incertidumbre, se expande que la tendencia del pronóstico avanza en el tiempo, indicando una mayor variabilidad y menor precisión.

Por otro lado, la Figura 92, muestra la Tendencia y la estacionalidad de los datos diarios del Qen. La Tendencia, muestra los incrementos y descensos del caudal con respecto al promedio global, donde los datos por debajo del promedio global, indican días con menos caudal de entrada, siendo estos más prolongados; mientras los de encima del promedio global, indican días con mayor caudal de entrada. La estacionalidad muestra la variación diaria del caudal, Entre los años 2013 al 2023 no presentaron muchas variaciones, excepto una pequeña variación en 2016. La banda de incertidumbre en ambos gráficos nos ayuda a medir la variabilidad y confiabilidad del pronóstico para planificar y gestionar el recurso.

Figura 92.

Tendencia y estacionalidad del caudal de entrada diario.




5.1.9.3. Serie de tiempo estructurales para pronóstico con Tfp para el Caudal de entrada mensual y anual.

La Figura 93, muestra el comportamiento y pronóstico mensual del Qen. El comportamiento del Qen, indica la entrada del caudal a la presa a lo largo de cada año analizado, donde los meses de mayor caudal se da a inicios de cada, alcanzado un máximo en 2017 con aproximadamente $10 \text{ m}^3/\text{s}$. Mientras que después de los picos, el Qen disminuye siendo más prolongada y llegando en algunos casos hasta $0 \text{ m}^3/\text{s}$, lo cual indica meses sin

entrada de agua a la presa. El pronóstico de los datos, muestra un comportamiento similar de subidas y bajadas del caudal a lo largo del tiempo, siendo el área de incertidumbre ancha en las curvas de bajo caudal son más angostas en los picos siguiendo el recorrido del Qen.

Figura 93.

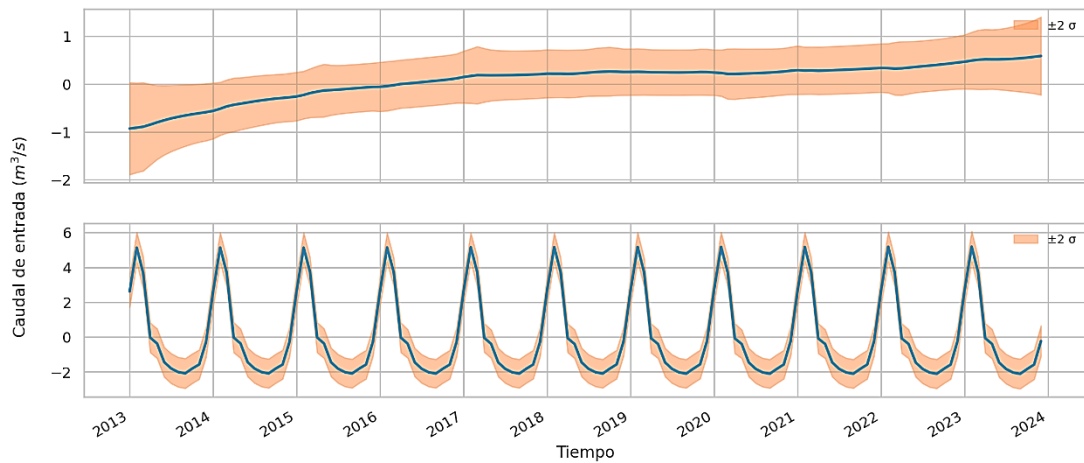
Predicción del caudal de entrada media mensual a la presa Cuchoquesera.



Por otro lado, la Figura 94, presenta la Tendencia y estacionalidad del Qen con datos mensuales. La Tendencia, muestra un crecimiento a través del tiempo encontrando en 2016 un punto de inflexión. Antes de 2016, los datos mensuales se encuentran por debajo del promedio global, indicando, que la entrada de agua al embalse en esos años fue baja. Mientras del 2016 hasta finales del 2023, los valores vienen estar por encima del promedio global, indicando mayor ingreso de agua al embalse de la presa.

Figura 94.

Tendencia y estacionalidad del caudal de entrada media mensual.




La estacionalidad muestra un ciclo que se repite cada año, donde se observa que los primeros meses se registra un pico máximo del caudal, que luego llega a disminuir en los próximos meses, para nuevamente aumentar para comenzar el ciclo. La banda de incertidumbre en ambos gráficos nos ayuda a comprender la variabilidad y confiabilidad de las predicciones del Qen a lo largo del tiempo.

La Figura 95, muestra el comportamiento y pronóstico anual del Qen, obteniendo estos datos con el promedio de los datos mensuales en cada año. Se observa, que el comportamiento del valor real del Qen, un crecimiento continuo a lo largo de los años 2013 hasta 2023. El Qen inicia en 2013 con un caudal aproximado de $1.2 \text{ m}^3/\text{s}^2$ y alcanzo un máximo de $3.0 \text{ m}^3/\text{s}^3$ en 2023.

Figura 95.

Predicción del caudal de entrada media anual a la presa Cuchoquesera.




El pronóstico muestra un aumento del Qen en los próximos años basado en los datos de entrenamiento, teniendo en cuenta que el área de incertidumbre es demasiado grande, presentando una variabilidad y una menor precisión a lo largo del tiempo.

La Figura 96, muestra la Tendencia y estacionalidad anual del Qen, teniendo en cuenta el promedio estacional como origen del gráfico. La Tendencia muestra un crecimiento del Qen a lo largo de los años desde 2013 hasta 2023; siendo el año 2017 como un punto de inflexión, al coincidir con el promedio global, donde los valores por debajo del 2017, indican un menor ingreso de agua al embalse. Mientras que a partir de 2017 hasta 2023 los valores se encuentran por encima del promedio global, indicando mayor ingreso de agua al embalse de la Presa Cuchoquesera. La estacionalidad muestra el comportamiento del caudal de entrada de la Figura 95, siendo los años 2013, 2016, 2020 y 2022 donde los valores del Qen fueron mínimos y los años de 2014, 2015, 2017, 2018, 2019 y 2023 años que se presentaron con mayor presencia de Qen. La banda de incertidumbre nos permite medir la variabilidad y confiabilidad de la predicción para una mejor planificación y gestión del Qen a lo largo del tiempo.

Figura 96.

Tendencia y estacionalidad del caudal de entrada media anual.



5.1.10. Descripción del comportamiento temporal del Caudal de salida en la Presa Cuchoquesera.

El caudal de salida se toma la medida uno por la mañana y el otro por la tarde, y se registras en una planilla, para posteriormente pasarlo en formato Excel por OPEMAN tal como se muestra en la Tabla 5, utilizando el promedio de estos datos del 2013 al 2023, para obtener los gráficos del caudal de salida diario, que indican, cuanto volumen de agua es liberado en un tiempo determinado para consumo agrícola y potable.

Tabla 5.

Caudales de salida diarios de la Presa Cuchoquesera registrados en el mes de junio del 2015.

Día	Caudales (m ³ /s)		
	06.00 am.	05.00 pm	Media

1	2.800	2.800	2.800
2	2.800	3.000	2.900
3	3.000	3.000	3.000
4	3.000	3.000	3.000
5	3.000	3.000	3.000
6	3.000	3.000	3.000
7	3.000	2.500	2.750
8	3.000	3.000	3.000
9	3.000	3.000	3.000
10	3.000	3.000	3.000
11	3.000	3.000	3.000
12	3.000	3.000	3.000
13	3.000	3.000	3.000
14	3.000	3.000	3.000
15	3.000	3.000	3.000
16	3.500	3.500	3.500
17	3.500	3.500	3.500
18	3.500	3.500	3.500
19	3.500	3.500	3.500
20	3.500	3.500	3.500
21	3.500	3.500	3.500
22	3.500	3.500	3.500
23	3.500	3.500	3.500
24	3.500	3.500	3.500
25	3.500	3.500	3.500
26	3.500	3.500	3.500
27	3.500	3.500	3.500
28	3.500	3.500	3.500
29	3.500	3.500	3.500
30	3.500	3.500	3.500


Fuente: OPEMAN

5.1.10.1. Minimización de la pérdida variacional.

La Figura 97, se muestra la minimización de la pérdida variacional del entrenamiento de los datos diarios del Caudal de Salida (Qs), empleando el optimizador Adam de TF, y considerando 500 pasos variacional, la curva muestra que efectivamente desciende aproximadamente de 9000 a 1800, lo que indica que los datos diarios de la Qs se estabilizan y mejoran el entrenamiento del modelo.

Figura 97.

Minimización de la pérdida variacional diario del caudal de salida.



Por otro lado, en la Figura 98, se observa la minimización de los datos mensuales, donde la pérdida varía de 300 a 130; y de manera similar en la Figura 99, se observa la minimización de los datos anuales que varía de 30 a 7. En estos 2 gráficos se presentan fluctuaciones debido a la complejidad del análisis, la cantidad de datos y el ruido presente en los datos de Tamb; no

alterando mucho el resultado de los gráficos, gracias a que el optimizador busca estabilizar el modelo.

Figura 98.

Minimización de la pérdida variacional mensual del caudal de salida.





Figura 99.

Minimización de la pérdida variacional anual del caudal de salida.




5.1.10.2. Serie de tiempo estructurales para pronóstico con Tfp para el Caudal de salida.

La Figura 100, muestra el comportamiento y pronóstico diario del Qs. El comportamiento de valor real del Qs, muestra un ciclo que se repite cada año de análisis desde 2013 hasta 2023. Los primeros meses de cada año muestra un caudal de salida mínimo llegando a $0 \text{ m}^3/\text{s}$, mientras que un aproximado de los meses de abril a noviembre el caudal de salida alcanza a su máximo llegando un aproximado de $5 \text{ m}^3/\text{s}$, para luego descender nuevamente hacia finales de cada año. El pronóstico muestra una tendencia negativa para el Qs después de los datos de entrenamiento, indicando una disminución progresiva a lo largo del tiempo, teniendo en cuenta que el área de incertidumbre es demasiado grande y se expande con el tiempo, indicando una mayor variabilidad y una menor precisión para el pronóstico.

Figura 100.


Predicción del caudal de salida diario de la presa Cuchoquesera.



La Figura 101, muestra la Tendencia y estacionalidad de los datos diarios del Qs. La Tendencia muestra los periodos de máximos y mínimos del Qs teniendo en cuenta el promedio global de referencia, mostrando que a inicios de cada año los valores están por debajo del promedio global, lo que indica que no hay salida de agua del embalse de la presa Cuchoquesera. Mientras a mediados de cada año, los valores del Qs están por encima del promedio global, siendo periodos más prolongados, indicando que hubo una mayor cantidad de agua saliendo del embalse de la presa. La estacionalidad muestra la variación diaria del Qs siendo los años 2013 al 2018 con menor variación de caudal, y luego las variaciones se vuelven amplias hasta 2023. La banda de incertidumbre, refleja la variación y confiabilidad del pronóstico del Qs.

Figura 101.

Tendencia y estacionalidad diario del caudal de salida.




5.1.10.3. Serie de tiempo estructurales para pronóstico con Tfp para el Caudal de salida mensual y anual.

La Figura 102, muestra el comportamiento y pronóstico mensual del Q_s , teniendo en cuenta el promedio de los datos diarios en cada mes de los años de análisis. Los valores reales muestran un ciclo repetitivo en cada año, iniciando a inicios de cada año en $0 m/s^3$, y asciende progresivamente, hasta llegar a un máximo de $4.2 m/s^3$ aproximadamente.

Figura 102.

Predicción del caudal de salida media mensual de la presa Cuchoquesera.




El pronóstico muestra un comportamiento continuo, repitiendo el ciclo para los próximos meses, y el área de incertidumbre sigue al pronóstico. Esta área es más pronunciada en los mínimos y máximos de cada curva.

La Figura 103, muestra la Tendencia y la estacionalidad de los datos mensuales. De la Tendencia, se observa un incremento del Qs a través del tiempo de análisis, siendo del 2013 al 2016, los valores que están por debajo del promedio global, indicando meses con menor salida de agua del embalse de la presa. A partir de 2016 hasta mediados del 2017, los valores del Qs están alrededor del promedio global, indicando una salida de agua regular del embalse. Por último, a partir del 2017 hasta 2023, los valores están por encima del promedio global, indicando una salida de agua mayor de lo normal del embalse de la presa.

Figura 103.

Tendencia y estacionalidad del caudal de salida media mensual.




La estacionalidad muestra un ciclo repetitivo cada año, iniciando de sus valores mínimos a inicios de año, luego asciende a un punto máximo y luego desciende a finales de año para repetir el ciclo. La banda de incertidumbre en ambos gráficos nos permite medir la variabilidad y confiabilidad de las predicciones a lo largo del tiempo.

La Figura 104, presenta el comportamiento y pronóstico anual del Q_s , los datos para los gráficos son mediante el promedio de los datos mensual en cada año. Se observa del comportamiento real representada por la línea azul, un crecimiento continuo a lo largo de los años transcurridos, pasando de 2.1 °C en 2013 hasta 2.5 °C en 2023, siendo el caudal máximo alcanzado fue 2.8 °C en 2018.

Figura 104.

Predicción del caudal de salida media anual de la presa Cuchoquesera.




El pronóstico, muestra un crecimiento continuo del caudal a lo largo del tiempo, teniendo en cuenta los datos de entrenamiento. El área de incertidumbre es considerablemente grande, y crece a lo largo que el pronóstico avanza, proporcionando una mayor variabilidad y menor precisión para predicciones futuras.

Por otro lado, la Figura 105, muestra la Tendencia y la estacionalidad de los datos anuales del Qs. Se observa, que la Tendencia, presenta un crecimiento a lo largo de los años del Qs. Los años del 2013 hasta 2017, los valores se encuentran debajo del promedio global de referencia, indicando años de menor salida de agua del embalse de la presa Cuchoquesera. Mientras los años del 2019 al 2023, los valores se encuentran sobre el promedio global de referencia, indicando un aumento significativo en la salida del caudal del embalse de la Presa.

Figura 105.

Tendencia y estacionalidad del caudal de salida media anual.



La estacionalidad muestra el comportamiento del Qs, a lo largo de los años, con el promedio estacional de referencia. Los años 2013, 2014, 2021, 2022 y 2023, están por debajo del promedio estacional, lo que indica que el Qs fue menor de lo esperado. Mientras los años 2016, 2018 y 2019, están por encima del promedio estacional, lo que indica caudales de salida mayores de lo esperado al embalse de la presa, y por último los años 2017 y 2020 se encuentran cercano al promedio estacional, indicando caudales dentro de lo esperado. La banda incertidumbre en ambos gráficos nos proporciona una medida de la variabilidad y la confiabilidad de la predicción, siendo la banda más angosta en puntos intermedios de los gráficos, indicando una mayor confianza en esas predicciones.

5.2. Modelo de simulación del balance hídrico mediante un algoritmo de Machine Learning, en la presa Cuchoquesera.

Para la simulación del balance hídrico se consideran dos aspectos esenciales, el primero de ellos es el ingreso de datos (datos de entrada), que son los datos para la simulación que son: la Pp, cantidad de lluvia que cae; Ev, cantidad de agua que se evapora del embalse; Tamb, temperatura del aire en el área de estudio; HR, cantidad de humedad en el aire; Qen, caudal de

agua que entra al embalse. El segundo son los datos salida: Q_s , caudal de agua que se libera para consumo agrícola y potable.

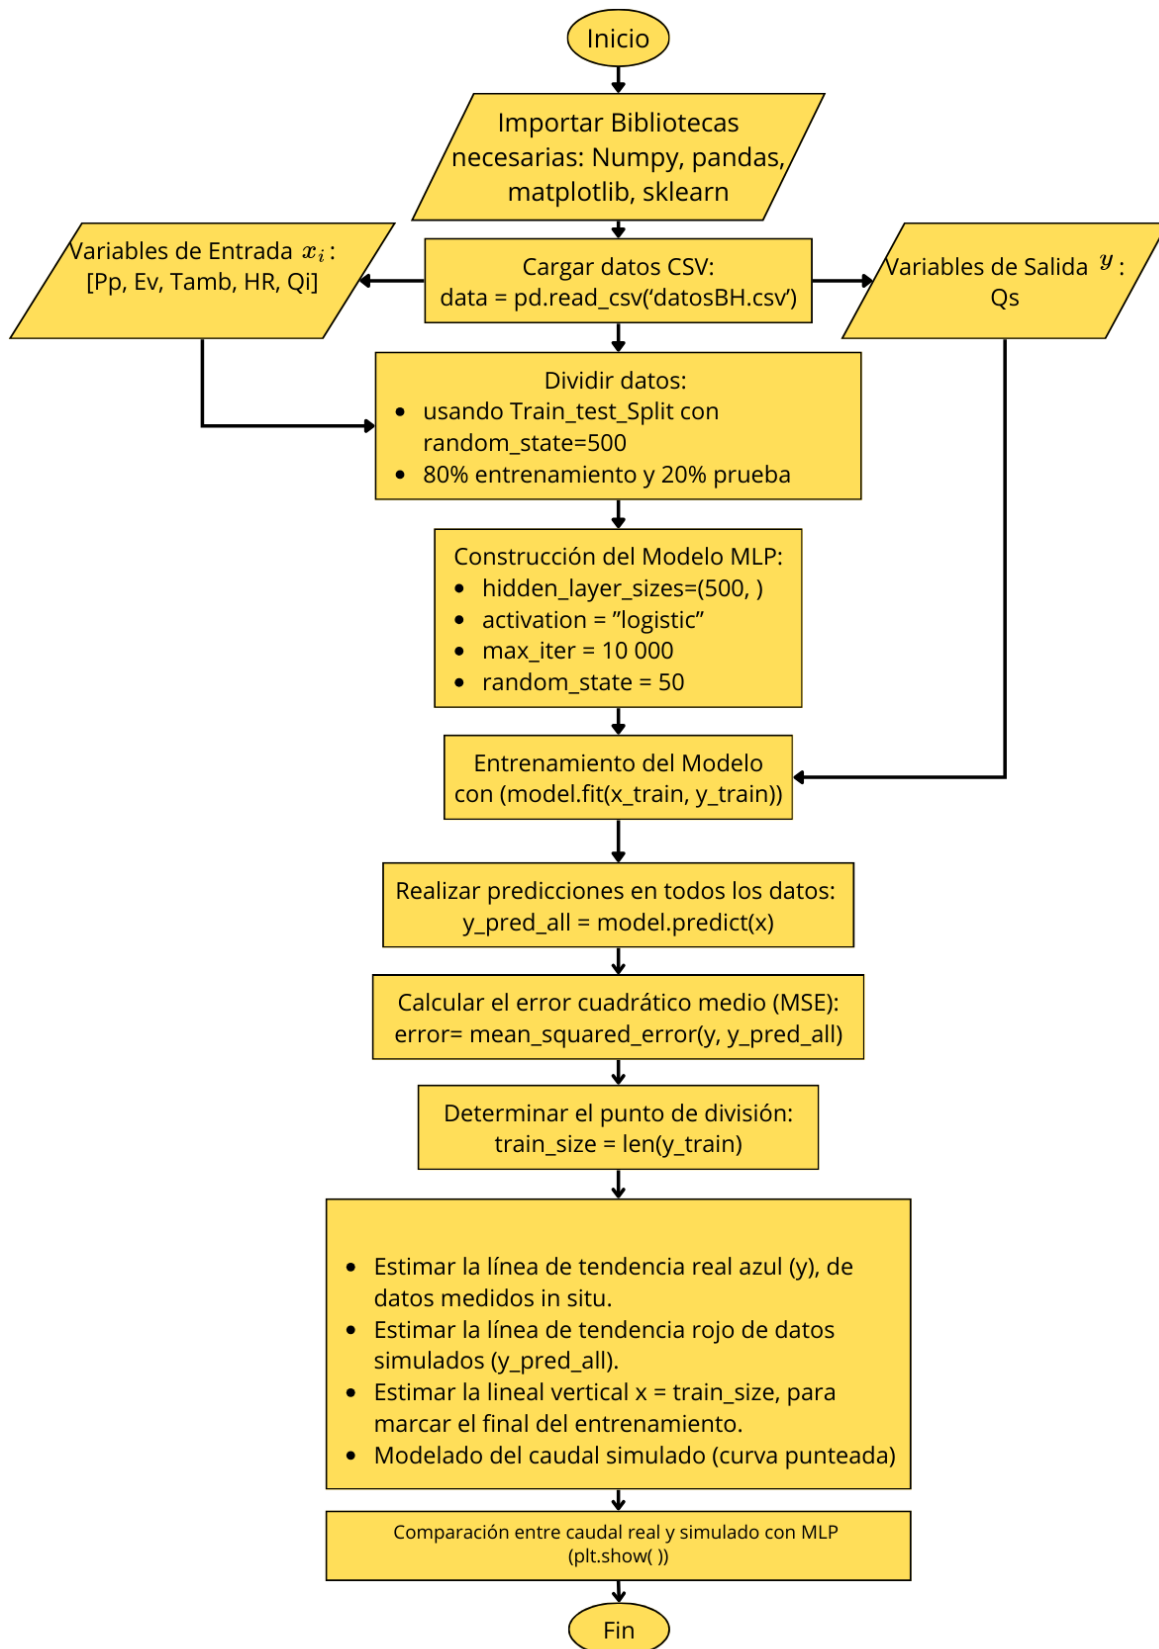
Los datos del caudal de salida a la cual se quiere simular con los datos de entrada. La red neuronal que se utilizará será la MLP (Red Neuronal Perceptrón Multicapa), teniendo en cuenta que este tipo de redes neuronales, funcionan a través de una variable objetivo a la que se quiere predecir que tendrá un valor real en este caso será el caudal de salida (Q_s), y los parámetros restantes, que son las variables predictoras para simular el comportamiento del Q_s , consideramos la Precipitación (P_p), evaporación (E_v), temperatura ambiente (T_{amb}), humedad relativa (HR), Caudal de entrada (Q_{en}) el código se encuentra en ANEXO C.

Para la construcción de la red neuronal se sigue una estructura como se llega a mostrar en la Figura 106. La Red Neuronal MLP, es una red neuronal artificial que modela relaciones complejas entre variables de entrada y salida que lo usamos para predecir.

Detallaremos cada proceso que realizamos paso a paso en el algoritmo para realizar el gráfico del Balance hídrico con el modelo MLP.

Figura 106.

Algoritmo de la Red Neuronal Perceptrón Multicapa (MLP) para el cálculo del BH.



A continuación, se detalla el procedimiento para ejecutar el algoritmo de la Figura 106, para la simulación del caudal de salida (Q_s), en la presa Cuchoquesera:

1. Importación de Bibliotecas: En la primera etapa, se importa los paquetes necesarios para el algoritmo. Los paquetes utilizados son los siguiente.
 - Pandas: Se utiliza para la manipulación y el análisis de datos mediante tablas numéricas.
 - Matplotlib: Se emplea para la generación de gráficos en dos dimensiones, a partir de los datos contenidos en listas.
 - Scikit-learn: Es una biblioteca de aprendizaje para realizar análisis predictivos, de la cual utilizamos los siguientes subpaquetes.
 - `sklearn.neural_network import MLPRegressor`: Para implementar la red neuronal Perceptrón multicapa (MLP)
 - `sklearn.metrics import mean_squared_error`: Para calcular el error cuadrático medio (MSE)
 - `sklearn.model_selection import train_test_split`: Para dividir los datos en conjuntos de entrenamiento y prueba.
2. Cargar datos en formato CSV: En esta etapa, los datos ordenados en Excel son convertidos al formato CSV para ser importados al programa, con la siguiente línea de código:

```
data = pd.read_csv('datosBH.csv')
```
3. Preparación de datos de entrada y salida: En esta etapa, se seleccionan los datos de entrada $x_i = [Pp, Ev, Tamb, HR, Qi]$ y los datos de salida a predecir $y = [Qs]$. Estos datos son fundamentales para el funcionamiento de predicción.
4. Dividir los datos: En esta etapa, se utiliza la función `train_test_split` para dividir los datos en un 80% de entrenamiento y un 20% de prueba asignando `random_state=500`.

Este es un parámetro inicial conocida como semilla $x_0 = 500$ que se encarga de barajar los datos. Para entender el proceso, se utiliza la ecuación del Generador de Congruencia Lineal (LCG):

$$x_{\{n+1\}} = (a \cdot x_n + c) \text{ mod } m$$

siendo a multiplicador, c incremento y m módulo. Al comenzar con x_0 como semilla para iniciar la separación, se garantiza que se obtenga la misma secuencia específica cada vez que se ejecute el código, asegurando que la división de los datos sea siempre la misma.

5. Construcción del modelo MLP: En esta etapa, se llega a construir el modelo MLP utilizando MLProgressor con las siguientes características.

- Hidden_layer_sizes (500,): Se le pide al programa que cree una capa oculta con 500 neuronas.

$$z = (w_1 \cdot Pp) + (w_2 \cdot Ev) + (w_3 \cdot HR) + (w_4 \cdot Tamb) + (w_5 \cdot Qen) + b \quad (27)$$

- Activation = “logistic”: Se activa la función de activación sigmoide, que transforma las variables de entrada para evitar la linealidad y seguir el comportamiento de la variable de salida. Esto permite la red aprender.

$$Salida = \sigma(z) = \frac{1}{1+e^{-z}} \quad (28)$$

- Max_iter = 10 000: Hace referencia al número máximo de iteraciones hasta que el modelo converja.
- Random state = 50: Este parámetro similar al caso anterior es una semilla específica, el generador de números pseudoaleatorios, que se utiliza para iniciar los pesos y sesgos de la RN de manera consistente en cada ejecución, minimizando el error.

6. Entrenamiento del modelo: En esta etapa el algoritmo, se utiliza `model.fit(x_train, y_train)`, para verificar la forma y el tipo de datos de entrada y asegurar que sean compatibles con el modelo. A continuación, se describen pasos internos de cómo funciona `model.fit` son.

- **Inicialización de pesos y sesgos:** Se inicializan los pesos y sesgos teniendo en cuenta que en el paso anterior se utilizó `random_state=50`. Lo que asegura resultados consistentes.
- **Propagación hacia adelante (Forward Propagation):** Es el proceso mediante el cual se calcula la entrada neta para cada neurona de la capa oculta.

$$z = \sum_i (w_i \cdot entrada: i) + b \quad (29)$$

Luego de ello, se aplica la función de activación sigmoide para transformar la entrada neta en una salida, las salidas de esta capa se utilizan en la siguiente etapa, para producir las predicciones finales del modelo.

- **Cálculo del error:** Se calcula el error entre la predicción del modelo y los valores reales, utilizando la función de costo del error el cuadrático medio (MSE)

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (30)$$

Donde n es el número de muestras, \hat{y}_i son las predicciones y y_i son los valores reales.

- **Retropropagación:** Es el proceso mediante el cual se ajustan los pesos y sesgos para minimizar el error calculado. Este proceso pasa por 2 etapas; la primera de ellas, es el cálculo de la gradiente de la función de costo con respecto a cada peso y sesgo, la segunda de ellas es que se actualizan los pesos y sesgos, la cual internamente utiliza el algoritmo de gradiente descendente:

$$w_{\{nuevo\}} = w_{\{anterior\}} - \eta \cdot \frac{\partial Costo}{\partial w} \quad (31)$$

Donde, η es la tasa de aprendizaje

- **Iteraciones:** Este proceso se repite según el parámetro `max_iter`, con un máximo de 10 000 iteraciones, o hasta que el error se reduzca a un nivel aceptable.
7. Realizar las predicciones: En esta etapa, se realizan las predicciones utilizando `model.predict(x)`. Los pasos que sigue el proceso son los siguientes:
- **Propagación hacia adelante (Forward Propagation):**
 - **Cálculo de la entrada Neta (z)** como una suma ponderada de las entradas más el sesgo.
 - **Aplicación de la función de activación (sigmoide)**, transformando la entrada neta en una salida.
 - **Cálculo de la salida de la Red**, utilizando las salidas de las neuronas en la capa oculta, se utilizan como entradas para la capa de salida, generando las predicciones finales del modelo.
8. Cálculo del error cuadrático medio (MSE): En esta etapa, se utiliza `mean_squared_error`, para visualizar y validar el modelo. Esta métrica es preciso y capaz de generalizar a nuevos datos. El MSE se calcula con la formula:
- $$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (32)$$
- Donde n es el número de muestras, \hat{y}_i son las predicciones y y_i son los valores reales.
9. Determinar el punto de división: En esta etapa, se marca la división de los datos de entrenamiento y prueba con el código `train_size = len(y_train)`, determinando el tamaño del conjunto de entrenamiento. Esto confirma la división de 80% de la muestra en la fase de entrenamiento, felicitando en la interpretación de los gráficos.
10. Generar los gráficos con los resultados: En esta etapa, se utilizarán los códigos para visualizar y analizar los resultados a partir de la predicción de los datos entrada con respecto al Q_{sal} . Las características de los gráficos son las siguientes:

- **Curva de color azul:** Representa los valores reales del Qsal.
- **Curva con líneas discontinuas de color rojo:** Representa las predicciones.
- **Línea vertical:** Marca la separación entre el conjunto de entrenamiento y prueba.
- **Puntos estimados de color rojo:** Algunos puntos estimados se representarán en rojo.

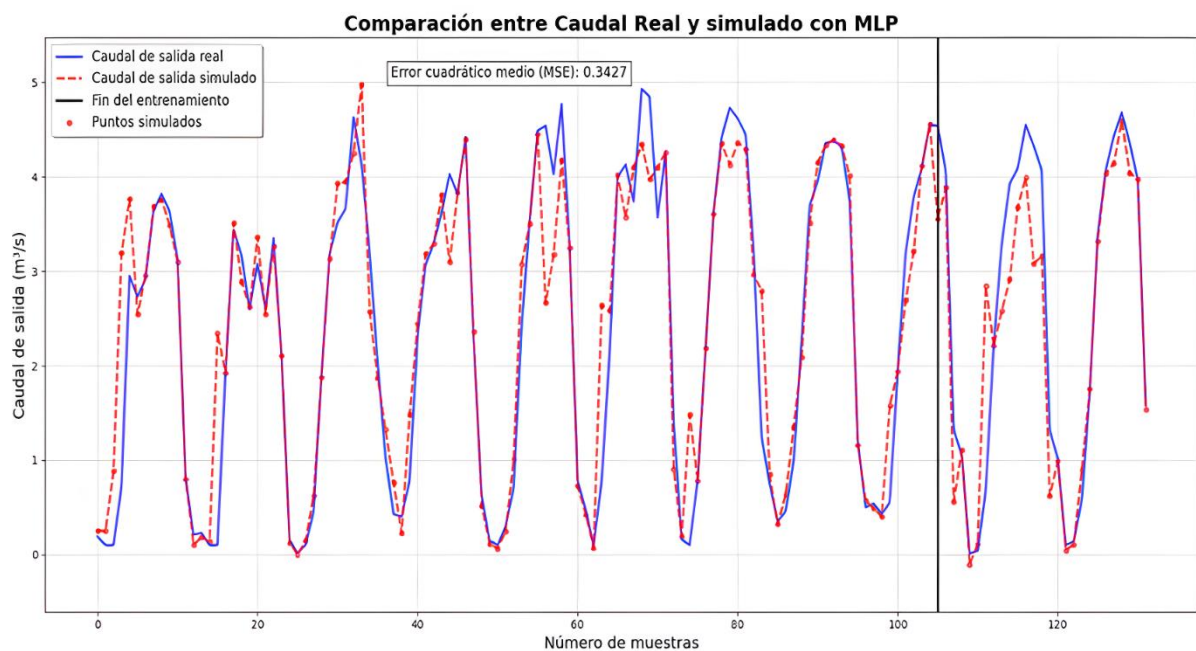
11. Mostrar el grafico: Por el ultimo se utiliza el `plt.show()` para visualizar y realizar el análisis del resultado del gráfico obtenido.

En Resumen, las características de esta red, es que se utiliza los siguientes paquetes: Numpy, parra manipulación de arreglos numéricos y operaciones matemática; Pandas, para lecturas y manipulación de datos en formato de tablas; Matplotlib, para visualizar los datos mediante gráficos y Scikit-learn, para la implementación de la red neuronal y obtener el error cuadrático medio de nuestro modelo. Teniendo en cuenta los datos de entrada y salida., estos se dividen en un 80 % para entrenamiento y el 20 % para la prueba, asegurando una distribución adecuada de datos para la validación del modelo. Se acopla los estados aleatorios a 500, para obtener mejor resultado y consistencia en los gráficos; se implementa 1000 neuronas en una capa oculta a la red del modelo, para mejorar el aprendizaje y reducir el error cuadrático medio. Se utiliza una función de activación logística o también conocido como función sigmoidea, adecuada para casos de predicción continua; y por ultima, se establecen 10000 iteraciones máximas para el entrenamiento del modelo, para que la red tenga suficientes ciclos de entrenamiento para converger a una solución óptima, fijando un estado aleatorio de 50 para inicialización de los pesos y partición de los datos, contribuyendo a la estabilidad y consistencia del modelo las iteraciones que implementamos son 10000 iteraciones máximas, con un estado aleatorio de 50 m.

La Figura 107, muestra el resultado del Balance hídrico. Las líneas azules muestran el comportamiento real del caudal de salida, evidenciando fluctuaciones de crecidas y disminuciones del Qs, siguiendo el comportamiento del gráfico de la Figura 100 de la serie temporal del caudal de salida. Estas oscilaciones se observan a través de las 132 muestras, que corresponde a los 132 meses de los 10 años de análisis de trabajo, desde 2013 hasta 2023.

Figura 107.

Resultados del algoritmo con Machine Learning para el modelado del Balance Hídrico en la presa Cuchoquesera.



La línea vertical negra separa el gráfico de los datos de entrenamiento y datos de prueba. Antes de la línea vertical, la red se entrena utilizando los datos de entrada y pesos aleatorios, aprendiendo el comportamiento del Qs a lo largo del tiempo, de la cual trata recrear los momentos de crecidas y bajadas del caudal con ciertos momentos que no llegan a ser precisos a lo largo de las muestras. Después de la línea vertical de separación, la red muestra el gráfico con los datos de prueba, siendo la línea roja la que representa a la predicción del modelo, que

muestra un error cuadrático medio (MSE) de 0.34287, indicando una precisión del modelo para las predicciones con poca variación a lo largo del tiempo analizado.

Para encontrar los diferentes tipos de coeficiencia con respecto a la observada y la simulada se descarga la base de datos en formato Excel con el siguiente código:

```
import pandas as pd

# Crear un DataFrame con los resultados

results = pd.DataFrame({'Caudal de salida real': y, 'Caudal de salida predicho':
y_pred_all.flatten()}) # Replaced y_test with y


# Guardar el DataFrame en un archivo CSV

results.to_csv('resultados MLP.csv', index=False)
```

Al descargar los datos se gráfica la tendencia lineal de los datos observados vs datos simulados como se muestra en la Figura 108, para realizar un análisis más profundo, donde se muestran, valores sobre estimados desde el punto 0 hasta 2.2 y valores sub estimados a partir 2.2 hasta 5.0, mostrando el modelo mediante una MLP en Python un Coeficiente de determinación (R^2) de 0.8739, indicando una fuerte relación entre los datos observados y los datos estimados, mostrando confiabilidad en el modelo.

Figura 108.

Correlación entre el Caudal Simulado (Q_{sim}) vs Caudal observado (Q_{obs}).



En la Tabla 6, muestra los diferentes indicadores de validación del modelo con RNA; el valor de NSE (Nash-Sutcliffe Efficiency) que es de 0.8733291 muestra la eficiencia del modelo con los datos observados siendo esta cercana a 1; la NSE-Ln que da mayor peso a los datos de caudales mínimos utilizando el logaritmo natural de los datos, muestra un valor de 0.83028593, teniendo un buen desempeño, pero siendo menor a la NSE.

Tabla 6.

Indicadores de validación del caudal simulado con respecto al caudal observado.

NSE	0.8733291
NSE-Ln	0.83028593
Pearson	0.93483012

R2	0.87390736
RMSE	0.24345417
Bias	0.99997658
RVB	0.0048394
NPE	0.00991769
PBIAS	0.14251724

El coeficiente de correlación de Pearson tiene un valor de 0.93483012, indicando la relación entre el caudal simulado y la observada, son fuertes y positivas por ser cercana a 1; el R^2 que es de 0.87390736 representa al coeficiente de determinación muestra la varianza de los datos entre el simulado y observado habiendo algunas discrepancias en el modelo, tal como se muestra en la Figura 108; el valor de RMSE es de 0.24345417, donde muestra el error promedio entre los valores observados y estimados teniendo un buen ajuste para el modelo dado que las diferencias promedio de ambos son pequeñas cercanas a 0, pero aun pudiendo mejorar el modelo.

El valor de Bias es de 0.99997658, indica que el modelo predice valores cercanas a los datos observados, pero que aún se puede hacer sobreajustes en algunos datos; el valor de RVB (Relative Volume Bias) es de 0.0048394, que es el error relativo del volumen estimado frente al observado, siendo el modelo excelente en términos de conservación de volumen; la NPE (Normalized Prediction Error) tiene el valor de 0.00991769, que es un error normalizado para comparar el modelo independientemente a la magnitud de los datos, indicando que el error a ser cercana a 0 es despreciable en términos relativos.

Por último, tenemos PBIAS (Porcentaje de sesgo relativo) con un valor de 0.14251724 que es el sesgo promedio entre los valores estimados y observados, que en porcentaje sería el


14.25 % mostrando un desempeño aceptable, pero pudiendo mejorar en algunas áreas para reducir las sobreestimaciones y subestimaciones.

5.3. Tendencia mensual y anual del caudal de entrada y salida en el embalse de la presa Cuchoquesera, a partir del modelo de balance hídrico mediante el algoritmo de Machine Learning.

Para la tendencia mensual y anual se realiza gráficos de serie temporales del caudal de entrada media mensual (Qen) y caudal de salida simulada (Qsim) de los datos proyectados de la presa Cuchoquesera con sus respectivas líneas de tendencia. En la Figura 109, se muestra la evolución del Qen y Qsim en la presa Cuchoquesera desde enero del 2013 hasta diciembre del 2023, mostrando un incremento ligero en ambos gráficos; la línea negra muestra la tendencia lineal del Qen y la línea roja para el Qsim. La tendencia del Qsim evidencia un leve incremento mayor que la tendencia del Qen hasta el 2021 aproximadamente donde existe un punto de inflexión, a lo que sugiere, que el Qen muestra un pendiente mayor que el Qsim, debido a cambios graduales en las condiciones climáticas.

Figura 109.


Tendencia mensual del caudal de entrada vs caudal de salida simulada en la presa Cuchoquesera mediante serie temporales.



Se realiza el análisis para las Tendencias lineales anual del Qen representada por la línea roja y Qsim por la línea negra desde 2013 hasta 2023, como se muestra en la Figura 110, a lo que se muestra una tendencia lineal positiva en ambos parámetros, siendo el Qen con mayor pendiente a lo largo del tiempo a comparado del Qsim, siendo este crecimiento de variación más notable, donde el Qsim es mayor que el Qen hasta el 2019, y a partir de los años 2019 al 2023 la tendencia del Qsim es menor al Qen, sugiriendo, que anualmente se recibe mayor aportación de agua al embalse en cada año, por lo que es necesario estos tipos de estudio para la seguridad de la presa para la disponibilidad de agua y posibles inundaciones que pudiera ocurrir

Figura 110.

Tendencia media anual del caudal de entrada vs el caudal de salida simulado en la presa Cuchoquesera mediante series temporales.




5.4. Estimación de la pérdida de embalsamiento de la presa Cuchoquesera, a partir del Balance Hídrico.

Para la pérdida de embalsamiento con el Caudal de salida simulado (Q_{sim}) y el Caudal de salida observado (Q_{obs}), se utiliza los datos del modelo y los datos de entrada para realizar el gráfico como se muestra en la Figura 111. El área de color azul que son las más pronunciadas representan las diferencias entre los datos del Q_{sim} y los datos del Q_{en} , siendo más pronunciadas en ciertos puntos y por otro lado el área de color rojo muestra la diferencia del Q_{obs} y el Q_{en} , mostrando una similitud en ambas diferencias, sin embargo, el área azul llega a ser más pronunciadas en algunos puntos, indicando mayor discrepancia.

Figura 111.

Perdida de embalsamiento de agua de la presa Cuchoquesera del caudal simulado y observado con el caudal de entrada.



Los datos mayores a 0 indican que hay pérdida de agua en el embalse de la presa, debido a que el Q_{sim} y Q_{obs} es mayor al Q_{en} , debido a la infiltración y evapotranspiración del agua

en la presa Cuchoquesera; mientras el área debajo de la línea 0 que son valores negativos, muestran que hay más agua que entra al embalse de la que sale, sugiriendo que el embalse de la presa Cuchoquesera, está ganando agua.

Discusión de resultados

- Los parámetros hidrometeorológicos extraídos de las plantillas de OPEMAN, recopiladas desde enero del 2013 hasta diciembre de 2023, fueron de aproximadamente 4018 datos diarios, de los cuales, los datos diarios para el entrenamiento del modelo se tomaron desde el 2013 al 2021 que fueron alrededor de 3287 datos, mientras que los datos utilizados para la validación, van desde 2022 hasta 2023, que fueron alrededor de 730 datos, a diferencia de Dashti Latif et al., (2021) que utilizó el almacenamiento inicial y final mensual para el entrenamiento de la red desde el 2000 al 2007, obteniendo un error mínimo del modelo. Con este procedimiento el algoritmo de Machine Learning permitió la realización del balance hídrico con la proyección o el pronóstico de eventos futuros principalmente de los parámetros relacionados con el caudal de entrada y salida de la presa Cuchoquesera.
- En los caudales de entrada y salida, también fueron extraídos de las Plantillas de OPEMAN, alrededor de 4018 datos, de las cuales se utilizaron 3287 datos para el entrenamiento y 730 datos para la validación, permitiendo realizar pronóstico precisos.
- Se mostró el comportamiento de los parámetros hidrometeorológicos mediante series temporales utilizando redes neuronales (RNA) y paquetes de TensorFlow (Tf). En la Figura 20, se observaron valores de 0 durante largo periodos, siendo la velocidad de viento la menos relevante de la cual no utilizamos para nuestro modelado y datos sobreestimados en la evaporación en 2023 debido que se registraron a otras unidades de medida pasando a convertirlos a mm para obtener gráficos de series temporales más precisos y consecuentes con los datos registrados en los años anteriores. Para algunos valores sobreestimados de los parámetros hidrometeorológicos, se utilizó la estimación promedio de los datos. A diferencia con Turlione, (2022), utilizo datos de entrada como la precipitación, temperatura mínima y temperatura máxima durante los años 2000 al

2020, utilizando el programa MODSIM, para la validación de modelo hidrológico y la predicción del caudal de la sub cuencas específicas, destacando el modelo LSTM, que son efectivas para aprender patrones hidrológicos, adaptándose a diversas condiciones y mejorando la precisión en la predicción de caudales.

- Para obtener los datos de la precipitación y evaporación mensuales y anuales, se obtuvieron mediante la suma acumulada de los datos diarios extraídos de las plantillas,
- Para los datos de la humedad relativa, nubosidad, temperatura máxima, mínima y ambiente; y así como los caudales de entrada y salida mensuales y anuales, se utilizó el promedio de los datos diarios.
- Se elaboro los gráficos diarios, mensuales y anuales para el pronóstico de los parámetros hidrometeorológicos de la estación de Sunilla; y los caudales de entrada y salida de la presa Cuchoquesera. Los gráficos mensuales mostraron un mejor pronostico en las series temporales, destacando la Tendencia y la estacionalidad la cual nos ayudó a analizar de manera más efectiva las variaciones en cada año, y permitiendo desarrollar el balance hídrico.
- Se desarrolló un balance hídrico mediante un algoritmo de machine learning con una red neuronal de tipo Perceptrón Multicapa, con 500 neuronas en la capa oculta y su función de activación logística. Utilizando los datos mensuales de los parámetros hidrometeorológicos y los caudales, se logró modelar al Caudal de salida (Q_s), con un porcentaje de error cuadrático medio de 34.27 %.
- Se realizo un gráfico de correlación del caudal simulados vs el caudal observado del modelo como se muestra en la Figura 108, para el gráfico se utilizó una línea de tendencia, mostrando datos sobreestimados hasta el punto (2.2,2.2), y valores subestimados hasta el punto (5,5). Los indicadores de validación que mostro como la NSE (0.8733), NSE-Ln (0.8303), Pearson (0.9348), R^2 (0.8739) RMSE (0.2435), Bias

(0.9999), RVB (0.0048), NPE (0.0099) y PBIAS (0.1425) mostraron que el modelo funciona bien tratando de simular al caudal de salida, existiendo varianzas que pueden mejorarse. Estos indicadores comparados con otros autores como Dashti Latif y Marín Vilca y Pineda Torres, se encuentra una diferencia en los valores obtenidos debido a diferentes factores climáticos en el lugar de estudio, así como los parámetros hidrometeorológicos usados en el modelo. El modelo también obtiene una métrica NSE mejor que las reportadas en modelos univariantes como el modelo de Zhang et al., (2018) que obtuvo NSE entre 0,75 y 0,85 utilizando datos históricos de caudal. Sin embargo, este modelo sigue siendo de gran importancia para las cuencas con una instrumentación limitada, donde la recogida de datos multivariantes no es factible.

- En la Figura 109 y 110, se presentan los gráficos de tendencia lineal mensual y media anual del caudal del caudal de entrada y del caudal de salida simulado (Qsim), mostrándonos una tendencia positiva. En el gráfico mensual, se observó que el Qsim fue ligeramente mayor al Qen, pero siendo el Qen con mayor pendiente, mientras que el gráfico anual, mostró un crecimiento acelerado del Qen en comparación al Qsim, existiendo un punto de inflexión en el año 2019, siendo a partir de ese año que el Qen es mayor al caudal de salida, estos resultados obtenidos en los gráficos se deben a cambios graduales en las condiciones climáticas.
- Para la pérdida de embalsamiento, se utilizaron los datos del caudal de salida observada y simulada restados al caudal de entrada. donde en la Figura 111 mostró áreas sombreadas positivas lo que significa que sale más agua de la que entra, indicando pérdida de agua por evaporación e infiltración, y áreas negativas que indican mayor ingreso de agua al embalse, que son mayormente a inicios y finales del año.

Conclusiones

- Las técnicas de Machine Learning, a través de TensorFlow y redes neuronales, permitieron describir el comportamiento de los parámetros hidrometeorológicos mediante series temporales. Los gráficos diarios, mensuales y anuales de los parámetros hidrometeorológicos y así como los caudales de entrada y salida, proporcionaron una comprensión detallada de sus variaciones y tendencias a lo largo del tiempo.
- Se logro construir el modelo de balance hídrico mediante un algoritmo basado en técnicas de Machine Learning, siendo el caudal de salida la variable a simular mediante las variables de entrada la precipitación, evaporación, caudal de entrada, humedad relativa y temperatura ambiente. El modelo logro simular los cambios del caudal de salida a lo largo del tiempo analiza, aunque se observaron valores sobreestimados y subestimadas.
- Se logro estimar la tendencia mensual y anual del caudal de entrada y caudal simulado. Se observo que el caudal simulado fue mayor hasta el 2019, mostrando una tendencia positiva con un crecimiento lento. A partir del 2019 hasta 2023, el caudal de entrada mostró un crecimiento más acelerado, manteniendo la tendencia positiva, siendo mayor al caudal simulado.
- Se estimaron las pérdidas de embalsamiento de la presa Cuchoquesera utilizando los datos del caudal de salida simulado y observado, restándolos con el caudal de entrada. Este análisis permitió identificar periodos de perdida de agua debido a la evaporación e infiltración, así como periodos de ganancia de agua al embalse.

Recomendaciones

- Utilizar otras técnicas de machine learning, utilizando otro tipo de Redes Neuronales para comparar con la simulación propuesta, a fin de determinar cuál es más efectiva para predicciones del embalse a la presa Cuchoquesera.
- Encontrar fórmulas para entrelazar los diferentes parámetros hidrometeorológicos para desarrollar un modelo integrado que muestra como estos parámetros afectan al balance hídrico.
- Dado que hay parámetros y datos de caudales incompletos, es necesario buscar otras fuentes adicionales aparte de la oficina de OPEMAN para obtener estos datos y describir mejor los gráficos de serie temporal y predecir eventos futuros con mayor precisión.
- Para un análisis espacio-temporal de los parámetros hidrometeorológicos, es necesario realizar mapeos en la presa Cuchoquesera y sus alrededores cercanos mediante satélites, para llevar a cabo un análisis más profundo y describir con más eficiencia los comportamientos de estos parámetros a lo largo del tiempo.

Referencia bibliografica

- Ahmed, A. A., Sayed, S., Abdoulhalik, A., Moutari, S., & Oyedele, L. (2024). Applications of machine learning to water resources management: A review of present status and future opportunities. *Journal of Cleaner Production*, 441, 140715. <https://doi.org/10.1016/j.jclepro.2024.140715>
- Alonso, R. (2021, octubre 22). *IA, Machine Learning y Deep Learning, ¿cuál es la diferencia?* [Artículos]. hardzone. <https://hardzone.es/tutoriales/rendimiento/diferencias-ia-deep-machine-learning/>
- Alpaydin, E. (2004). *Introduction to machine learning*. Massachusetts Institute of Technology.
- ANA. (2010). *Evaluación de Recursos Hídricos Superficiales en la Cuenca del Río Mantaro* (Inventarios y evaluación de ecosistemas proveedores de agua Aguas superficiales, p. 137) [Hidrogeología]. Autoridad Nacional del Agua (ANA). <https://hdl.handle.net/20.500.12543/1968>
- ANA, & MINAGRI. (2016, julio). *Priorización de cuencas para la gestión de recursos hídricos*. <https://hdl.handle.net/11537/25384>
- Brunton, S. L., Noack, B. R., & Koumoutsakos, P. (2020). Machine Learning for Fluid Mechanics. *Annual Review of Fluid Mechanics*, 52(1), 477-508. <https://doi.org/10.1146/annurev-fluid-010719-060214>
- Campos, D. (1998). *Procesos del ciclo hidrológico* (Tercera edición). Universidad Autónoma de San Luis Potosí. <http://ninive.uaslp.mx/jspui/handle/i/3331>
- Cavero, M. (2013, octubre 18). *Estudios de balance hídrico en cuencas hidrográficas*. Gestión del agua, Popular y etiquetado agua superficial. <https://gidahatari.com/ih-es/estudios-balance-hidrico-cuencas-hidrograficas>

- Chereque Morán, W. (1989). *PONTIFICIA UNIVERSIDAD CATOLICA DEL PERU* (Fondo Editorial y otros aportes). Fondo Editorial y otros aportes. <http://repositorio.pucp.edu.pe/index/handle/123456789/28689>
- Claro R., F. A. (1991, agosto). *BALANCE HIDRICO*. INSTITUTO COLOMBIANO DE HIDROLOGIA, METEOROLOGIA Y ADECUACION DE TIERRAS HIMAT.
- Dashti Latif, S., Najah Ahmed, A., Sherif, M., Sefelnasr, A., & El-Shafie, A. (2021). Reservoir water balance simulation model utilizing machine learning algorithm. *Alexandria Engineering Journal*, 60(1), 1365-1378. <https://doi.org/10.1016/j.aej.2020.10.057>
- Fathian, F., Mehdizadeh, S., Kozekalani Sales, A., & Safari, M. J. S. (2019). Hybrid models to improve the monthly river flow prediction: Integrating artificial intelligence and non-linear time series models. *Journal of Hydrology*, 575, 1200-1213. <https://doi.org/10.1016/j.jhydrol.2019.06.025>
- Hassan-Esfahani, L., Torres-Rua, A., & McKee, M. (2015). Assessment of optimal irrigation water allocation for pressurized irrigation system using water balance approach, learning machines, and remotely sensed data. *Agricultural Water Management*, 153, 42-50. <https://doi.org/10.1016/j.agwat.2015.02.005>
- Hurtado Asto, J. J. (2019). *Análisis hidrológico y estimación del balance hídrico para la presa de relaves Pataz—La Libertad – 2019* [Bachiller, Universidad Ricardo Palma]. <http://repositorio.urp.edu.pe/handle/URP/2926>
- Hurwitz, J., & Kirsch, D. (2018). *Machine Learning For Dummies* (IBM Limited Edition). <https://www.ibm.com/downloads/cas/GB8ZMQZ3>
- Llorens, P. (2003). La evaluación y modelización del balance hidrológico a escala de cuenca. *Revista Ecosistemas*, 12(1), 5. <https://doi.org/10.7818/re.2014.12-1.00>
- López-Tapia, S., Ruiz, P., Smith, M., Matthews, J., Zercher, B., Sydorenko, L., Varia, N., Jin, Y., Wang, M., Dunn, J. B., & Katsaggelos, A. K. (2021). Machine learning with high-

- resolution aerial imagery and data fusion to improve and automate the detection of wetlands. *International Journal of Applied Earth Observation and Geoinformation*, 105, 102581. <https://doi.org/10.1016/j.jag.2021.102581>
- Luque Mamani, E. F. (2018). *Modelo estocástico basado en redes neuronales no tradicionales aplicada a la generación de caudales mensuales caso: Cuenca del Rio Chili, Arequipa* [BACHILLER, Universidad Nacional de San Agustín de Arequipa]. <http://repositorio.unsa.edu.pe/handle/UNSA/6091>
- Marín Vilca, D. G., & Pineda Torres, I. A. (2019). *Modelo predictivo Machine Learning aplicado a análisis de datos Hidrometeorológicos para un SAT en Represas* [Licenciatura]. Universidad Tecnológica del Perú.
- Melo, L. L. de, Melo, V. G. M. L. de, Marques, P. A. A., Frizzone, J. A., Coelho, R. D., Romero, R. A. F., & Barros, T. H. da S. (2022). Deep learning for identification of water deficits in sugarcane based on thermal images. *Agricultural Water Management*, 272, 107820. <https://doi.org/10.1016/j.agwat.2022.107820>
- Mitchell, T. M. (1997). *Machine Learning (McGraw-Hill International Editions Computer Science Series)* (1.^a ed.). McGraw-Hill Education.
- Ordoñez Gálvez, J. J. (2012). *Cartilla Técnica: Balance Hídrico superficial* (1.^a ed.). Sociedad Geográfica de Lima. https://www.gwp.org/globalassets/global/gwp-sam_files/publicaciones/varios/balance_hidrico.pdf
- Organización Meteorológica Mundial (OMM). (2014). *Guía de instrumentos y métodos de observación meteorológicos*. (Actualizado 2017). Organización Meteorológica Mundial. https://library.wmo.int/doc_num.php?explnum_id=3664
- Oso Rodríguez, M. C., Cabrales Arevalo, S., & Rosso Murillo, J. W. (2017). Diseño metodológico para la simulación del balance hídrico de una represa: Caso Tunja,

- Colombia. *Revista Científica*, 29 (2), 230-248.
<https://doi.org/10.14483/udistrital.jour.RC.2016.29.a10>
- Qian, X., Qi, H., Shang, S., Wan, H., & Wang, R. (2024). Estimating distributed autumn irrigation water use in a large irrigation district by combining machine learning with water balance models. *Computers and Electronics in Agriculture*, 224, 109110.
<https://doi.org/10.1016/j.compag.2024.109110>
- Qué es Tensorflow y su uso para el aprendizaje automático.* (sf). SYNTONIZE.
<https://www.syntonize.com/que-es-tensorflow/>
- Raschka, S., & Mirjalili, V. (2019). *Aprendizaje automático con python* (Segunda edición). MARCOMBO.
- Russell, R. (2018). *Machine Learning Guía Paso a Paso Para Implementar Algoritmos De Machine Learning Con Python* (1.^a ed.). CreateSpace Independent Publishing Platform.
- Sánchez San Román, F. J. (2017). *El ciclo hidrológico* [Educativo]. Hidrología.
<https://hidrologia.usal.es/>
- Secretaría de la Convención de Ramsar. (2010). *Manejo de cuencas hidrográficas* (4ta edición, Vol. 9). Manuales Ramsar.
<https://www.ramsar.org/sites/default/files/documents/pdf/lib/hbk4-09sp.pdf>
- Turlione, A. R. (2022). *Modelado del caudal natural en la cuenca hidrográfica Chambo con redes neuronales.* <https://repositorio.unican.es/xmlui/handle/10902/27063>
- UNESCO. (2006). *Balance hídrico superficial del Perú a nivel multianual.* Programa Hidrológico Internacional (PHI) de la Oficina Regional de Ciencia para América Latina y el Caribe de la Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (UNESCO).
<https://es.unesco.org/fieldoffice/montevideo/agua/publicaciones>

- Universidad de Coruña. (2019). *Capítulo 5: ESCORRENTÍA* [Academico]. caminos.udc.
http://caminos.udc.es/info/asignaturas/grado_itop/415/pdfs/Capitulo%205.pdf
- Vaisman Bacall, A. (2007). *Detección y estimación de parámetros de fenómenos de escala en trazas muestrales de tráfico en un segmento de red simulado de unidades mediante WAVELET MRA con estimador A&V*. Universidad de Los Andes.
- Vargas Crispin, W. S., Montes Raymundo, E., Castrejón Valdez, M., & Hinojosa Benavides, R. A. (2021). Machine Learning como Herramienta para Determinar la Variación de los Recursos Hídricos. *Scientific Research Journal CIDI*, 1(1), 56-69.
<https://doi.org/10.53942/srjcidiv1i1.46>
- Zamora, J. (2020, julio 31). *Los modelos matemáticos detrás de Machine Learning*. asesoftware. <http://asesoftware.com/los-modelos-matematicos-detras-de-machine-learning/>
- Zhang, Z., Zhang ,Qiang, & and Singh, V. P. (2018). Univariate streamflow forecasting using commonly used data-driven models: Literature review and case study. *Hydrological Sciences Journal*, 63(7), 1091-1111. <https://doi.org/10.1080/02626667.2018.1469756>

Lista de abreviaturas

OPEMAN: Oficina de Operaciones y Mantenimiento.

ANA: Autoridad Nacional del Agua.

Tf: TensorFlow.

ML: Machine Learning.

RNA: Red Neuronal Artificial

Tfp: Paquete de probabilidades de TensorFlow.

Pp: Precipitación.

Ev: Evaporación.

HR: Humedad Relativa.

Nb: Nubosidad.

Tmín: Temperatura mínima.

Tmáx: Temperatura máxima.

Tamb: Temperatura ambiente.

Qen: Caudal de entrada.

Qs: Caudal de salida.

Qobs: Caudal de salida observado.

Qsim: Caudal de salida simulado.

Anexo A

Matriz de consistencia

Problema Principal	Objetivo General	Hipótesis General	Variabes	Indicadores	Métodos	Técnicas e Instrumentos
<p>¿En qué medida las técnicas de machine learning permiten modelar el balance hídrico en la presa Cuchoquesera de la región Ayacucho?</p> <p>Problemas Específicos</p> <p>1. ¿Cuál es el comportamiento de los parámetros climáticos e hidrológicos medidos en la estación hidrometeorológica que influyen en el embalse de la presa Cuchoquesera?</p> <p>2. ¿En qué medida la aplicación de TensorFlow o redes neuronales permiten construir un</p>	<p>Modelar el balance hídrico mediante técnicas de Machine Learning, en la presa Cuchoquesera de la región Ayacucho.</p> <p>Objetivos Específicos</p> <p>1. Determinar el comportamiento de los parámetros climáticos e hidrológicos medidos en la estación meteorológica que influyen en el embalse de la presa Cuchoquesera.</p> <p>2. Construir un modelo de balance hídrico mediante la aplicación de TensorFlow o redes neuronales, en la presa Cuchoquesera.</p>	<p>El modelo del balance hídrico se realiza de manera eficiente mediante técnicas de Machine Learning, en la presa Cuchoquesera de la región Ayacucho.</p> <p>Hipótesis Específicas</p> <p>1. El comportamiento de los parámetros climáticos e hidrológicos medidos en la estación meteorológica influyen de manera significativa en el embalse de la presa Cuchoquesera.</p> <p>2. La construcción de un modelo de</p>	<p>Variable Independiente:</p> <ul style="list-style-type: none"> Modelo de balance hídrico <p>Se aplica como un método de control y predicción con datos de entrada y salida.</p> <p>Variable Dependiente:</p> <ul style="list-style-type: none"> Técnicas de Machine Learning <p>Estas técnicas ayudan a tener mejores resultados para manejar la información y obtener mejores interpretaciones.</p>	<p>Indicadores</p> <ul style="list-style-type: none"> Precipitación Temperatura máxima y mínima del aire Evaporación de tanque Caudal de entrada y salida Velocidad del viento <p>Indicadores</p> <ul style="list-style-type: none"> Función de regresión logística simple y múltiple Árbol de decisiones. Redes neuronales Tensor Flow. 	<p>Tipo de Investigación:</p> <ul style="list-style-type: none"> Aplicada <p>Nivel de Investigación:</p> <ul style="list-style-type: none"> Explicativa <p>Diseño de Investigación:</p> <ul style="list-style-type: none"> No experimental <p>Método de la Investigación:</p> <ul style="list-style-type: none"> Cualitativo y cuantitativo <p>Población: datos de la estación hidrometeorológica.</p> <p>Muestra: datos de entrenamiento en las Redes Neuronales.</p>	<p>Técnicas:</p> <ul style="list-style-type: none"> Recopilación de datos hidrometeorológicos Uso de las Redes Neuronales para el procesamiento de datos hidrometeorológicos Uso del TensorFlow para el procesamiento de datos hidrometeorológicos en Python. Análisis de los resultados y gráficos obtenidos. <p>Instrumentos:</p> <ul style="list-style-type: none"> Programas de procesamiento de datos con el software Python y R-Studio.

<p>modelo de balance hídrico en la presa Cuchoquesera?</p> <p>3. ¿Cuál es la tendencia anual del caudal de entrada y salida que influye en el embalse de la presa Cuchoquesera, a partir del modelo de balance hídrico con Machine Learning?</p>	<p>3. Estimar la tendencia anual del caudal de entrada y salida que influye en el embalse de la presa Cuchoquesera, a partir del modelo de balance hídrico con Machine Learning.</p>	<p>balance hídrico resulta eficiente cuando se realiza mediante la aplicación de TensorFlow o redes neuronales, en la presa Cuchoquesera.</p> <p>3. La estimación de la tendencia anual del caudal de entrada y salida influye de manera significativa en el embalse de la presa Cuchoquesera, a partir del modelo de balance hídrico con Machine Learning.</p>				<p>Fuentes:</p> <ul style="list-style-type: none"> • Tesis de Grado. • Revistas científicas • Catálogos virtuales • Páginas Web • Libros y textos especializados
--	--	---	--	--	--	--

Anexo B

Código para construcción de series temporales estructurales con Tensor Flow

Se carga los paquetes a utilizar.

```
%matplotlib inline
import matplotlib as mpl
from matplotlib import pylab as plt
import matplotlib.dates as mdates
import seaborn as sns

import collections

import numpy as np
import tensorflow.compat.v2 as tf
import tensorflow_probability as tfp

from tensorflow_probability import distributions as tfd
from tensorflow_probability import sts

tf.enable_v2_behavior()
```

Se importa los paquetes para los gráficos.

```
from pandas.plotting import register_matplotlib_converters
register_matplotlib_converters()

sns.set_context("notebook", font_scale=1.)
sns.set_style("whitegrid")

%config InlineBackend.figure_format = 'retina'
```

Se define para las gráficas de predicción de datos.

```
def plot_forecast(x, y,
                  forecast_mean, forecast_scale, forecast_samples
,
                  title, x_locator=None, x_formatter=None):
    """Plot a forecast distribution against the 'true' time series.
    """
    colors = sns.color_palette()
    c1, c2 = colors[0], colors[1]
    fig = plt.figure(figsize=(12, 6))
    ax = fig.add_subplot(1, 1, 1)

    num_steps = len(y)
    num_steps_forecast = forecast_mean.shape[-1]
    num_steps_train = num_steps - num_steps_forecast

    ax.plot(x, y, lw=2, color=c1, label='ground truth')

    forecast_steps = np.arange(
        x[num_steps_train],
        x[num_steps_train]+num_steps_forecast,
        dtype=x.dtype)

    ax.plot(forecast_steps, forecast_samples.T, lw=1, color=c2, alp
ha=0.1)

    ax.plot(forecast_steps, forecast_mean, lw=2, ls='--', color=c2,
            label='forecast')
    ax.fill_between(forecast_steps,
```

```

        forecast_mean-2*forecast_scale,
        forecast_mean+2*forecast_scale, color=c2, alph
a=0.2)

    ymin, ymax = min(np.min(forecast_samples), np.min(y)), max(np.m
ax(forecast_samples), np.max(y))

    yrange = ymax-ymin

    ax.set_ylim([ymin - yrange*0.1, ymax + yrange*0.1])

    ax.set_title("{}".format(title))

    ax.legend()

    if x_locator is not None:

        ax.xaxis.set_major_locator(x_locator)

        ax.xaxis.set_major_formatter(x_formatter)

        fig.autofmt_xdate()

    return fig, ax

```

Se define las componentes que intervienen en las gráficas como la media, desviación estándar y los datos de muestra

```

def plot_components(dates,
                   component_means_dict,
                   component_stddevs_dict,
                   x_locator=None,
                   x_formatter=None):

    """Plot the contributions of posterior components in a single f
igure."""

    colors = sns.color_palette()

    c1, c2 = colors[0], colors[1]

```

```

axes_dict = collections.OrderedDict()
num_components = len(component_means_dict)
fig = plt.figure(figsize=(12, 2.5 * num_components))
for i, component_name in enumerate(component_means_dict.keys()):
    component_mean = component_means_dict[component_name]
    component_stddev = component_stddevs_dict[component_name]

    ax = fig.add_subplot(num_components, 1, 1+i)
    ax.plot(dates, component_mean, lw=2)
    ax.fill_between(dates,
                    component_mean-2*component_stddev,
                    component_mean+2*component_stddev,
                    color=c2, alpha=0.5)

    ax.set_title(component_name)
    if x_locator is not None:
        ax.xaxis.set_major_locator(x_locator)
        ax.xaxis.set_major_formatter(x_formatter)
    axes_dict[component_name] = ax
fig.autofmt_xdate()
fig.tight_layout()
return fig, axes_dict

```

Definimos los pasos de predicción

```

def plot_one_step_predictive(dates, observed_time_series,
                             one_step_mean, one_step_scale,
                             x_locator=None, x_formatter=None):
    """Gráfico de una serie de tiempo contra las predicciones de un
    paso del modelo"""

```

```

colors = sns.color_palette()
c1, c2 = colors[0], colors[1]

fig=plt.figure(figsize=(12, 6))
ax = fig.add_subplot(1,1,1)
num_timesteps = one_step_mean.shape[-1]
ax.plot(dates, observed_time_series, label="observed time series", color=c1)

ax.plot(dates, one_step_mean, label="one-step prediction", color=c2)

ax.fill_between(dates,
                one_step_mean - one_step_scale,
                one_step_mean + one_step_scale,
                alpha=0.1, color=c2)

ax.legend()

if x_locator is not None:
    ax.xaxis.set_major_locator(x_locator)
    ax.xaxis.set_major_formatter(x_formatter)

fig.autofmt_xdate()

fig.tight_layout()

return fig, ax

```

Importamos el archivo csv

```

import pandas as pd
import matplotlib.pyplot as plt

df=pd.read_csv("Libro2.csv")

```

Definimos el variable a utilizar y el tiempo que queremos realizar nuestro análisis.

```

demand_dates = np.arange('2013-01-01', '2022-01-01', dtype='datetime64[D]')

demand_loc = mdates.YearLocator(1)

demand_fmt = mdates.DateFormatter('%d/%m/%Y')

demand = df['Precipitación']

demand = demand

num_forecast_steps = 365*2 # 2 años.

demand_training_data = demand[:-num_forecast_steps]

```

Graficamos la serie de tiempo

```

colors = sns.color_palette()

c1 = colors[0]

fig = plt.figure(figsize=(12, 6))

ax = fig.add_subplot(2, 1, 1)

ax.plot(demand_dates[:-num_forecast_steps],
        demand[:-num_forecast_steps], lw=2, label="Entrenamiento de datos")

ax.set_ylabel("Precipitación (mm)")

ax.xaxis.set_major_locator(demand_loc)

ax.xaxis.set_major_formatter(demand_fmt)

fig.autofmt_xdate()

```

Anexo C

Código para construcción del Balance Hídrico

```
import numpy as np

import pandas as pd

import matplotlib.pyplot as plt

from sklearn.neural_network import MLPRegressor

from sklearn.metrics import mean_squared_error

from sklearn.model_selection import train_test_split

# 1. Cargar datos de un CSV

data = pd.read_csv('datosBH.csv')

# 2. Preparar datos de entrada y salida

X = data[['Pp', 'Ev', 'Qi', 'Tamb', 'HR',]]

y = data['Qs']

# 3. Dividir los datos en conjuntos de entrenamiento y prueba

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.20,
random_state=500)

# 4. Crear y entrenar el modelo MLP

model = MLPRegressor(hidden_layer_sizes=(500,), activation='logistic',
max_iter=10000, random_state=50)
```

```

model.fit(X_train, y_train)

# 5. Predecir para todos los datos y calcular el error

y_pred_all = model.predict(X)

error = mean_squared_error(y, y_pred_all)

print(f'Error cuadrático medio: {error}')

# 6. Calcular el punto de división entre entrenamiento y prueba

train_size = len(y_train)

# Calcular el error cuadrático medio (MSE)

error = mean_squared_error(y, y_pred_all)

# Generar el gráfico con el error incluido

plt.figure(figsize=(16, 8))

# Trazar líneas reales y estimados

plt.plot(y.values, label='Caudal de salida real', color='blue', linewidth=2, alpha=0.8) #
Línea real

plt.plot(y_pred_all, label='Caudal de salida estimado', color='red', linestyle='--',
linewidth=2, alpha=0.8) # Línea estimado

```

```

# Línea vertical para marcar el final del entrenamiento

plt.axvline(x=train_size, color='black', linestyle='-', linewidth=2, label='Fin del
entrenamiento')

# Añadir puntos en la curva de datos proyectados

plt.scatter(range(len(y_pred_all)), y_pred_all, color='red', s=20, alpha=0.6,
label='Puntos estimados')

# Añadir título y etiquetas descriptivas

plt.title('Comparación entre Caudal Real y Estimado con MLP, fontsize=18,
fontweight='bold')

plt.xlabel('Número de muestras', fontsize=14)

plt.ylabel('Caudal de salida (m³/s)', fontsize=14)

# Añadir el error en una esquina del gráfico

plt.text(0.3, 0.95, f'Error cuadrático medio (MSE): {error:.4f}',

        fontsize=12, transform=plt.gca().transAxes,

        verticalalignment='top', bbox=dict(facecolor='white', alpha=0.8))

# Personalizar la leyenda

plt.legend(fontsize=12, loc='upper left', frameon=True, shadow=True)

# Añadir cuadrícula para facilitar la interpretación

```

```
plt.grid(color='gray', linestyle='--', linewidth=0.5, alpha=0.7)

# Ajustar los límites del eje Y para que se vean mejor los datos

plt.ylim(min(y.min(), y_pred_all.min()) - 0.5, max(y.max(), y_pred_all.max()) + 0.5)

# Ajustar los márgenes del gráfico

plt.tight_layout()

# Mostrar el gráfico

plt.show()
```


Anexo D

IMÁGENES DEL VIAJE GUIADO A LA PRESA CUCHOQUESERA.

En la Figura 112, presenta la sala de control de la salida del caudal de la Presa Cuchoquesera, siendo fuente importante para la distribución de agua para la agricultura, industria y consumo de agua potable para la ciudad de Ayacucho.

Figura 112.

Visita guiada a la presa Cuchoquesera.



En la Figura 113, se observa instrumentos deteriorados para medir el viento, y la infiltración de agua.

Figura 113

Instrumentos de medición deteriorados.



La Figura 114, se observa la sala de control por interior del caudal de salida, de tipo válvula esférica Howell Bunger que tiene la capacidad para descargar hasta un máximo de 10 m/s³, la cual se monitorea para la distribución de agua,

Figura 114.

Caseta de válvulas, para monitorear el paso del caudal de salida.



En la Figura 115, se observa la entrada a la sala de control de la presa Cuchoquesera, mientras que la Figura 116, muestra el interior de la sala de control, para la salida de agua por dos compuertas de emergencia en caso que el embalse d la presa este completamente lleno con

caudal máximo de $32 \text{ m}^3/\text{s}$, siendo operadas manualmente o automáticamente por sensores electromecánicos equipadas a la caseta de control.

Figura 115.

Sala de control de la presa Cuchoquesera.



Figura 116.

Sala de control para dar paso al agua por compuertas.



En la Figura 117, se observa el mapa de guía, para la ubicación y manejo de la presa Cuchoquesera.

Figura 117.

Mapa guía de la presa Cuchoquesera.



En la Figura 118, se observa la estación Sunilla para obtener los datos de los parámetros hidrometeorológicos de la presa Cuchoquesera, ubicado a 100 m de esta.

Figura 118.

Estación de Sunilla.



En la figura 119, se observa el tanque de evaporación de tipo a en la presa Cuchoquesera, su unidad de medida es en mm, la cual tiene que estar en un soporte de madera, en un lugar cubierto de hierbas, lejos de obstáculos, que no permitan el llenado del tanque.

Figura 119.

Tanque de evaporación.



La Figura 120, se observa el control automatizado en la estación de Sunilla, que son datos del viento, temperatura, nubosidad, humedad, etc.

Figura 120.

Control automatizado para datos hidrometeorológicos.



En la Figura 121, se observa la caseta de protección de las temperaturas mínima y máximas, los espacios vacíos de la caseta permiten el paso de la atmosfera terrestre, pero protegiendo de la radiación solar del cielo como el del suelo.

Figura 121.

Caseta para proteger los termómetros de temperatura mínima y máxima.





ACTA DE SUSTENTACIÓN DE TESIS N° 018-2025-FIMGC

**PARA OPTAR EL TÍTULO PROFESIONAL DE LICENCIADO EN CIENCIAS FÍSICO
MATEMÁTICAS. ESPECIALIDAD DE FÍSICA**

En la Universidad Nacional de San Cristóbal de Huamanga de la ciudad de Ayacucho, en cumplimiento a la **RESOLUCIÓN DECANAL No 118-2025-FIMGC-D**, a los doce días del mes de junio de 2025, siendo las 4:00 p.m., reunidos en el Auditorio de la Escuela Profesional de Ingeniería de Minas, bajo la presidencia del MSc. Ing. José Ernesto ESTRADA CÁRDENAS y los miembros: Dr. Kléber JANAMPA QUISPE, Mg. Wilmer MONCADA SOSA y Mg. Renato SOCA FLORES, actuando como secretario docente el MSc. Ing. Saul Walter RETAMOZO FERNÁNDEZ, para proceder a la sustentación de tesis para optar el Título Profesional de Licenciado en Ciencias Físico Matemáticas. Especialidad de Física, del bachiller:

MARCO ANTONIO CORDERO MANCILLA

Quien presentó la tesis denominada:

“Modelado de balance hídrico de la presa Cuchoquesera-Ayacucho, mediante un algoritmo de machine learning”

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

Aprobado con dieciocho (18)

Siendo las 5:30 p.m. del día 12 de junio de 2025, culmina el acto de sustentación de tesis, y en conformidad con lo actuado, los miembros del jurado firman al pie del presente.

MSc. Ing. José Ernesto ESTRADA
CÁRDENAS
Presidente

Dr. Kléber JANAMPA QUISPE
Miembro

Mg. Renato SOCA FLORES
Miembro

Mg. Wilmer MONCADA SOSA
Miembro - Asesor

MSc. Ing. Saul Walter RETAMOZO FERNÁNDEZ
Secretario Docente de la FIMGC

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

CONSTANCIA DE ORIGINALIDAD DE TRABAJO DE INVESTIGACIÓN

CONSTANCIA N° 005-2025-JAHQ-FIMGC/UNSCH


El que suscribe; responsable verificador de originalidad de trabajos de tesis de pregrado con el software Turnitin, en segunda instancia para las Escuelas Profesionales 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 -D, deja constancia de originalidad de trabajo de investigación, que el/la Sr./Srta.

Nombres y Apellidos : MARCO ANTONIO CORDERO MANCILLA.
Escuela Profesional : CIENCIAS FÍSICO MATEMÁTICAS.
Título de la Tesis : "Modelado de balance hídrico de la presa Cuchoquesera-Ayacucho, mediante un algoritmo de machine learning"
Evaluación de la Originalidad : 9% Índice de Similitud.
Identificador de la entrega : 2723422863.

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, 31 de julio del 2025.


Dr. JUAN ALFREDO HUAMANCHAQUI QUISPE
DNI N°: 41764585

“Modelado de balance hídrico de la presa Cuchoquesera- Ayacucho, mediante un algoritmo de machine learning”

por Marco Antonio CORDERO MANCILLA

Fecha de entrega: 31-jul-2025 04:49p. m. (UTC-0500)

Identificador de la entrega: 2723422863

Nombre del archivo: TESIS.pdf (11.22M)

Total de palabras: 36052

Total de caracteres: 197444

“Modelado de balance hídrico de la presa Cuchoquesera-Ayacucho, mediante un algoritmo de machine learning”

INFORME DE ORIGINALIDAD

9%

INDICE DE SIMILITUD

8%

FUENTES DE INTERNET

2%

PUBLICACIONES

2%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	www.tensorflow.org Fuente de Internet	2%
2	hdl.handle.net Fuente de Internet	1%
3	Marco Antonio Cordero Mancilla, Wilmer Moncada, Vinie Lee Silva Alvarado. "A New Machine Learning Algorithm to Simulate the Outlet Flow in a Reservoir, Based on a Water Balance Model", Limnological Review, 2025 Publicación	1%
4	bdigital.unal.edu.co Fuente de Internet	1%
5	library.wmo.int Fuente de Internet	1%
6	Submitted to Universidad Nacional de San Cristóbal de Huamanga Trabajo del estudiante	<1%
7	eprints.ucm.es	

Fuente de Internet

<1 %

8

es.readkong.com

Fuente de Internet

<1 %

9

repositorio.uss.edu.pe

Fuente de Internet

<1 %

10

www.yumpu.com

Fuente de Internet

<1 %

11

Submitted to Universidad Anahuac México Sur

Trabajo del estudiante

<1 %

12

García, . "Monitoring, inspection and diagnoses activities", Dam Maintenance and Rehabilitation II, 2010.

Publicación

<1 %

13

repositorio.esan.edu.pe

Fuente de Internet

<1 %

14

www.cncs.com.uy

Fuente de Internet

<1 %

15

1library.co

Fuente de Internet

<1 %

16

dspace.unitru.edu.pe

Fuente de Internet

<1 %

17

juandomingofarnos.wordpress.com

Fuente de Internet

<1 %

18	www.ptolomeo.unam.mx:8080 Fuente de Internet	<1 %
19	tesis.pucp.edu.pe Fuente de Internet	<1 %
20	www.meteored.mx Fuente de Internet	<1 %
21	Submitted to Universidad Internacional de la Rioja Trabajo del estudiante	<1 %
22	repositorio.unsch.edu.pe Fuente de Internet	<1 %
23	repositorio.upt.edu.pe Fuente de Internet	<1 %
24	issuu.com Fuente de Internet	<1 %
25	revistas.udistrital.edu.co Fuente de Internet	<1 %
26	repositoriodirplan.mop.gob.cl Fuente de Internet	<1 %
27	Submitted to Centro Europeo de Postgrado - CEUPE Trabajo del estudiante	<1 %
28	repositorio.unac.edu.pe Fuente de Internet	<1 %

29 geox.udistrital.edu.co <1 %
Fuente de Internet

30 repositorio.unicach.mx <1 %
Fuente de Internet

31 repositorio.autonomadeica.edu.pe <1 %
Fuente de Internet

32 www.scribd.com <1 %
Fuente de Internet

33 livrosdeamor.com.br <1 %
Fuente de Internet

Excluir citas

Activo

Excluir coincidencias < 30 words

Excluir bibliografía

Activo