



UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO
ESCUELA DE POSGRADO
DOCTORADO EN ADMINISTRACIÓN



**Modelo predictivo de aprendizaje máquina para la gestión del agua de
fuente subterránea en el valle Chancay Lambayeque**

TESIS

**PRESENTADA PARA OPTAR EL GRADO ACADÉMICO DE
DOCTOR EN ADMINISTRACIÓN**

AUTOR:


MA. Roberto Carlos Arteaga Lora

ASESOR:

DR. Enrique Santos Nauca Torres

LAMBAYEQUE – PERÚ

7 de setiembre de 2026



DR. Enrique Santos Nauca Torres
ASESOR



MA. Roberto Carlos Arteaga Lora
AUTOR

Tesis presentada a la Escuela de Posgrado de la Universidad Nacional Pedro Ruiz Gallo para optar el grado académico de DOCTOR EN ADMINISTRACIÓN.

Aprobado por:



DR. Noe Alberto Rosillo Alberca
PRESIDENTE DEL JURADO



DR. Regis Jorge Alberto Diaz Plaza
SECRETARIO DE JURADO



DR. Willy Rolando Anaya Morales
VOCAL DE JURADO

ACTA DE SUSTENTACIÓN DE TESIS



UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO
FACULTAD DE CIENCIAS ECONÓMICAS, ADMINISTRATIVAS Y CONTABLES
UNIDAD DE INVESTIGACIÓN


ACTA DE SUSTENTACIÓN DE TESIS – UNIDAD DE POSTGRADO

Siendo las 11 a.m. del día 07 de Setiembre del 2026, en la sala de sustentaciones de la FACULTAD DE CIENCIAS ECONÓMICAS, ADMINISTRATIVAS Y CONTABLES de la UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO, se reunieron los miembros de jurado designados mediante Resolución N° 0731-2025-UNPRG-FACEAC-D/JAM de fecha 03 de abril de 2025, conformado por:



PRESIDENTE:	DR. NOE ALBERTO ROSILLO ALBERCA
SECRETARIO (A):	DR. REGIS JORGE ALBERTO DIAZ PLAZA
VOCAL	DR. WILLY ROLANDO ANAYA MORALES
ASESOR	DR. ENRIQUE SANTOS NAUCA TORRES

Con la finalidad de evaluar la tesis titulada "MODELO PREDICTIVO DE APRENDIZAJE MAQUINA, PARA LA GESTIÓN DEL AGUA DE FUENTE SUBTERRANEA EN EL VALLE CHANCAY LAMBAYEQUE", presentado por el Doctorante ROBERTO CARLOS ARTEAGA LORA; sustentación que es autorizada mediante Resolución No0961-2026-UNPRG-FACEAC-D/JAM de fecha 02 de setiembre de 2026.

El presidente del jurado autorizó el acto académico y después de la sustentación, los señores miembros del jurado formularon las observaciones y preguntas correspondientes, las mismas que fueron absueltas en forma Satisfactoria o Por el sustentante quien obtuvo 19 Puntos que equivale al calificativo Muy Bueno.

En consecuencia, el (la) sustentante quedo apto (a) o no apto (a) para obtener el grado académico de DOCTOR EN ADMINISTRACIÓN.

Siendo las 13 horas del mismo día se da por concluido el acto académico, firmando la presente acta.

 DR. NOE ALBERTO ROSILLO ALBERCA PRESIDENTE	 DR. REGIS JORGE ALBERTO DIAZ PLAZA SECRETARIO
 DR. WILLY ROLANDO ANAYA MORALES VOCAL	 DR. ENRIQUE SANTOS NAUCA TORRES ASESOR

CONSTANCIA DE VERIFICACIÓN DE ORIGINALIDAD

Yo, Enrique Santos Nauca Torres docente asesor de la tesis titulada:

Modelo predictivo de aprendizaje máquina, para la gestión del agua de fuente subterránea en el valle Chancay Lambayeque.

Cuyo autor es, Roberto Carlos Arteaga Lora, identificado con documento de identidad DNI: 16755764; declaro que la evaluación realizada por el programa informático, ha arrojado un porcentaje de similitud de 15 %, verificable en el resumen del reporte de similitud del programa Turnitin, que se acompaña.

El suscrito analizó dicho reporte y concluyó que cada una de las coincidencias detectadas dentro del porcentaje de similitud permitido no constituyen plagio y que el documento cumple con la integridad científica y con las normas para el uso de citas y referencias establecidas por la Universidad Nacional Pedro Ruiz Gallo.

Se cumple con adjuntar el Recibo digital a efectos de la trazabilidad respectiva del proceso.

Lambayeque, 24 de agosto de 2026



DR. Enrique Santos Nauca Torres
DNI: 41657065
ASESOR

Adjunto:

- Resumen del reporte automatizado de similitudes
- Recibo digital

RESUMEN DEL INFORME DE ORIGINALIDAD (TURNITIN)

Modelo predictivo de aprendizaje máquina para la gestión del agua de fuente subterránea en el valle Chancay Lambayeque

INFORME DE ORIGINALIDAD

15%
INDICE DE SIMILITUD

11%
FUENTES DE INTERNET

5%
PUBLICACIONES

8%
TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS


1	Submitted to Universidad Nacional de San Cristóbal de Huamanga Trabajo del estudiante	4%
2	hdl.handle.net Fuente de Internet	2%
3	Submitted to Universidad Cesar Vallejo Trabajo del estudiante	1%
4	www.scielo.org.mx Fuente de Internet	1%
5	repositorio.unprg.edu.pe Fuente de Internet	1%
6	xdoc.mx Fuente de Internet	1%
7	es.readkong.com Fuente de Internet	1%
8	scielo.iics.una.py Fuente de Internet	1%
9	press.religacion.com Fuente de Internet	<1%
10	Submitted to Universidad Americana Trabajo del estudiante	<1%
11	www.ana.gob.pe Fuente de Internet	<1%
12	alicia.concytec.gob.pe Fuente de Internet	<1%
13	Guevara Lezama, Annie Geraldine. "Crisis hídrica y agroexportación en Ica: impacto del TLC con EE.UU. en la gestión del agua.", Pontificia Universidad Católica del Perú (Peru) Publicación	<1%
14	www.slideshare.net Fuente de Internet	


Dr. Ing. Enrique Santos Nauca Torres
DNI 41657065
ASESOR

		<1 %
15	Submitted to Universidad Católica de Santa María Trabajo del estudiante	<1 %
16	repository.unad.edu.co Fuente de Internet	<1 %
17	repositorio.unap.edu.pe Fuente de Internet	<1 %
18	repositorio.esan.edu.pe Fuente de Internet	<1 %
19	fddocuments.in Fuente de Internet	<1 %
20	tesis.usat.edu.pe Fuente de Internet	<1 %
21	Submitted to Universidad Carlos III de Madrid - EUR Trabajo del estudiante	<1 %
22	www.rilco.org Fuente de Internet	<1 %
23	titula.universidadeuropea.com Fuente de Internet	<1 %
24	mobile.repository.ubn.ru.nl Fuente de Internet	<1 %
25	repositorio.unfv.edu.pe Fuente de Internet	<1 %
26	documentop.com Fuente de Internet	<1 %
27	Submitted to Universidad de Sevilla Trabajo del estudiante	<1 %
28	revistas.up.ac.pa Fuente de Internet	<1 %
29	Vilca Perez, Estaban Moises. "La gestión del agua de riego en la cuenca del rio Cabanillas, orientada a la política y estrategia nacional de recursos hídricos del Perú", Universidad Nacional del Altiplano de Puno (Peru) Publicación	<1 %
30	Submitted to Universidad Internacional del Ecuador Trabajo del estudiante	<1 %


 Dr. Ing. Enrique Santos Nauca Torres
 DNI 41657065
 ASESOR

31	Adrianzen Flores, Miryam Angelica Farfan Sanchez , Daniana Catherine Gives Calderon, Adela Milagros. "Gestion de la empresa prestadora de servicios de saneamiento Grau S.A. en la implementacion de la politica de saneamiento relacionada al tratamiento y disposicion final de las aguas residuales de la ciudad de Piura y Castilla.", Pontificia Universidad Catolica del Peru - CENTRUM Catolica (Peru), 2021 Publicación	<1 %
32	pdffox.com Fuente de Internet	<1 %
33	Submitted to CVDOF - LTI Trabajo del estudiante	<1 %
34	redibai-myd.org Fuente de Internet	<1 %
35	repositorio.ana.gob.pe Fuente de Internet	<1 %
36	Nohora Nubia Mercado Caruso. "Determinantes de eco-innovación en clústers industriales. Una aplicación empírica en el departamento del Atlántico", Universitat Politecnica de Valencia, 2022 Publicación	<1 %
37	Submitted to Universidad Politécnica del Perú Trabajo del estudiante	<1 %
38	cienciadigital.org Fuente de Internet	<1 %
39	repositorio.ucsg.edu.ec Fuente de Internet	<1 %
40	scielo.senescyt.gob.ec Fuente de Internet	<1 %
41	Submitted to Universidad Estatal Amazonica- Trabajo del estudiante	<1 %
42	colposdigital.colpos.mx:8080 Fuente de Internet	<1 %
43	Gerardo Damonte, Bettina Schorr. "Andean States and the Resource Curse - Institutional Change in Extractive Economies", Routledge, 2021 Publicación	<1 %
44	ojs.unemi.edu.ec Fuente de Internet	<1 %


 Dr. Ing. Enrique Santos Nauca Torres
 DNI 41657065
 ASESOR

45	repositorio.uide.edu.ec Fuente de Internet	<1 %
46	support.minitab.com Fuente de Internet	<1 %
47	Alvarado, Juan Diego Moyano. "Predicción de Caudales del Río Bogotá Mediante Modelos Estadísticos y de Machine Learning.", Universidad de La Sabana (Colombia) Publicación	<1 %
48	CESEL S.A. "MEIA del Proyecto Ampliación de la Central Hidroeléctrica Santa Teresa-IGA0001581", R.D. N° 310-2016-MEM/DGAAE, 2020 Publicación	<1 %
49	KNIGHT PIESOLD CONSULTORES S.A.. "Plan de Cierre de Minas Proyecto Minero Constancia-IGA0000969", R.D. N° 286-2012-MEM-AAM, 2020 Publicación	<1 %
50	Mestas Yucra, Edwin Edgar. "Modelo basado en Deep Learning para predecir el ingreso de estudiantes a la UNA Puno", Universidad Nacional del Altiplano de Puno (Peru) Publicación	<1 %
51	Submitted to Universidad Internacional de la Rioja Trabajo del estudiante	<1 %
52	issuu.com Fuente de Internet	<1 %
53	repositorio.chapingo.edu.mx Fuente de Internet	<1 %
54	utm-cdn-labcontenidos-htfaarehf2gcfyca01.azurefd.net Fuente de Internet	<1 %
55	Submitted to Universidad Andina Nestor Caceres Velasquez Trabajo del estudiante	<1 %
56	Submitted to Universidad Autonoma De Guadalajara A.C. Trabajo del estudiante	<1 %
57	Submitted to Universidad Nacional Pedro Ruiz Gallo Trabajo del estudiante	<1 %
58	Submitted to Universidad Tecnologica del Peru Trabajo del estudiante	<1 %
59	repositorio.unprg.edu.pe:8080 Fuente de Internet	<1 %



Dr. Ing. Enrique Santos Nauca Torres
DNI 41657065
ASESOR

RECIBO DIGITAL (TURNITIN)



Recibo digital

Este recibo confirma que su trabajo ha sido recibido por Turnitin. A continuación podrá ver la información del recibo con respecto a su entrega.

La primera página de tus entregas se muestra abajo.

Autor de la entrega: Roberto Carlos Arteaga Lora
Título del ejercicio: Informe de tesis
Título de la entrega: Modelo predictivo de aprendizaje máquina para la gestión del ...
Nombre del archivo: MODELO_PREDICTIVO_DE_APRENDIZAJE_MÁQUINA_PARA_LA_...
Tamaño del archivo: 11.99M
Total páginas: 135
Total de palabras: 29,525
Total de caracteres: 163,898
Fecha de entrega: 04-sept-2026 05:23a. m. (UTC-0500)
Identificador de la entrega: 3023878550



Derechos de autor 2026 Turnitin. Todos los derechos reservados.

DEDICATORIA

Va dedicado a mis amados padres Manuel y María, por la eterna y maravillosa presencia de ambos en mi vida, darme el cariño, sus valiosas enseñanzas y valores que me ayudan permanentemente en la vida, por lo cual estoy muy agradecido.

AGRADECIMIENTO

Siempre a Dios, por sus bendiciones, ya que todo lo recibido a lo largo de mi vida, es por El, a mi esposa y a mi hija, por la motivación y alegría que significan para mí. A mi querido hermano Charles, por su apoyo y consejo al logro de esta tesis. A mis asesores y amigos Dr. Enrique Nauca y el Dr. Walter Campos por su valiosa orientación y haberme demostrado su apoyo para la consecución de esta tesis.

De manera especial a mi colega y amigo el Dr. Juan Villegas por su valioso apoyo al desarrollo de la presente tesis.

ÍNDICE GENERAL

RESUMEN.....	17
ABSTRACT	18
INTRODUCCIÓN	19
I DISEÑO TEÓRICO	23
1.1 Antecedentes	23
1.2 Estado del arte	28
1.3 Bases epistemológicas	30
1.4 Bases teóricas.....	31
1.4.1 Recurso hídrico.....	32
1.4.2 Machine Learning y algoritmos predictivos.....	36
1.4.3 Impacto ambiental y gestión.....	53
1.5 Operacionalización de variables.....	56
II DISEÑO METODOLÓGICO.....	59
2.1 Tipo de investigación	59
2.2 Procedimiento a seguir en la investigación	59
2.3 Población	60
2.4 Técnicas, instrumentos, equipos, materiales	61
2.5 Aspectos éticos de la investigación	61
III RESULTADOS	63
3.1 Caracterización la situación actual en la gestión de agua de fuente subterránea en el valle Chancay Lambayeque.	63
3.2 Diseñar un modelo predictivo de aprendizaje máquina para la gestión del agua de fuente subterránea en el valle Chancay Lambayeque.....	67
3.2.1 Recopilación de datos.....	68
3.2.2 Pre procesamiento de los datos.....	70
3.2.3 Selección de algoritmo	94
3.2.4 Entrenamiento del modelo	94
3.2.5 Evaluación de los modelos.....	99
3.2.6 Despliegue o inferencia	102

3.3	Elaborar una propuesta de un plan de gestión administrativa para la adecuada utilización de agua subterránea mediante los resultados del modelo predictivo	107
3.3.1	Introducción	107
3.3.2	Objetivo General	108
3.3.3	Fundamento Normativo	108
3.3.4	Fundamentos teóricos	109
3.3.5	Justificación	111
3.3.6	Plan de intervención administrativa.....	112
3.3.7	Cronograma de Implementación	116
 IV	 DISCUSIÓN DE RESULTADOS.....	 117
	CONCLUSIONES	120
	RECOMENDACIONES.....	122
	REFERENCIAS.....	124
	ANEXOS.....	134

ÍNDICE DE TABLAS

Tabla 1	Estadísticos históricos del nivel estático NE (metros) por zona.....	36
Tabla 2	Criterios para la interpretación del nivel estático NE (metros) pronosticado...36	
Tabla 3	COMPARATIVO DE MODELOS PREDICTIVOS PARA LA GESTIÓN DEL AGUA SUBTERRÁNEA	46
Tabla 4	CUADRO COMPARATIVO DE ALGORITMOS PARA PREDICCIÓN DE AGUAS SUBTERRÁNEAS	48
Tabla 5	ALGORITMOS DE DESCOMPOSICIÓN UTILIZADOS EN MODELOS HÍBRIDOS	52
Tabla 6	Operacionalización de variable Modelo predictivo de aprendizaje máquina...57	
Tabla 7	Operacionalización de variable Gestión Administrativa	58
Tabla 8	Zonificación del acuífero.....	63
Tabla 9	Pozos Monitoreados – Red Piezométrica	64
Tabla 10	Clasificación de Agua para Riego (Conductividad Eléctrica – CE).....	65
Tabla 11	Clasificación del Agua por PH.....	66
Tabla 12	Tendencia de Conductividad Eléctrica (1999–2023).....	67
Tabla 13	Pozos registrados y monitoreados del acuífero del valle Chancay Lambayeque	68
Tabla 14	Datos faltantes en data histórica del nivel estático desde 1996 hasta 2023 de los pozos del valle Chancay Lambayeque.....	69
Tabla 15	Formato de presentación original de la data histórica de 1996 a 2023, con un total de 348 registros de nivel estático del acuífero del valle Chancay Lambayeque....	70
Tabla 16	Análisis descriptivo del nivel estático	71
Tabla 17	Formato de presentación original de la data histórica de 1996 a 2023, con un total de 22 registros de nivel estático del acuífero del valle Chancay Lambayeque.....	72
Tabla 18	Formato de presentación largo de la data histórica de 1996 a 2023, con un total de 1100 registros de nivel estático del acuífero del valle Chancay Lambayeque .	73
Tabla 19	Datos faltantes en data histórica apta del nivel estático desde 1996 hasta 2023 de los pozos del valle Chancay Lambayeque	75
Tabla 20	Ejemplo para determinar un valor faltante	77
Tabla 21	Resumen del proceso de remuestreo.....	79
Tabla 22	Formato de presentación largo de la data histórica trimestral de 1996 a 2023, con un total de 2398 registros de nivel estático del acuífero del valle Chancay Lambayeque	80
Tabla 23	Comparativa de Arquitecturas e Hiperparámetros.....	98
Tabla 24	Comparativa del rendimiento de los modelos predictivos.....	101
Tabla 25	Dimensión de planificación del plan de intervención	112
Tabla 26	Plan maestro de aguas subterráneas.....	113
Tabla 27	Dimensión de organización del plan de intervención	114
Tabla 28	Dimensión de dirección del plan de intervención.....	115
Tabla 29	Dimensión de control del plan de intervención.....	115
Tabla 30	Cronograma de implementación	116

ÍNDICE DE FIGURAS

Figura 1	Acuífero del valle Chancay Lambayeque	33
Figura 2	Tipos de fuentes hídricas subterráneas.....	34
Figura 3	Fases para elaboración de modelos predictivos	38
Figura 4	Proceso de análisis de datos	39
Figura 5	Regresión lineal.....	40
Figura 6	Modelo de Red Neuronal de 3 capas.....	43
Figura 7	Arquitectura de LSTM.....	44
Figura 8	Arquitectura de GRU	45
Figura 9	Pozos Monitoreados vs No Monitoreados por zona.....	64
Figura 10	Clasificación del agua por conductividad eléctrica (CE).....	65
Figura 11	Clasificación del Agua por PH.....	66
Figura 12	Etapas aplicadas en la formulación de un modelo predictivo de aprendizaje máquina.....	67
Figura 13	Tendencia de pozos de la zona Pátapo	85
Figura 14	Tendencia de pozos de la zona Pucala.....	85
Figura 15	Tendencia de pozos de la zona Tumán.....	86
Figura 16	Tendencia de pozos de la zona Chiclayo.....	87
Figura 17	Tendencia de pozos de la zona Pimentel.....	87
Figura 18	Tendencia de pozos de la zona Pomalca.....	88
Figura 19	Tendencia de pozos de la zona Ferreñafe.....	89
Figura 20	Tendencia de pozos de la zona Lambayeque	89
Figura 21	Tendencia de pozos de la zona Mesones Muro.....	90
Figura 22	Tendencia de pozos de la zona Mochumi.....	91
Figura 23	Tendencia de pozos de la zona Tucume.....	91
Figura 24	Tendencia de pozos de la zona Pitipo	92
Figura 25	Distribución del nivel estático por zona	93
Figura 26	Evolución trimestral del nivel estático promedio por zona	93
Figura 27	Nivel estático promedio general del acuífero del valle Chancay.....	94
Figura 28	Comparativa de errores de predicción y R^2	101
Figura 29	Simulación con LSTM con ventana de 20 trimestres y proyección de 2 trimestres.....	103
Figura 30	Simulación con GRU con ventana de 20 trimestres y proyección de 2 trimestres.....	104
Figura 31	Simulación con CNN-LSTM con ventana de 20 trimestres y proyección de 4 trimestres.....	104
Figura 32	Simulación con KNN-RF con ventana de 3 trimestres y proyección de 4 trimestres.....	105
Figura 33	Simulación con EEMD-SVR-RF con ventana de 3 trimestres y proyección de 4 trimestres	106
Figura 34	Modelo Teórico de Gestión Administrativa para el Uso Adecuado del Agua Subterránea.....	107

INFORMACIÓN GENERAL

➤ Título:

Modelo predictivo de aprendizaje máquina para la gestión del agua de fuente subterránea en el valle Chancay Lambayeque

➤ Autor:

MA. Ing. Roberto Carlos Arteaga Lora

➤ Asesor

Dr. Ing. Enrique Santos Nauca Torres (Metodológico)

➤ Línea de investigación

Organización y dirección estratégica de empresas

➤ Lugar

Valle Chancay Lambayeque

➤ Duración estimada del proyecto

Fecha de inicio: 23 de abril de 2025

Fecha de término: 24 de agosto de 2026

RESUMEN

La investigación abordó la problemática del deficiente control y monitoreo de pozos de extracción de agua subterránea en el acuífero del Valle Chancay - Lambayeque, una situación que pone en riesgo la seguridad hídrica, la sostenibilidad agrícola y el abastecimiento poblacional. El estudio se alineó con los Objetivos de Desarrollo Sostenible (ODS 6 y ODS 15), planteando como objetivo general determinar un modelo predictivo de aprendizaje máquina para mejorar la gestión del recurso subterráneo. La metodología adoptó un enfoque cuantitativo prospectivo, evaluando datos históricos de niveles estáticos (1996–2023) en cuatro zonas hidrogeológicas (I, II, III y IV). Se compararon cinco arquitecturas algorítmicas: redes neuronales de memoria profunda (LSTM, GRU, CNN-LSTM con Lag = 20 trimestres) y modelos híbridos de Machine Learning (KNN-RF y EEMD-SVR-RF con Lag = 3 trimestres). Los resultados permitieron caracterizar la dinámica hidrogeológica del acuífero, evidenciando un régimen freático somero regional (1.55 m a 3.50 m) con alta resiliencia multianual. En la evaluación algorítmica, los modelos de ventana corta (KNN-RF y EEMD-SVR-RF) mostraron alta precisión para capturar oscilaciones inmediatas de corto plazo (0.28 m a 2.53 m). Por su parte, las redes de Deep Learning demostraron una capacidad superior para capturar dependencias temporales no lineales multianuales. A través de estas últimas, se identificó de forma unánime que las Zonas I, II y III se mantendrán en Condición Favorable (2.01 m a 3.58 m), mientras que la Zona IV fue diagnosticada sistemáticamente en estado de ALERTA (Monitoreo) debido a un continuo ascenso del nivel freático (2.60 m a 3.04 m), advirtiendo un riesgo de anegamiento y salinización de suelos. Estos hallazgos permitieron comprobar que la modelación predictiva aporta información precisa sobre el nivel estático que resulta técnicamente indispensable para superar la gestión puramente administrativa e informal. Finalmente, sobre esta evidencia se diseñó una propuesta de Plan de Gestión Administrativa articulado a las disposiciones de la Autoridad Nacional del Agua (ANA), estructurado en cuatro dimensiones (Planificación, Organización, Dirección y Control) que incluyen la formulación del Plan Maestro de Aguas Subterráneas (PMAS), la instalación de telemetría IoT en la Zona IV y la formalización de pozos de extracción.

Palabras clave: Fuente subterránea, Aprendizaje máquina, Acuífero, Nivel estático, Gestión administrativa, Monitoreo hídrico.

ABSTRACT

The research addressed the problem of inadequate control and monitoring of groundwater extraction wells in the Chancay-Lambayeque Valley aquifer, a situation that jeopardizes water security, agricultural sustainability, and the supply of water to the population. The study aligned with the Sustainable Development Goals (SDGs 6 and 15), aiming to determine a predictive machine learning model to improve groundwater resource management. The methodology adopted a prospective quantitative approach, evaluating historical static level data (1996–2023) in four hydrogeological zones (I, II, III, and IV). Five algorithmic architectures were compared: deep memory neural networks (LSTM, GRU, CNN-LSTM with a lag of 20 quarters) and hybrid machine learning models (KNN-RF and EEMD-SVR-RF with a lag of 3 quarters). The results allowed for the characterization of the aquifer's hydrogeological dynamics, revealing a shallow regional water table regime (1.55 m to 3.50 m) with high multi-year resilience. In the algorithmic evaluation, the short-window models (KNN-RF and EEMD-SVR-RF) showed high accuracy in capturing immediate, short-term oscillations (0.28 m to 2.53 m). Deep Learning networks, on the other hand, demonstrated a superior capacity for capturing nonlinear, multi-year temporal dependencies. Through these networks, it was unanimously identified that Zones I, II, and III will remain in Favorable Condition (2.01 m to 3.58 m), while Zone IV was systematically diagnosed as being in an ALERT (Monitoring) state due to a continuous rise in the water table (2.60 m to 3.04 m), indicating a risk of flooding and soil salinization. These findings fully confirmed that predictive modeling provides accurate information on the static level that is technically essential to overcome purely administrative and informal management. Finally, based on this evidence, a proposed Administrative Management Plan was designed, aligned with the provisions of the National Water Authority (ANA), and structured around four dimensions (Planning, Organization, Management, and Control). These dimensions include the formulation of the Groundwater Master Plan (PMAS), the installation of IoT telemetry in Zone IV, and the formalization of extraction wells.

Key Word: Underground source, Machine learning, Aquifer, Static level, Administrative management, Water monitoring

INTRODUCCIÓN

• Síntesis de la situación problemática

Hoy en día, las organizaciones competentes en la gestión del uso de agua de fuente subterránea están priorizando estrategias o monitoreos para una adecuada administración, y de esta forma evitando la escasez de la misma. Ante ello, los modelos predictivos de aprendizaje máquina están siendo una alternativa estratégica en la toma de decisiones de los actores que intervienen en el control de uso de agua de fuente subterránea.

En Colombia, en el estudio de Blanco Alfonso (2024) manifestó la existencia de un gran potencial de aguas subterráneas, a causa de una variedad geológica y climática, basándose en la variabilidad de las características hidro geoquímicas de las aguas subterráneas, siendo crucial en la gestión de los recursos hídricos. La relevancia de las aguas subterráneas reside en un papel como fuente de agua potable, para la distribución en las zonas agrícolas y otras actividades agroindustriales. Ante ello, es la única fuente en tiempos de sequías; es por ello, se hace hincapié que debe estar protegida en el uso y ante la contaminación de esta. Por lo tanto, la visión de los entes reguladores a nivel administrativo enfocaría planes de gestión que permitiría un adecuado control mediante modelos predictivos en el uso de agua subterránea.

La presente investigación se vincula con el objetivo de desarrollo sostenible (ODS) 15, referente a la Vida de ecosistemas Terrestres, haciendo hincapié en apoyar a la seguridad alimentaria y el agua a nivel mundial; asimismo la ODS 6, haciendo mención en garantizar el acceso universal al agua potable segura y asequible, siendo las aguas subterráneas uno de los medios a lo mencionado.

La relevancia de las aguas subterráneas reside en un papel como fuente de agua potable, para la distribución en las zonas agrícolas y otras actividades agroindustriales. Ante ello, es la única fuente en tiempos de sequías; es por ello, se hace hincapié que debe estar protegida en el uso y ante la contaminación de esta. Por lo tanto, la visión de los entes reguladores a nivel administrativo enfocaría planes de gestión que permitiría un adecuado control mediante modelos predictivos en el uso de agua subterránea.

Los modelos matemáticos y estadísticos están siendo usados de manera gradual, los cuales se aplican para la formulación de hipótesis, asimismo comprobar su veracidad ante un problema. (Pineda, 2022).

El Machine Learning, está teniendo mayor protagonismo en la gestión de recursos hídricos, que permite mitigar el cambio climático mediante la interpretación de imágenes satelitales, monitorización, aparición o desaparición de acuíferos y lagos. (Vargas-Crispin et. al., 2021)

Para una adecuada gestión eficiente de los recursos hídricos, ha permitido ser un eje relevante para el desarrollo sostenible, lo cual es usado en sectores agrícolas donde el agua es un recurso crítico en la producción de alimentos; ante ello, el desarrollo de modelos predictivos en la gestión de recursos hídricos constituye una respuesta innovadora a los desafíos impuestos por el cambio climático y la creciente demanda de agua en la agricultura. (Santa Rosa, 2024).

Según un informe de la UNESCO, el 40% de la población mundial vive ya en zonas afectadas por el estrés hidrológico, y en 2025 más de dos tercios de la población mundial se enfrentará a problemas de escasez de agua. Esto es preocupante porque el uso del agua se ha duplicado en el último siglo y sigue aumentando a un ritmo del 1% cada año. Entre el 75% y el 80% de este volumen se utiliza en la agricultura; estas cifras ponen de relieve la necesidad crítica de un sistema eficaz y sostenible de gestión del agua en el sector agrario. (UNESCO, 2020).

El 36% del suministro de agua potable en el mundo proviene del agua subterránea, el 43% se utiliza para la agricultura de riego y el 24% para la utilización industrial (Döll et al., 2012, p. 143). No podemos pasar por alto su función en el avance de energías naturales (geotérmica, petróleo y gas) y en la conservación de ecosistemas acuáticos saludables (ríos, lagos y humedales), que requieren su liberación. (Foster y Cherlet, 2014, p. 5).

Del monitoreo realizado al acuífero el valle Chancay Lambayeque, se evidencia que, el inventario desarrollado en el presente valle no representa los cambios que se aprecian en la realidad actual del valle Chancay-Lambayeque,

el número de pozos para extracción de agua subterránea, se incrementó considerablemente (ANA, 2023).

Históricamente, en México, la gestión del agua se ha interpretado como un trabajo hidráulico fundamentado en un enfoque constructivo, en contraposición a una percepción del agua como un elemento natural en su aspecto de utilización y preservación (Carrillo-Rivera et al., 2016, p. 2).

En el Valle de Chancay se ha detectado alto nivel de extracción de agua subterránea lo que ha encaminado a las sequías, por otro lado se tiene una deficiencia en el control de pozos perforados, como de los caudales extraídos en los pozos ya existentes, a todo ello, se origina por la falta capacidad de estudio o diagnóstico mediante la realización de un inventario de recursos hídricos que se debe realizar cada 10 años, y en consecuencia el acuífero que sostiene el Valle Chancay de Lambayeque encaminará a que las actividades agroindustriales y el consumo humano estaría en riesgo en el abastecimiento de agua.

- Formulación del problema de investigación

Problema general:

¿Cómo desarrollar un modelo predictivo de aprendizaje máquina para mejorar la gestión del agua de fuente subterránea en el valle Chancay Lambayeque?

Problemas específicos

¿Cuál es la situación actual en la gestión de agua de fuente subterránea en el valle Chancay Lambayeque?

¿Como un modelo predictivo de aprendizaje máquina mejora la gestión del agua de fuente subterránea en el valle Chancay Lambayeque?

¿Cuál es el plan de gestión para la adecuada utilización de agua subterránea mediante los resultados del modelo predictivo?

- Objetivos

Objetivo General:

Determinar un modelo predictivo de aprendizaje máquina para mejorar la gestión del agua de fuente subterránea en el valle Chancay Lambayeque

Objetivos específicos

Caracterizar la situación actual en la gestión de agua de fuente subterránea en el valle Chancay Lambayeque

Diseñar un modelo predictivo de aprendizaje máquina para la gestión del agua de fuente subterránea en el valle Chancay Lambayeque

Elaborar una propuesta de un plan de gestión administrativa para la adecuada utilización de agua subterránea mediante los resultados del modelo predictivo.

I DISEÑO TEÓRICO

1.1 Antecedentes

Por otro lado, para la investigación se consideró los siguientes antecedentes:

El objetivo de este artículo fue examinar la función de las concesiones de agua subterránea inscritas en el Registro Público de Derechos de Agua, como herramienta de planeación para el agua subterránea en la cuenca del río Ayuquila-Armería. Se empleó una base de datos de los registros de 1994 a 2015, para examinar el consumo y la cantidad de agua consumida que se ha consumido en el periodo de las concesiones otorgadas. A partir de 2009 hubo un incremento en estas variables y una disminución acelerada de la disponibilidad de agua en los acuíferos, en donde algunos se les consideró “sobreexplotados”. Se deduce que la asignación administrativa de los acuíferos no ayuda a comprender la dinámica geohidrológica, y que tal herramienta no está operativa para la planificación y el control. Por ende, resulta imprescindible evaluar la administración actual del agua subterránea y fomentar una transformación hacia una perspectiva holística de ella, conforme a la teoría de los sistemas de flujo (Hernández et al., 2019).

Hoy en día, la inteligencia artificial es una disciplina científica que se ha aplicado desde comienzos de este siglo, especialmente en la gestión de recursos acuáticos. Esta disciplina se ha empleado en la administración de recursos acuáticos para mitigar el grave cambio climático mediante la interpretación de imágenes satelitales, el monitoreo y la predicción de las fluctuaciones de la cubierta vegetal, la existencia o pérdida de acuíferos y lagos, la variación de los volúmenes. Por lo tanto, el propósito de esta investigación es evidenciar la efectividad del aprendizaje automático en la administración de recursos hídricos. Se realizó mediante un estudio sistemático de bases de datos científicas como SciELO, ScienceDirect, Redalyc, Scopus, Web of Science, en lo que respecta a contenidos de Inteligencia Artificial vinculados con los recursos acuáticos. Por lo tanto, se determinó que el Aprendizaje Automático potencia los sistemas de alerta anticipada, mapeo y teledetección. En conclusión, es un método de análisis de datos sumamente eficiente para la interpretación y modelado de información hidrometeorológica, especialmente al emplearse en cuencas hidrográficas (Shortridge et al., 2021).

El objetivo es demostrar la eficacia del ML en la gestión de los recursos hídricos. De acuerdo con Marín y Pineda (2019), su modelo predice a partir de registros y lecturas hidro-meteorológicas, utilizando una red neuronal vinculada a las etapas del Machine Learning (ML), para modelar la información en un intervalo de tiempo específico. Esta es una innovación en el ámbito de la hidrología, trabajando de manera muy eficaz para estimar la escorrentía de man. De acuerdo con Starzyk (2010), El Machine Learning genera un sistema de aprendizaje automático capaz de respaldar la supervisión y mejora del desempeño del sistema, mientras selecciona una acción para tratar los problemas más apremiantes de entre los muchos que pueden resolver de manera eficaz.

Se enfocó en resolver el problema de la predicción del nivel de agua subterránea, debido a su comportamiento complejo y no estacionario en el tiempo. Además, su investigación se basó en encontrar una solución a la dificultad de pronosticar con mayor precisión la profundidad del agua subterránea, teniendo como objetivo proponer un modelo híbrido que mejore la precisión del pronóstico mediante la combinación de descomposición wavelet y redes neuronales LSTM. Como hipótesis, se planteó que el modelo Wavelet–LSTM permitiría obtener mejores resultados de predicción que los métodos tradicionales, para ello, se utilizó la descomposición de ondículas junto con redes neuronales LSTM para el análisis de series temporales, los datos fueron desde el año 2015 hasta el año 2021, tomando como muestra a dos lugares, en China: Lu Wangfen (Pozo n.º 5) y Muye (Pozo n.º 3), en la provincia de Henan y con esto se pudo trabajar con datos de profundidad del agua subterránea del periodo 2005–2021. El resultado mostró que el modelo Wavelet–LSTM obtuvo mejor desempeño que el LSTM convencional y BP, ya que presentó errores relativos promedio cercanos al 2 %, inferiores al 5 % de los otros modelos y, en conclusión, el modelo híbrido demostró ser más preciso y eficiente para la predicción del agua subterránea, por ello, se considera una herramienta útil para la gestión y análisis hidrológico en ingeniería e investigación (Zhang et al., 2023).

Se aborda la problemática de la predicción del nivel de agua subterránea, la cual es relevante por el tema de la sobreexplotación de los acuíferos que generan impactos ambientales y sociales, por lo que se requiere contar con

pronósticos más precisos para una adecuada gestión del recurso hídrico ya que los métodos tradicionales presentan limitaciones para modelar correctamente las variaciones y patrones del nivel freático. El objetivo del estudio es desarrollar un modelo híbrido más preciso, integrando la Descomposición Empírica de Modos (EMD), la Transformada Wavelet (WT) y redes neuronales LSTM y teniendo como hipótesis que un modelo híbrido mejora significativamente la precisión de las predicciones frente a modelos tradicionales. El estudio se basa en datos históricos de nivel de agua subterránea (GWL) obtenidos de tres pozos ubicados en el condado de San Bernardino, California (W0804, W0904 y W4905), con registros diarios del periodo 2017–2022. Los datos se dividen en entrenamiento y prueba para evaluar el desempeño del modelo. Los resultados muestran que el modelo híbrido EMD–LSTM es superior tanto a los modelos Wavelet–LSTM como a los modelos LSTM individuales tradicionales. Según el índice de Error Cuadrático Medio (RMSE), el EMD–LSTM redujo los errores de pronóstico hasta en un 19% y un 78% para los pozos W0804 y W0904, respectivamente. En cambio, para el pozo 4905, WT y EMD no lograron aumentar la precisión del LSTM cuando las fluctuaciones se produjeron aleatoriamente. Estos hallazgos nos demuestran que el modelo EMD–LSTM es una herramienta eficaz para pronosticar los niveles de agua subterránea (Nazari et al., 2025).

Se aborda el problema de la baja precisión en la predicción del nivel del agua, lo que dificulta la prevención de inundaciones y la toma de decisiones oportunas. Este problema es muy importante debido a que los métodos tradicionales no logran una precisión ya que los datos presentan alta variabilidad, ruido, tendencias y comportamiento no estacionario. El objetivo del estudio es proponer un método de predicción más preciso del nivel del agua del Río Rojo del Norte, con el fin de apoyar a anticipar eventos de inundación. La hipótesis plantea que el modelo de aprendizaje profundo LSTM presenta un mejor desempeño predictivo en comparación con modelos tradicionales como SARIMA y Random Forest, debido a su capacidad para modelar relaciones no lineales y dependencias temporales a largo plazo. El estudio utiliza un enfoque cuantitativo comparativo, aplicando tres modelos principales: SARIMA, Random Forest (RF) y LSTM. Los datos corresponden a estaciones hidrológicas ubicadas en las ciudades de Pembina, Drayton y Grand Forks (Estados Unidos), con registros

del periodo 2019–2027. Los resultados, evidencian que el modelo LSTM supera a los modelos SARIMA y Random Forest, presentando menores valores de error (RMSE) en las tres estaciones analizadas (Pembina: 0.190, Drayton: 0.151 y Grand Forks: 0.107), lo que demuestra su mayor precisión en la predicción a corto plazo. Además, el LSTM reduce el error en 77.22% frente a RF y en 78.70% frente a SARIMA, llegando incluso a mejoras de hasta 83.70% en Grand Forks, lo que confirma su mejor capacidad para capturar tendencias y picos del nivel del agua. Finalmente, se concluye que el modelo LSTM es el más preciso para la predicción del nivel del agua en el Río Rojo del Norte, consolidándose como una herramienta eficaz para la prevención de inundaciones y la gestión de riesgos hidrológicos (Atashi et al., 2021).

Se aborda el problema de predecir el nivel freático en regiones áridas y semiáridas, donde la sobreexplotación del recurso hídrico representa un riesgo y donde la baja precisión de los métodos tradicionales son escasos de datos, además de una compleja dinámica no lineal del agua subterránea. El objetivo del estudio es desarrollar un modelo más preciso que permita mejorar la predicción del nivel de agua subterránea incluso con datos limitados y pasa eso se presenta la hipótesis que sostiene que la integración del meta-aprendizaje con el modelo CNN–LSTM–ML mejora significativamente la precisión. Los datos fueron del río Heihe (China), en zonas como Zhangye, Linze, Gaotai, Jinta y Ejinaqi, a partir de 66 pozos de observación con registros de 2003 a 2012, junto con variables meteorológicas. El proceso inicia con la división del problema en múltiples tareas de predicción. Luego, el CNN extrae características relevantes, el LSTM modela dependencias temporales y una capa densa genera la predicción final. Posteriormente, el meta-aprendizaje ajusta los parámetros globales del modelo para mejorar su rendimiento en nuevas tareas. Los resultados muestran que el modelo CNN–LSTM–ML supera a métodos tradicionales como ARIMA, regresión lineal y LSTNet, destacando su mayor precisión y robustez, especialmente cuando los datos son limitados. Además, los experimentos de ablación evidencian que CNN–LSTM–ML mejora en un 26.5% el RMSE respecto a la estructura CNN–LSTM original. Finalmente, se concluye que el modelo CNN–LSTM–ML es eficaz para la predicción del nivel de agua subterránea, mejorando

la precisión y la capacidad de generalización, lo que lo convierte en una herramienta útil para la gestión de recursos hídricos (Yang et al., 2022).

El artículo titulado “Modelo de predicción del nivel de agua subterránea a largo plazo basado en la técnica híbrida KNNRF” aborda el problema de la baja precisión en la predicción del nivel freático debido a la escasez y limitada calidad de los datos, por esta situación es que se dificulta la generación de pronósticos confiables y evidencia la necesidad de modelos más robustos para trabajar en contextos con información limitada. El objetivo del estudio es desarrollar y asegurarnos que un modelo de aprendizaje automático es capaz de predecir de manera eficiente el nivel de agua subterránea, evaluando su desempeño mediante métricas estadísticas que garanticen su confiabilidad y por esto se plantea la hipótesis de que el modelo híbrido KNNRF mejora la caracterización de la variación estacional del nivel freático, incluso en condiciones de datos escasos. Además, se tiene como lugar de estudio los datos del acuífero de Mukarange, en Ruanda oriental, específicamente del pozo F6, con registros diarios del periodo 2016–2018. Estos datos permiten analizar el comportamiento del nivel freático con datos limitados reales. Los resultados, el modelo KNNRF supera a los modelos comparados (KNN, RF, SVM Y ANN) en todas métricas de evaluación (MAE, RMSE, R^2 YNSE), logrando un alto rendimiento del modelo propuesto en términos de error cuadrático medio (RMSE=0.0031), error absoluto medio (MAE=0.0022), Nash-Sutcliffe (NSE=0.9346) y coeficiente de determinación ($R^2=0.9387$) con plazo de predicción de 90 días. Finalmente, se concluye que el modelo híbrido KNNRF es una alternativa robusta y precisa para la predicción del nivel de agua subterránea en condiciones de datos limitados, demostrando mejor capacidad de generalización y contribuyendo a la gestión y planificación sostenible de los recursos hídricos (Haji, 2022).

El artículo titulado “Una descomposición en modo conjunto combinada con modelo SVRRF para la predicción del nivel de aguas subterráneas: caso de los acuíferos de Ruanda Oriental” aborda la dificultad de obtener predicciones precisas del nivel freático debido a la complejidad del sistema hidrogeológico y a la poca disponibilidad de datos. El objetivo del estudio es mejorar la predicción del nivel de agua subterránea mediante la integración del uso de modelos híbridos, específicamente EEMD con un modelo híbrido SVR–RF. La hipótesis plantea que esta ayuda a superar las limitaciones de los datos y mejorar significativamente la precisión predictiva frente a métodos individuales. El estudio utilizó datos de la provincia Oriental de Ruanda, específicamente en Mukarange (Kayonza) y Rugarama (Gatsibo), con registros de dos pozos de observación (F6 y F7) entre 2016 y 2020. Los datos incluyen variables hidroclimáticas y niveles freáticos transformados a series diarias. Los resultados muestran que el modelo EEMD–SVRRF supera a los modelos comparados (EEMD–SVR, EEMD–RF y EEMD–ANN), obteniendo menores errores y mayores valores de R^2 y NSE. Destaca el rendimiento en el pozo de Rugarama, donde alcanza un R^2 de 0.9608 superando a los otros modelos como EEMD-SVM, EEMD-RF y EEMD-ANN en 90 días y también obtuvo un NSE de 0,9586, siendo más preciso que los demás métodos comparados. Esto demuestra que el EEMD-SVM-RF tiene mejor capacidad de predicción. En general, es más confiable para estimar aguas subterráneas incluso con pocos datos demostrando mejor desempeño en predicciones, que lo convierte en una herramienta útil para la gestión de recursos hídricos y la toma de decisiones (Haji, 2022).

1.2 Estado del arte

En los últimos años, la predicción del nivel freático ha sido abordada mediante distintos enfoques, evolucionando desde modelos estadísticos tradicionales hacia modelos basados en aprendizaje automático y aprendizaje profundo, debido a la complejidad de las series temporales hidrológicas, caracterizadas por no estacionariedad, ruido y comportamiento no lineal.

Inicialmente, los modelos tradicionales como SARIMA, regresión lineal y métodos estadísticos fueron ampliamente utilizados; sin embargo, encontramos muchos estudios que evidencian que estos presentan limitaciones significativas para capturar patrones no lineales y variaciones abruptas en las series

temporales. En respuesta a ello, Atashi et al. (2022) implementaron modelos basados en Redes Neuronales Recurrentes (RNR) LSTM (Memoria a corto y largo plazo), demostrando que resulta una mejora en la precisión para pronosticar comportamientos no lineales y cambios abruptos en la serie temporal, frente a modelos tradicionales. No obstante, aunque el modelo LSTM logra capturar dependencias temporales de largo plazo, no desaparece completamente el ruido de los datos ni la no estacionariedad, lo que se hace limitado su desempeño en series complejas.

Ante esta limitación, Zhang et al. (2023) propusieron un modelo híbrido Wavelet-LSTM, incorporando una etapa de descomposición de la señal antes del modelado. Este enfoque permitió separar componentes de alta y baja frecuencia, reduciendo el ruido y mejorando significativamente la precisión, alcanzando errores relativos cercanos al 2 %. Esto nos quiere decir que, el modelo no solo mejora la predicción, sino que logra una mayor capacidad de forma general, especialmente en series temporales largas.

De manera similar, Nazari et al. (2024) desarrollaron modelos híbridos basados en la combinación de EMD (Descomposición de modo empírico), Wavelet y LSTM, obteniendo mejoras en métricas como RMSE (Raíz de error cuadrático medio), MAE (Error absoluto medio) y R^2 . Estos modelos nos demostraran una alta capacidad para modelar la no estacionariedad cuando se trata de datos que oscilan drásticamente; sin embargo, su difícil estructura incrementa nuevos requerimientos computacionales, lo que hace limitado su uso en realidades con recursos restringidos.

Por otro lado, Yang & Zhang (2022) propusieron un modelo CNN (Red neuronal convolucional) - LSTM con meta-aprendizaje, el cual alcanzó altos niveles de precisión en escenarios con múltiples variables y gran cantidad de datos. A pesar de ser modelos muy eficientes, su aplicación es limitada en contextos con pocos pozos o datos incompletos como en nuestra investigación, debido a que estos modelos trabajan con grandes volúmenes de información.

Asimismo, Hají (2022) evaluó modelos híbridos como EEMD (Descomposición en modo empírico de conjunto) - SVR (Regresión de vectores de soporte) - RF (Bosques aleatorios) y KNN (K Vecinos cercanos) - RF,

obteniendo valores elevados de R^2 en contextos específicos. No obstante, estos modelos presentan menor estabilidad en series temporales largas, lo que impacta negativamente su capacidad de extensión en escenarios reales.

Se puede decir que los modelos híbridos superan a los modelos individuales, porque al integrar técnicas de descomposición que reducen la no estacionariedad y mejoran la precisión predictiva se puede obtener mejores resultados más precisos. No todos los modelos híbridos son más adecuados en cualquier situación ya sea en datos completos como incompletos, ya que algunos requieren grandes volúmenes de datos o presentan limitaciones en estabilidad.

1.3 Bases epistemológicas

La presente investigación se sustenta en una epistemología positivista, debido a que busca comprender y predecir el comportamiento del agua subterránea mediante el análisis objetivo de datos hidrológicos, climáticos y ambientales. Desde esta perspectiva, se considera que los fenómenos naturales pueden estudiarse de manera sistemática a través de la observación, la medición y el uso de herramientas científicas que permitan identificar patrones y relaciones entre variables. En el ámbito de los recursos hídricos, los modelos de aprendizaje automático han demostrado una capacidad significativa para representar procesos complejos y mejorar la precisión de las predicciones relacionadas con los acuíferos (Tao et al., 2022).

Asimismo, la investigación adopta una orientación empirista, puesto que el conocimiento se construye a partir de evidencias obtenidas de datos reales. En este sentido, los algoritmos de aprendizaje máquina aprovechan grandes volúmenes de información histórica para reconocer tendencias y comportamientos que pueden pasar desapercibidos mediante métodos convencionales. Según Ahmadi et al. (2022), el uso de técnicas de inteligencia artificial ha permitido incrementar la capacidad predictiva en estudios relacionados con los niveles de agua subterránea, favoreciendo una mejor comprensión de la dinámica de los acuíferos.

De igual forma, el estudio incorpora una visión tecnocientífica del conocimiento, donde la ciencia y la tecnología se integran para abordar problemas complejos de gestión ambiental. Desde esta perspectiva, los modelos

computacionales no solo cumplen una función analítica, sino que también se convierten en herramientas de apoyo para la toma de decisiones. Como señalan Di Salvo (2022) y Yaseen et al. (2023), la incorporación de técnicas de inteligencia artificial en la gestión del agua permite optimizar los procesos de monitoreo, evaluación y planificación de los recursos hídricos.

Por otra parte, la investigación presenta una orientación pragmática, ya que el propósito principal del conocimiento generado es contribuir a la solución de problemas reales asociados a la sostenibilidad del recurso hídrico. En consecuencia, la utilidad práctica del modelo predictivo constituye un criterio fundamental para valorar su aporte, especialmente en contextos donde la presión sobre los acuíferos exige decisiones oportunas y fundamentadas. En esta línea, Cuthbert et al. (2023) destacan la importancia de desarrollar herramientas científicas que fortalezcan la gestión sostenible de las aguas subterráneas y favorezcan la seguridad hídrica a largo plazo.

1.4 Bases teóricas

En razón a las teorías de la variable modelo predictivo de aprendizaje, según a Tóth (citado por Juárez et al., 2019) menciona la teoría de los sistemas es el flujo que permite representar al ambiente hidrogeológico, basado en un modelo conceptual, lo cual alinea parámetros geológicos, hidrológicos, edáficos, de vegetación y geomorfológicos, los cuales determinan el estado del flujo de agua subterránea, en donde ocasiona manifestaciones contrastantes en superficie entre las zonas de recarga y descarga.

En términos generales, la teoría de la toma de decisiones sostiene que el decisor elige un acto de entre una variedad de alternativas, cuyo desenlace depende de la elección elegida como los posibles estados naturales que el decisor tiene un conocimiento parcial. (Antón,2024).

En relación con la variable gestión, existen teorías vinculadas a los enfoques de administración y gestión. Los paradigmas científicos han influido y moldeado el desarrollo histórico de diversas doctrinas administrativas y, a su vez, han originado distintas teorías de gestión y gerencia que han servido como fundamentos en los procesos prácticos y operativos de administración de las organizaciones. En este contexto, Casassus (2005, 2009) y Narváez et al.

(2011) argumentan que las estrategias de administración de las organizaciones se fundamentan en teorías administrativas originadas en las diversas teorías científicas.

En la ontología de la rama científica de administración y en la teoría organizacional, las categorías "administración", "gestión" y "gerencia" se conceptualizan desde tres perspectivas distintas. (Ropa-Carrión & Alama-Flores, (2022a). La base teórica de la circularidad del agua radica en el ciclo hidrológico del agua; el procedimiento de desplazamiento del agua entre los diferentes compartimentos que componen la hidrosfera (Díaz-Ríos, 2021).

1.4.1 Recurso hídrico

Es un recurso regulado en su uso, gestión integral, la actuación del estado, las particularidades de su gestión y bienes asociados. Comprende el agua superficial, subterránea, continental y los bienes asociados a esta, se extiende al agua marítima y atmosférica en lo que resulte aplicable. Las premisas fundamentales aplicables son:

- El agua constituye patrimonio de la nación.
- El dominio sobre ella es inalienable e imprescriptible.
- Es un bien de uso público. Su administración solo puede ser otorgada y ejercida con el bien común, la protección ambiental y el interés de la nación.
- No hay propiedad privada sobre el agua (Ley de recursos hídricos N° 29338, 2009).


1.4.1.1 Acuífero

Formación geológica que permitiendo la circulación de agua por sus poros o grietas hace que el hombre pueda aprovecharla en cantidades económicamente apreciables para satisfacer sus necesidades, según (Custodio, E y Lamas, M. 1976: 259)

Si se analiza detenidamente esta definición (del latín agua = agua y fero = llevar), se aprecia que el agua encerrada en una formación geológica cualquiera (gravas de un río, calizas muy agrietadas, areniscas porosas) puede

estar ocupando ya sea los poros o vacíos intergranulares que presenta la misma, ya sean las fracturas, diaclasas o grietas que también pueden darse.

Figura 1
Acuífero del valle Chancay Lambayeque




Nota: ANA

1.4.1.2 Nivel freático

El nivel freático corresponde a la superficie del agua subterránea en un acuífero donde la presión del agua es igual a la presión atmosférica. Esta cota marca el límite entre la zona no saturada y la zona saturada del suelo o las rocas. El nivel freático puede subir o bajar dependiendo de la recarga del acuífero (por lluvia, ríos o infiltración) y la extracción de agua por pozos o bombeos (Wunsch et al., 2021).

Figura 2
Tipos de fuentes hídricas subterráneas



Nota: Cabrejos, 2018

En lo que corresponde a la data del nivel freático esta se guarda como una serie temporal, la cual se define como una secuencia de observaciones del mismo fenómeno, que son registradas en diferentes momentos de tiempo y en intervalos constantes. En hidrología la medición del nivel freático en un pozo a lo largo de semanas, meses o años conforman la serie temporal. Estas pueden presentar características como tendencia, estacionalidad o ruido, lo que hace necesaria la utilización de modelos predictivos adecuados (Wunsch et al., 2021).

Mención aparte para la no estacionariedad de la serie temporal, lo cual hace referencia a que las propiedades estadísticas de una serie temporal como la media o la varianza cambian con el tiempo. Esto ocurre con frecuencia en datos hidrológicos porque influencias como el clima, la extracción de agua o fenómenos extremos alteran el comportamiento de la serie. Los modelos tradicionales que suponen estacionariedad no son adecuados para este tipo de series temporales (Boo et al., 2024).

Interpretación del nivel freático para la gestión de aguas subterráneas

El nivel estático del agua subterránea constituye uno de los principales indicadores para evaluar el comportamiento hidrodinámico de un acuífero, debido a que de esta manera se puede evaluar a los procesos de recarga natural y extracción de agua en este caso en el Valle Chancay. En el tema de la gestión de este recurso es muy importante saber el nivel estático del agua para poder usarlo como indicador de estabilidad, abatimiento o recuperación del acuífero, proporcionando información técnica para la toma de decisiones relacionadas con el aprovechamiento sostenible del recurso. Como lo menciona Alley et al. (1999), el nivel estático del agua subterránea es un indicador fundamental para evaluar el comportamiento del acuífero, ya que refleja los efectos de la recarga natural y la extracción de agua, proporcionando información para su gestión sostenible.

Hay muchos estudios que han concluido que para poder interpretar el nivel estático no se debe tomar en cuenta valores universales, porque cada acuífero tiene diferentes características, tiene diferentes condiciones en la manera de recarga, explotación y comportamiento temporal de cada acuífero, además que cada uno posee características hidrogeológicas particulares. En consecuencia, los umbrales de interpretación deben establecerse utilizando el comportamiento histórico del propio acuífero y no mediante valores fijos aplicables a todas las zonas (Alley et al., 1999; California Department of Water Resources, 2016).

Asimismo, hay mucha literatura especializada que nos cuenta que la forma más adecuada de establecer criterios de interpretación consiste en analizar estadísticamente la información histórica disponible en este caso la Data del Valle Chancay, obteniendo parámetros descriptivos como la media, el valor mínimo y el valor máximo de cada zona (I, II, III, IV). La interpretación de los niveles de agua subterránea debe realizarse utilizando estadísticas a partir de la Data histórica del Valle Chancay, ya que estas permiten comparar las mediciones recientes con el comportamiento histórico del acuífero (U.S. Geological Survey, s. f.). Estos indicadores permiten definir cómo va el comportamiento del acuífero para luego saber interpretar los resultados obtenidos en el modelo predictivo que quedaría como el más eficiente y de esta manera facilitar la toma de decisiones por parte de las entidades responsables de la administración del agua.

En la presente investigación, el análisis se realizó de manera independiente para las cuatro zonas del acuífero del valle Chancay–Lambayeque (Zona I, Zona II, Zona III y Zona IV), debido a que cada una presenta condiciones hidrogeológicas diferentes y está representada por pozos con registros históricos completos desde 1996 al 2023. Con estos datos se calcularon la media histórica, el valor mínimo y el valor máximo del nivel estático para cada zona, estos datos servirán como criterios de referencia para interpretar los resultados pronosticados por el modelo más eficiente que saldrá de esta investigación.

Tabla 1
Estadísticos históricos del nivel estático NE (metros) por zona

Zona	Número de registros	Media histórica (m)	Mínimo histórico (m)	Máximo histórico (m)
Zona Uno	192	6.81	0.42	13.20
Zona Dos	184	7.43	0.19	14.66
Zona Tres	339	4.22	0.03	8.40
Zona Cuatro	344	2.20	0.00	4.40

Nota: elaborado en base a la data histórica de la ANA

Tabla 2
Criterios para la interpretación del nivel estático NE (metros) pronosticado

Zona	Condición favorable (m)	Condición de alerta (m)	Condición de riesgo (m)
Zona Uno	0.42 <= NE <= 6.81	6.81 < NE <= 13.20	NE > 13.20
Zona Dos	0.19 <= NE <= 7.43	7.43 < NE <= 14.66	NE > 14.66
Zona Tres	0.03 <= NE <= 4.22	4.22 < NE <= 8.40	NE > 8.40
Zona Cuatro	0.00 <= NE <= 2.20	2.20 < NE <= 4.40	NE > 4.40

Nota: elaborado en base a la data histórica de la ANA

1.4.2 Machine Learning y algoritmos predictivos

El Aprendizaje Automático hace referencia a la capacidad de un sistema o máquina de adquirir e identificar patrones complejos mediante el manejo de grandes volúmenes de datos a través de algoritmos particulares. Adicionalmente, es destacable la diversidad de programas/herramientas existentes para la implementación de estos algoritmos, siendo Python y R los lenguajes más habituales para tal fin. (Dellot y Balaram, 2019). Específicamente, Python proporciona librerías especializadas como SciPy, que incluyen NumPy y Pandas para operaciones de álgebra lineal, y Scikit Learn, una biblioteca de código abierto destinada a algoritmos de aprendizaje supervisado y no supervisado.

También hay plataformas, como IBM Watson Analytics, que ofrecen interfaces intuitivas y herramientas para simplificar la implementación y el análisis, posibilitando, por ejemplo, cargar archivos en la nube y gestionarlos para adquirir percepciones. En el Aprendizaje Automático, se suele aplicar el análisis predictivo, utilizando métodos matemáticos para analizar datos actuales y anticipar sucesos o resultados futuros basándose en la información procesada. (Agrawal et al., 2019).

Para examinar la información, se pueden elegir dos métodos de aprendizaje automático.: En el aprendizaje supervisado, los algoritmos trabajan con datos que han sido previamente "etiquetados", en busca de una función que pueda relacionar adecuadamente una etiqueta de salida con las variables de entrada.


En el entrenamiento, se ajusta el algoritmo utilizando un conjunto de entrenamiento (training set) con el objetivo de anticipar la respuesta para un conjunto de prueba (test set) seleccionado (Dellot y Balaram, 2019).

En cambio, en el aprendizaje no supervisado, se manejan datos de entrada sin las correspondientes etiquetas. Como las salidas no están preestablecidas para los ingresos, la meta es examinar la estructura interna de los datos con el fin de detectar patrones o grupos comunes, tal como se lleva a cabo en métodos de agrupación (clustering) (Dellot y Balaram, 2019).

1.4.2.1 Fases de un proyecto de Machine Learning

Los modelos predictivos en aprendizaje máquina, se basa en las siguientes fases para el proceso de la información:

Figura 3
Fases para elaboración de modelos predictivos




Nota. Tomado de (Komorebi AI, 2023).

Modelos Computacionales

Los modelos informáticos son simulaciones de sistemas reales, generados a través de algoritmos y ejecutados en ordenadores. Facilitan el estudio y experimentación de fenómenos complejos en un ambiente virtual regulado.

Estos modelos pueden oscilar entre sencillas fórmulas matemáticas hasta simulaciones minuciosas de procesos físicos, biológicos o sociales. Son fundamentales en campos como la meteorología, la ingeniería y las ciencias cognitivas, ofreciendo percepciones detalladas, mejorando procedimientos y anticipando resultados. El progreso tecnológico incrementa su eficacia, posibilitando simulaciones cada vez más exactas y detalladas (Núñez et al., 2011).

Figura 4
Proceso de análisis de datos



Nota. Ejemplo de un proceso de aprendizaje automático. Tomado de (Blanco, 2015).

1.4.2.2 Algoritmos predictivos


Los algoritmos predictivos son modelos de aprendizaje automático (Machine Learning) y análisis estadístico diseñados para identificar patrones recurrentes y relaciones no lineales dentro de series históricas de datos. Su propósito principal es realizar inferencias cuantitativas y proyectar escenarios futuros con un margen de error minimizado. En el ámbito del modelado hidrológico, estas técnicas (como redes neuronales recurrentes LSTM, GRU o ensamblajes como KNN-RF) procesan secuencias temporales para predecir la evolución del nivel freático a partir del comportamiento histórico del acuífero (Bishop, 2006; Hastie et al., 2009).

1.4.2.2.1 Regresión Lineal

El modelo lineal de regresión analiza la relación entre una variable dependiente y diversas variables independientes, ilustrando esta relación mediante una ecuación lineal en relación con los parámetros. El objetivo del algoritmo es establecer los parámetros que reducen al mínimo la suma total de los cuadrados de las diferencias entre los valores detectados y los pronosticados por este modelo. En resumen, intenta definir la línea recta que mejor se ajuste a

los datos, mediante un procedimiento denominado método de mínimos cuadrados, tal como se muestra en la siguiente figura. (Cortés y Rubalcava,1983).

Figura 5
Regresión lineal



Nota. Tomado de (Pousada, 2021).

1.4.2.2.2 Árboles de decisión

En el campo de la computación, los árboles se utilizan extensamente para representar diversas circunstancias y estructuras, particularmente para representaciones jerárquicas que simplifican operaciones y desplazamientos de forma recursiva. Un árbol se compone de un nodo central llamado raíz, que le sigue a ramas, nodos secundarios y nodos finales denominados hojas. (Bonaccorso, 2018).

Un árbol de decisiones, que se expande desde un nodo base, emplea nodos para simbolizar las decisiones. Cada nodo ratifica determinadas características, cuyos resultados orientan el flujo a través de las ramas hacia otros nodos, donde se realizan más elecciones, o hacia un desenlace final (Larose y Larose, 2014)

Para que un árbol de decisiones resulte eficaz en la clasificación, debe satisfacer tres requisitos fundamentales:

- Contar con un conjunto de datos de entrenamiento que apoye el aprendizaje supervisado centrado en una variable objetivo.
- Es necesario garantizar que la base de datos de entrenamiento sea variada y no tenga sesgo.
- Pronosticar que la variable tenga un carácter discreto.

1.4.2.2.3 K-NN vecinos más cercanos

K-NN vecinos más próximos K-NN, también conocido como k-vecinos más próximos, es un método de aprendizaje supervisado que se aplica a actividades de clasificación y regresión. Opera tomando en cuenta los ejemplos de entrenamiento más cercanos en el espacio de atributos (Liu., 2022). Para categorizar en K-NN, el algoritmo otorga una categoría al objeto, basándose en la mayoría de los votos de sus vecinos más próximos. Si k es equivalente a 1, el objeto se categoriza de acuerdo a su único vecino más próximo.

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

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

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

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

K-NN se categoriza como aprendizaje basado en instancia o perezoso, debido a que no produce una función discriminativa específica, sino que memoriza las instancias de entrenamiento para emplearlas en la predicción.

En este algoritmo, la selección de k es crucial, dado que un k reducido puede ser propenso a irregularidades, mientras que un k amplio puede diluir las fronteras entre las clases. Usualmente, se cuantifica la separación entre los puntos utilizando la distancia euclidiana, particularmente en espacios de diversas dimensiones:

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

1.4.2.2.4 Redes neuronales


El cerebro humano, con sus cerca de 100 mil millones de neuronas vinculadas, posee una habilidad extraordinaria para identificar patrones y regula una gran cantidad de las funciones corporales. Tanto los matemáticos como los científicos han tratado de descifrar y representar matemáticamente su intrincada mecánica.

El ámbito de las Redes Neuronales (NN) o Artificiales Neuronales (ANN) se originó hace aproximadamente 80 años. En 1943, Warren McCulloch, neurofisiólogo y matemático Walter Pitts, plantearon una teoría acerca del funcionamiento neuronal, desarrollando una NN neuronal con circuitos electrónicos.

En 1957, Frank Rosenblatt realizó un avance importante al crear el perceptrón, antecesor de la neurona actual, que tenía la habilidad de aprender e identificar nuevos patrones después de ser sometido a patrones parecidos, aunque presentaba restricciones en la categorización de clases no separables linealmente.

Una red neuronal común consta de tres niveles: uno de entrada para la información, uno oculto donde los datos son procesados a través de funciones de activación, y uno de salida que muestra los resultados. Estas redes presentan variaciones en su complejidad, en función del número de capas y la cantidad de neuronas presentes en cada una. Se puede observar una red de tres capas en la imagen suministrada, donde la primera alberga cuatro neuronas, la segunda dos, y la tercera una sola neurona que proporciona el resultado (Srinivas, 2021).

Figura 6
Modelo de Red Neuronal de 3 capas



Nota. Tomado de (Srinivas, 2021).

Las redes neuronales de una sola capa funcionan a través de las salidas producidas por las neuronas de la primera capa. Cada neurona procesa los datos obtenidos a través de una operación denominada función de activación. Estas funciones de activación son vitales para detectar patrones y mitigar posibles ruidos en los datos de entrada. Se categorizan en tres categorías fundamentales, que son:

Funciones Binarias de Activación: Se activan en función de un límite preestablecido. Si el ingreso (x) es inferior a cero, la salida es 0, mientras que si es equivalente o superior, la salida es 1. En términos matemáticos, se ilustra de la siguiente manera:

$$f(x) = \begin{cases} 0, & \text{si } x < 0 \\ 1, & \text{si } x \geq 0 \end{cases}$$

Funciones de Activación Lineales: Estas están gobernadas por ecuaciones lineales sencillas y se pueden representar como $f(x) = x + b$, siendo b una constante.

Funciones No Lineales de Activación: Estas funciones gestionan entradas de valor auténtico y producen salidas fundamentadas en un modelo lineal de regresión. Son beneficiosos para facilitar la conexión entre las entradas y salidas sin añadir una complejidad excesiva al mapa (Liu, et al., 2022).

1.4.2.2.4.1 Redes Neuronales Recurrentes (RNN)


Están diseñadas específicamente para el procesamiento de datos secuenciales. A diferencia de las redes feedforward, las RNN incorporan conexiones recurrentes que permiten mantener un estado interno o memoria, integrando información pasada en el cálculo actual.

El objetivo de las RNN es modelar dependencias temporales, lo que las hace particularmente adecuadas para series temporales hidrológicas. Sin embargo, las RNN tradicionales presentan limitaciones asociadas al problema del gradiente desvanecido, lo cual dificulta el aprendizaje de dependencias de largo plazo (Bengio et al., 1994).

Para superar esta limitación, se desarrolló el modelo Long Short-Term Memory (LSTM), que incorpora mecanismos de compuertas para controlar el flujo de información (Hochreiter & Schmidhuber, 1997). Actualmente, las variantes LSTM constituyen una de las arquitecturas más utilizadas en predicción de niveles de aguas subterráneas (Kratzert et al., 2021).

La arquitectura LSTM, propuesta por Hochreiter y Schmidhuber (1997), se presenta en la siguiente figura.


Figura 7
Arquitectura de LSTM



Gated Recurrent Unit (GRU), existe como una arquitectura de RNN que es una versión simplificada de LSTM, diseñada para modelar dependencias temporales en series de tiempo mediante un menor número de parámetros. Solo emplea dos compuertas (actualización y reinicio) que reduce su complejidad

estructura, facilitando un entrenamiento rápido y estable (Cho et al., 2014; Goodfellow et al., 2016).

Figura 8
Arquitectura de GRU



1.4.2.2.5 Modelos híbridos

Las RNR puras evolucionan integrándose en arquitecturas multinivel para retos complejos de ingeniería.

Tabla 3
COMPARATIVO DE MODELOS PREDICTIVOS PARA LA GESTIÓN DEL AGUA SUBTERRÁNEA

Modelo	Fundamento teórico	Ventajas	Limitaciones	Aplicación en la gestión del agua subterránea	Referencia
LSTM	Red neuronal recurrente diseñada para capturar dependencias temporales de largo plazo mediante celdas de memoria.	Identifica patrones complejos y relaciones no lineales en series temporales hidrológicas.	Requiere gran cantidad de datos y entrenamiento adecuado para alcanzar alto desempeño.	Predicción de niveles freáticos y comportamiento temporal de acuíferos.	Hochreiter y Schmidhuber (1997); Xiang et al. (2020).
Wavelet-LSTM	Combina la Transformada Wavelet con LSTM para separar componentes de alta y baja frecuencia antes de la predicción.	Mejora la precisión y estabilidad de las predicciones en series no estacionarias.	Su rendimiento depende de la calidad de la descomposición de la señal.	Predicción de profundidad y nivel de agua subterránea.	Zhang et al. (2023); Wu et al. (2021).

EMD-WT-LSTM	Integra Empirical Mode Decomposition (EMD), Wavelet y LSTM para capturar dinámicas de distintas escalas temporales.	Permite modelar estructuras no lineales y no estacionarias con mayor precisión.	Puede generar sobreajuste cuando la serie no presenta suficiente complejidad estructural.	Pronóstico de acuíferos con variaciones estacionales e interanuales.	Nazari et al. (2024/2025); Wang et al. (2023).
CNN-LSTM-ML	Combina CNN para extracción de características, LSTM para dependencias temporales y un algoritmo ML para optimización final.	Captura simultáneamente relaciones espaciales y temporales.	Mayor complejidad computacional y necesidad de grandes volúmenes de datos.	Predicción hidrológica multivariable considerando precipitación, temperatura y extracción.	Yang y Zhang (2022); Sun et al. (2022); Zhao et al. (2022).
EEMD-SVRRF	Combina EEMD, SVR y Random Forest para modelar relaciones complejas y no lineales.	Reduce ruido, mejora estabilidad y aumenta la capacidad predictiva.	Mayor complejidad de implementación y procesamiento.	Modelo con buen desempeño	Haji (2024); Wang et al. (2023); Wu y Huang (2009).

KNN-RF	Combina K-Nearest Neighbors y Random Forest para aprovechar similitud local y ensamble de árboles.	Fácil interpretación y buen desempeño cuando existen patrones relativamente consistentes.	Menor estabilidad temporal en series complejas y largas.	Utilizado como modelo comparativo frente a arquitecturas profundas.	Haji (2024); Ahmed et al. (2020); Mosavi et al. (2021).

Tabla 4
CUADRO COMPARATIVO DE ALGORITMOS PARA PREDICCIÓN DE AGUAS SUBTERRÁNEAS

Algoritmo	Descripción	Ventajas	Limitaciones	Referencia
LSTM (Long Short-Term Memory)	Red neuronal recurrente diseñada para capturar dependencias temporales de largo plazo mediante mecanismos de memoria.	Excelente para series temporales complejas y no lineales. Permite modelar patrones hidrológicos de largo plazo.	Requiere mayor cantidad de datos y capacidad computacional.	Hochreiter y Schmidhuber (1997); Xiang et al. (2020).
GRU (Gated Recurrent Unit)	Variante simplificada de LSTM que utiliza únicamente compuertas de actualización y reinicio.	Menor complejidad, entrenamiento más rápido y desempeño similar a LSTM.	Puede ser menos robusto cuando existen dependencias extremadamente largas.	Cho et al. (2014); Goodfellow et al. (2016).
SVR (Support Vector Regression)	Método basado en máquinas de soporte vectorial que utiliza funciones kernel para modelar relaciones no lineales.	Buen rendimiento en aplicaciones ambientales y climáticas.	Sensible a la selección de parámetros y kernels.	Bansal et al. (2021).

Random Forest (RF)	Método de ensamble basado en múltiples árboles de decisión.	Reduce el sobreajuste y mejora la estabilidad de las predicciones.	No captura directamente dependencias temporales.	Xu et al. (2021).
K-Nearest Neighbors (KNN)	Algoritmo basado en similitud local entre observaciones.	Fácil implementación y capacidad para identificar patrones locales.	Depende de la normalización y de la métrica de distancia utilizada.	Martínez et al. (2019).
RNN (Redes Neuronales Recurrentes)	Redes diseñadas para procesar secuencias temporales y dependencias cronológicas.	Modelan la evolución temporal de las variables hidrológicas.	Problemas de gradiente cuando existen secuencias largas.	Bengio et al. (1994).
CNN (Convolutional Neural Network)	Arquitectura utilizada para extraer características complejas de los datos antes del proceso predictivo.	Identifica patrones espaciales y relaciones complejas.	Requiere gran cantidad de datos para alcanzar alto rendimiento.	LeCun et al. (1998).

STGNN (Spatio-Temporal Graph Neural Network)	Red neuronal de grafos que aprende simultáneamente relaciones espaciales y temporales entre pozos de monitoreo.	Captura interacciones hidrológicas entre múltiples ubicaciones.	Alta complejidad computacional y estructural.	Taccari (2024).
--	---	---	---	-----------------

Tabla 5
ALGORITMOS DE DESCOMPOSICIÓN UTILIZADOS EN MODELOS HÍBRIDOS

Algoritmo	Función principal	Referencia
Wavelet Transform (WT)	Descompone la señal en componentes de alta y baja frecuencia para eliminar ruido y mejorar la predicción.	Mallat (1989); Daubechies (1992).
EMD (Empirical Mode Decomposition)	Divide series temporales no estacionarias en funciones modales intrínsecas.	Huang et al. (1998).
EEMD (Ensemble Empirical Mode Decomposition)	Versión mejorada del EMD que reduce el efecto del ruido y mejora la estabilidad predictiva.	Wu y Huang (2009).

1.4.3 Impacto ambiental y gestión

El impacto ambiental hace referencia a las modificaciones en el entorno causadas por acciones humanas o sucesos naturales. Incorpora modificaciones en la biodiversidad, recursos de agua, calidad del aire, terrenos y ecosistemas. Puede ser beneficioso o perjudicial, aunque a menudo se vincula con perjuicios como la contaminación, la deforestación y la desaparición de especies. Es fundamental la valoración del impacto ambiental para organizar y atenuar impactos negativos en proyectos de desarrollo (Guillén et al., 2020).

Sostenibilidad

La sostenibilidad es una filosofía y método de desarrollo que aspira a cubrir las demandas presentes sin poner en riesgo la habilidad de las generaciones venideras para satisfacer las de ellas. Incorpora elementos económicos, sociales y medioambientales, fomentando un balance entre desarrollo y preservación. Su perspectiva incluye la administración consciente de recursos, disminución de la huella ecológica y promoción de la equidad social. La sostenibilidad es esencial en diversos campos, desde la agricultura hasta la industria, para un futuro resistente y floreciente, garantizando la armonía entre la humanidad y el planeta (Guillén et al., 2020).

En razón a las dimensiones del modelo predictivo del aprendizaje máquina, según Developers, (2021) son: (i) Desempeño, teniendo como indicadores de precisión: RMSE, MAE, R^2 .

Por otro lado, los conceptos de gerencia y gestión provienen del vocablo raízgesto, que se deriva del latín gestos, que se define como una predisposición, gesto o postura corporal. Este, a su vez, proviene del término genere, que se refiere a realizar, ejecutar o realizar gestiones. La voz gerente se deriva de gerens, que se refiere a aquel que realiza o ejecuta algo. Además, la gestión deriva de la palabra latina gestio -onis, que se interpreta como la acción de realizar algo, y sus siglas son gestionar, gestor y administrador. (Corominas y Pascual, 1984; citados en Torres-Valdivieso y Mejía-Villa, 2006).

Encontramos autores como Senlle (2001), Chiavenato (2001), Pacheco y otros en el progreso de la ciencia de la administración. (2002), Chiara y Di-

Virgilio (2017) y Bonicatto (2017), quienes siguen la tradición etimológica de la gestión, intentando ajustar las definiciones de la categoría gestión a la realidad y a las demandas de la sociedad y las entidades.

La gestión es una disciplina científica, técnica y artística. Si se percibe a la ciencia como un conjunto de saberes verificados, estructurados y certificados sistemáticamente, o como un vínculo de entendimientos confirmados sobre los sistemas naturales, sociales y espirituales, es razonable afirmar que la gestión es objeto de investigación en la disciplina científica de la administración (Ropa-Carrión & Alama-Flores, 2022b).

En términos etimológicos, la gestión implica efectuar o llevar a cabo tareas; o dirigir, orientar o dirigir a un conjunto de individuos hacia la consecución de los objetivos de las organizaciones o empresas. En otras palabras, llevar a cabo un conjunto de acciones estratégicas, previamente establecidas con la colaboración de la comunidad de colaboradores, con el fin de alcanzar la visión de las organizaciones (Ropa-Carrión & Alama-Flores, 2022c).

Para sustentar este estudio, se examinó la Teoría clásica de la gestión de Henri Fayol. De acuerdo con Poudyal (2013, citado en AlMulhim, 2023), la teoría definió un esquema esencial para comprender la estructura y gestión de empresas, fundamentado en catorce principios interconectados. Resalta la división del trabajo, que mejora la eficiencia, y la autoridad y responsabilidad, en la que los directivos toman decisiones y asumen los resultados. Además, enfatiza la relevancia de la disciplina, la organización, la cohesión en la dirección estratégica para la transparencia en la estructura, y la remuneración equitativa para preservar la moral.

Asimismo, enfatiza la acumulación de poder, la estructura organizativa, el orden, la equidad, iniciativa y el espíritu de colaboración para un entorno laboral armónico y cooperativo. Además, indicó que esta teoría comprendía cuatro funciones (la planificación, la organización, la dirección, la coordinación y el control), que resultan esenciales para el desempeño eficiente de una institución.

Igualmente, de acuerdo con Luna (2015, citado en Mendoza-Fernández y Moreira-Chóez, 2021a), la gestión administrativa se fundamenta en una serie de procesos sistemáticos que incluyen la planificación, organización, dirección y

supervisión de los recursos y tareas de una entidad. Este método señala la importancia de organizar y emplear los recursos de manera eficiente para alcanzar los objetivos propuestos. En contraposición, Espinoza et al. (2023) argumentan que la administración comprende la implementación de políticas y procesos administrativos que simplifiquen la selección de medidas y la consecución de objetivos institucionales, subrayando la importancia vital de la estructura organizativa y la comunicación interna. Finalmente, García (2020) define la gestión administrativa como el conjunto de acciones orientadas al funcionamiento ordenado de una entidad, subrayando la importancia de la planificación estratégica y la vigilancia constante para ajustarse a las variaciones del ambiente.

Para la variable de gestión administrativa, se tiene a las siguientes dimensiones: organización, dirección y control. Luna (2015, citado en Mendoza-Fernández y Moreira-Chóez, 2021b) detalla que la planificación es el periodo en el que se establecen metas y se determinan las medidas necesarias para alcanzarlas. Este proceso implica prever decisiones y establecer qué, cómo, cuándo y quién llevará a cabo cada labor, posibilitando que las organizaciones se ajusten a las variaciones del entorno y mejoren su eficacia. Como segunda función, la organización se centra en organizar y coordinar los recursos para alcanzar los objetivos establecidos. Esto implica establecer una estructura formal que otorgue tareas y obligaciones, establezca vínculos jerárquicos y mejore la comunicación y aportación entre los miembros del equipo, garantizando un uso eficiente de los recursos disponibles.

En la tercera función del proceso administrativo, es la dirección en donde resalta la relevancia del liderazgo y la administración de personas. En este lugar, se incentiva e impacta a los trabajadores para que desempeñen sus responsabilidades de forma eficaz. Esto incluye tareas como la comunicación, la toma de decisiones y la motivación, siendo esencial que los líderes motiven a su equipo y conserven un entorno laboral en sintonía con las metas de la organización. Finalmente, el control alude a la valoración y modificación del desempeño para confirmar que se alcancen los objetivos propuestos. Este procedimiento implica la evaluación constante de las actividades y los resultados, cotejándolos con los estándares esperados y adoptando medidas

correctivas cuando se detectan desvíos. Un control eficiente posibilita la detección oportuna de problemas y la optimización de procesos, asegurando la consecución de los objetivos estratégicos institucionales.

De igual manera, la Ley General de Recursos Hídricos - Ley N° 29338; en su séptimo artículo establece que el agua es un bien de propiedad pública y que nadie tiene la potestad de modificar, cambiar o influir en las características de dicho bien; sin la autorización explícita de la entidad reguladora administrativa. Además, la legislación indica que su prioridad se atribuye al uso primario. La Autoridad Nacional del Agua (ANA) es la entidad reguladora establecida por Ley con el objetivo de autorizar el uso del recurso hídrico; considerando el orden de prioridad establecido por el Reglamento de la Ley de Recursos Hídricos (Morales, 2018). En conclusión, el agua es el recurso natural más relevante que impulsa nuestra economía; Valderrama et. al. (2020) sostienen que "a medida que la población aumenta y las industrias de manufactura se expanden, las demandas de agua a escala mundial se incrementan" (p.70).

1.5 Operacionalización de variables

Definición conceptual de la variable Modelos Predictivos, son instrumentos estadísticos y matemáticos que examinan patrones de datos pasados y presentes con el objetivo de anticipar comportamientos o resultados futuros. Mediante el uso de algoritmos y métodos como la regresión, la clasificación y el aprendizaje automático, estos modelos detectan vínculos y tendencias ocultas en los datos. Se utilizan extensamente en áreas variadas como finanzas, salud y climatología, contribuyendo a la toma de decisiones basadas en información, dado que su habilidad para prever sucesos futuros los convierte en fundamentales en la organización y mejora de procesos (Parisi et al., 2003). El modelo predictivo presenta las siguientes dimensiones: Rendimiento y eficacia, también se emplea la herramienta Python para simular los escenarios, basándose en la información recolectada de los pozos de agua subterránea del Valle Chancay de Lambayeque.

En términos etimológicos, la gestión implica efectuar o llevar a cabo tareas; o dirigir, orientar o dirigir a un conjunto de individuos hacia la consecución de los objetivos de las organizaciones o empresas. En otras palabras, llevar a cabo un conjunto de acciones estratégicas, previamente establecidas con la

colaboración de la comunidad de colaboradores, con el fin de alcanzar la visión de las organizaciones (Ropa-Carrión & Alama-Flores, 2022c). Igualmente, la definición operacional se realiza mediante cuatro dimensiones: planificación, organización, dirección y supervisión. Por otro lado, las dimensiones se medirán utilizando como instrumento la guía de entrevista.

Tabla 6
Operacionalización de variable Modelo predictivo de aprendizaje máquina

Definición conceptual	Definición operacional	Dimensiones	Indicadores
Se utilizan extensamente en áreas variadas como finanzas, salud y climatología, contribuyendo a la toma de decisiones basadas en información, dado que su habilidad para prever sucesos futuros los convierte en fundamentales en la organización y mejora de procesos (Parisi et al., 2003).	El modelo predictivo tiene como dimensiones: Desempeño y eficiencia, asimismo se usará como herramienta Python para la simulación de los escenarios, en base a la información recopilada de los pozos de aguas subterráneas del Valle Chancay de Lambayeque	Desempeño	Precisión RMSE MAE R ²
		Eficiencia	Tiempo de procesamiento Uso de memoria

Tabla 7
Operacionalización de variable *Gestión Administrativa*

Definición conceptual	Definición operacional	Dimensiones	Indicadores	Escala de medición
Es el conjunto de actividades orientadas al funcionamiento ordenado de una entidad, subrayando la importancia de la planificación estratégica y la supervisión constante para ajustarse a las variaciones del ambiente (García, 2020).	La gestión administrativa se operacionaliza a través de cuatro dimensiones : planificación, organización , dirección y control (Luna, 2015 citado en Mendoza-Fernández y Moreira-Chóez, 2021). Todas las dimensiones se medirán utilizando como instrumentos fichas de registro y guía de entrevista	Planificación	Planificación de metas. Actividades planificadas	Nominal
		Organización	Organización de recursos Organización estructural	
		Dirección	Decisiones orientadas a la eficiencia de las actividades	
		Control	Nivel de control	

II DISEÑO METODOLÓGICO

2.1 Tipo de investigación

La investigación es de tipo Aplicada, en donde se realizará un análisis exhaustivo con la finalidad de dar soluciones a la problemática encontrada.

Asimismo, es de enfoque cuantitativo por el análisis numérico y el uso de estadística descriptiva e inferencial; por otro lado, se tendrá algunos parámetros cualitativos con el sentido de conocer la percepción de la problemática a estudiar, puesto está subyace de la pertinencia asumida desde el paradigma positivista, Ricoy (2006) indica que el “paradigma positivista se califica de cuantitativo, empírico-analítico, racionalista, sistemático gerencial y científico tecnológico”. Por tanto, se plasmaron medios estadísticos de una determinada variable mediante la expresión numérica. (p. 14),

Además, es de diseño no experimental. Según Hernández et al. (2014), este tipo de diseño de investigación se centra en analizar fenómenos tal como ocurren naturalmente, sin intervención o manipulación por parte del investigador. y de corte longitudinal, debido a que se recogerá información histórica de los pozos en referencia a sus monitoreos de la extracción de las aguas subterráneas. Por otro lado, será de alcance descriptivo y explicativo, en donde la creación de un modelo predictivo a menudo implica recopilar y analizar datos existentes para identificar patrones y relaciones, en lugar de controlar activamente las variables de interés, como se haría en un diseño experimental. En este caso, se recogerán y analizarán datos sobre la conductividad hidráulica para desarrollar el modelo predictivo, sin alterar intencionadamente las condiciones del sistema de riego durante la fase de recolección de datos.

2.2 Procedimiento a seguir en la investigación

- Recopilación de datos: Obtención de la data histórica pertinente del acuífero del Valle Chancay-Lambayeque.
- Preprocesamiento de datos: Depuración, integración y normalización de la base de datos (dataset) para eliminar inconsistencias, valores faltantes y registros atípicos.
- Selección del algoritmo

Teniendo en cuenta a modelos que son parte de las redes neuronales recurrentes, destacando aquí las arquitecturas LSTM y GRU y aquellos de arquitectura multinivel para proyectos que son un reto de ingeniería como:

- Entrenamiento del modelo predictivo: Implementación de algoritmos de aprendizaje máquina para predecir el comportamiento futuro del agua subterránea.
- Evaluación de los modelos: División de los datos en conjuntos de entrenamiento y prueba para evaluar el desempeño del modelo mediante métricas de precisión y error.
- Despliegue e inferencia de predicciones: Simulación de escenarios futuros sobre la disponibilidad y comportamiento del recurso hídrico subterráneo.
- Propuesta de gestión: Formulación de recomendaciones para la toma de decisiones orientadas al uso sostenible del agua subterránea en el Valle Chancay-Lambayeque.

2.3 Población

La población estará conformada con la información de variaciones en el nivel estático de agua de 348 pozos registrados desde el año 1996 hasta el año 2023, ubicados en el Valle Chancay de Lambayeque, los cuales son gestionados por la Autoridad Nacional de Agua (ANA). Asimismo.

Muestra

Corresponde a un muestreo no probabilístico por juicio o conveniencia técnica (intencional, ver anexo 2), estructurado en dos niveles interconectados:

- Muestra Espacial (Zonificación Hydrogeológica): Se seleccionó la serie de datos agrupada en cuatro zonas geográficas representativas (Zonas I, II, III y IV) del Valle Chancay-Lambayeque, las cuales concentran la variabilidad de la dinámica hídrica desde sectores de recarga hasta los sectores de descarga agrícola.
- Muestra Temporal (Series de Tiempo y Registro Técnico): Se extrajo un conjunto de registros continuos organizados en frecuencia trimestral. Para el entrenamiento y validación de los modelos predictivos de inteligencia artificial

(LSTM, GRU, CNN-LSTM, KNN-RF, EEMD-SVR-RF), la muestra comprendió: a) Memoria Larga (Lag = 20): Muestra de 20 trimestres históricos (5 años: 2019Q1–2023Q4) para proyecciones de 2 a 4 trimestres en adelante (2024); b) Memoria Corta (Lag = 3): Muestra de 3 trimestres históricos inmediatos (2023Q2–2023Q4) para evaluar la respuesta de inercia y oscilación anual a 4 trimestres (2024Q1–2024Q4).

2.4 Técnicas, instrumentos, equipos, materiales

Las técnicas que se van a utilizar en la investigación son: el análisis documental y la entrevista, y como instrumento fichas de registro y guía de entrevista (Ver anexo 1). Para el análisis documental, se tendrá en cuenta los registros de los pozos subterráneos en base a la información sobre los parámetros del agua subterránea. Asimismo, se entrevistará al jefe de monitoreo encargado del Valle Chancay de Lambayeque, en donde se plasmará interrogantes que permitan analizar la situación actual del uso del agua subterránea del valle mencionado.

Procedimientos: se realizó las coordinaciones correspondientes con el responsable de la Autoridad Nacional del Agua Sede Lambayeque, con la finalidad de obtener el permiso para la recopilación de información y ser entrevistado, asimismo, luego será procesado utilizando herramientas de software como: Python, Excel 2016. Método de análisis de datos: se empleó el método deductivo, el cual parte de la idea general para llegar a las secundarias, por otro lado, con entrevista, direcciona a lo inductivo, es decir, de las ideas secundarias para llegar a la general.

2.5 Aspectos éticos de la investigación

La presente investigación se desarrollará respetando los principios de integridad científica, objetividad y responsabilidad académica. Durante todas las etapas del estudio se garantizará que la información utilizada provenga de fuentes oficiales, confiables y debidamente referenciadas, reconociendo la autoría de los trabajos consultados y evitando cualquier forma de plagio o uso indebido de información.

Asimismo, los datos empleados para el desarrollo del modelo predictivo serán tratados con rigor técnico, asegurando su correcta recopilación,

procesamiento y análisis. Los resultados obtenidos se reportarán de manera transparente, sin alterar, omitir o manipular información que pueda afectar la validez de las conclusiones. De esta forma, se busca garantizar la reproducibilidad y confiabilidad de los hallazgos.

Por otro lado, el uso de herramientas de aprendizaje máquina estará orientado exclusivamente a fines científicos y de apoyo a la gestión sostenible del recurso hídrico. En consecuencia, las predicciones generadas por el modelo serán interpretadas como un instrumento de apoyo para la toma de decisiones y no como una sustitución del criterio técnico de los especialistas responsables de la gestión del agua.

Finalmente, la investigación asume un compromiso con el bienestar colectivo y la sostenibilidad ambiental, considerando que la adecuada administración del agua subterránea constituye un elemento fundamental para el desarrollo económico, social y ecológico del Valle Chancay-Lambayeque. Por ello, los resultados estarán orientados a contribuir al uso responsable y sostenible de este recurso estratégico para las generaciones presentes y futuras.

III RESULTADOS

3.1 Caracterización la situación actual en la gestión de agua de fuente subterránea en el valle Chancay Lambayeque.

Con base en el análisis documental y entrevistas realizadas a personas clave de la Autoridad Nacional del Agua, se presenta a continuación la caracterización de la gestión de agua subterránea. El acuífero está dividido en cuatro zonas, según la tabla siguiente, esta zonificación permite un mejor análisis del acuífero, ya que agrupa pozos que están comprendidos dentro de un área con características similares.

Tabla 8
Zonificación del acuífero

Monitoreo del acuífero del valle Chancay Lambayeque		
Zona	Distritos	
Zona I	Chongoyape	Pucalá
	Pátapo	Tumán
	Chiclayo	Pimentel
Zona II	Eten	Pomalca
	José Leonardo Ortiz	Reque
	La Victoria	San José
	Monsefú	Santa Rosa
Zona III	Ferreñafe	Mesones Muro
	Lambayeque	Picsi
	Pueblo Nuevo	
Zona IV	Mochumi	Pitipo
	Morrope	Túcume


Nota: ANA

Tabla 9
Pozos Monitoreados – Red Piezométrica

Zona	Pozos Monitoreados	% Monitoreados	Pozos No Monitoreados	% No Monitoreados	Total, de Pozos
Zona I	41	38.3%	66	61.7%	107
Zona II	37	35.2%	68	64.8%	105
Zona III	41	64.1%	23	35.9%	64
Zona IV	37	51.4%	35	48.6%	72
Total	156	44.8%	192	55.2%	348

Nota: ANA

Figura 9
Pozos Monitoreados vs No Monitoreados por zona



Nota: ANA

De los 348 pozos registrados, solo el 44.8% está siendo monitoreado, lo que indica una cobertura de monitoreo deficiente. Zona III presenta el mayor


porcentaje de monitoreo (64.1%), mientras que Zona II tiene la menor cobertura (35.2%). Esto evidencia una necesidad urgente de ampliar la red de monitoreo, especialmente en las Zonas I y II.

Tabla 10
 Clasificación de Agua para Riego (Conductividad Eléctrica – CE)

Zona	C2 (Moderado)	C3 (Medio)	C4-C6 (Alto a Excesivo)	Total
Zona I	14 (32.6%)	29 (67.4%)	0	43
Zona II	7 (16.7%)	30 (71.4%)	5 (11.9%)	42
Zona III	3 (8.8%)	29 (85.3%)	2 (5.9%)	34
Zona IV	0	21 (75.0%)	7 (25.0%)	28
Total	24 (16.3%)	109 (74.1%)	14 (9.6%)	147

Nota: ANA

Figura 10
 Clasificación del agua por conductividad eléctrica (CE)



Nota: ANA

La mayoría del agua analizada presenta una conductividad eléctrica media (C3: 74.1%), adecuada para riego con ciertas restricciones. Un 9.6% del total tiene desde alta a excesiva salinidad (C4-C6), lo cual puede ser dañino para los cultivos. Zona IV es la más afectada, con 25% de pozos en esta categoría. Ante


ello, se deben implementar estrategias de manejo de suelos y aguas salinas, especialmente en Zonas II y IV.

Tabla 11
Clasificación del Agua por PH

Zona	Ácida (<7)	Neutra (=7)	Alcalina (>7)	Total
Zona I	7 (15.2%)	1 (2.2%)	38 (82.6%)	46
Zona II	9 (21.4%)	1 (2.4%)	32 (76.2%)	42
Zona III	0	0	35 (100%)	35
Zona IV	0	0	28 (100%)	28
Total	16 (10.6%)	2 (1.3%)	133 (88.1%)	151

Nota: ANA

Figura 11
Clasificación del Agua por PH



Nota: ANA

El 88.1% del agua es alcalina, lo que podría afectar ciertos cultivos sensibles. Las Zonas III y IV tienen exclusivamente aguas alcalinas (100%). El agua ácida es escasa (10.6%), y se encuentra solo en las Zonas I y II. Se sugiere monitorear el impacto en la calidad del suelo y aplicar correcciones si es necesario.

Tabla 12
Tendencia de Conductividad Eléctrica (1999–2023)

Zona	Aumenta	% Aumenta	Disminuye	% Disminuye	Total
Zona I	34	74%	12	26%	46
Zona II	15	35%	28	65%	43
Zona III	26	72%	10	28%	36
Zona IV	19	63%	11	37%	30
Total	94	60.6%	61	39.4%	155


Nota: ANA

El 60.6% de los pozos muestra un aumento en la conductividad eléctrica, lo cual indica una tendencia hacia la salinización del recurso hídrico. Zona I y III son las más críticas, con 74% y 72% respectivamente de pozos en aumento de CE. En contraste, la Zona II muestra una mejora, con 65% de pozos en disminución. Es esencial identificar las causas y aplicar medidas correctivas.

3.2 Diseñar un modelo predictivo de aprendizaje máquina para la gestión del agua de fuente subterránea en el valle Chancay Lambayeque

Para elaborar los modelos predictivos se procedió en base a las diferentes etapas que se encuentran representadas en la siguiente figura:

Figura 12
Etapas aplicadas en la formulación de un modelo predictivo de aprendizaje máquina



3.2.1 Recopilación de datos

Se obtienen los datos históricos existentes desde el año 1996 hasta 2023, que son gestionados inicialmente por el Instituto Nacional de Recursos Naturales (INRENA) y luego por la Autoridad Nacional del Agua (ANA), correspondientes al monitoreo del nivel estático (metros) del agua subterránea del acuífero del valle Chancay Lambayeque.

Tabla 13

Pozos registrados y monitoreados del acuífero del valle Chancay Lambayeque

Nº	ZONA	DISTRITO	POZOS REGISTRADOS POR DISTRITO	POZOS POR ZONA	POZOS MONITOREADOS APTOS	POZOS APTOS	
1	I	Chongoyape	31	107	2	4	
2		Pátapo	19				
3		Pucalá	29				
4		Tumán	28				
5	II	Chiclayo	13	105	1	4	
6		Pimentel	13		2		
7		San José	8				
8		Eten	8				
9		José Leonardo Ortiz	9				
10		La Victoria	12				
11		Reque	7				
12		Monsefú	16				
13		Santa Rosa	1				
14		Pomalca	18		1		
15		Picsi	8				
16		Ferreñafe	16		1		
17		Pueblo Nuevo	3		64		
18		Mesones Muro	6				1
19		Lambayeque	31				5
20	IV	Mórrope	26	72	2	7	
21		Mochumí	20				
22		Túcume	20				
23		Pítipo	6				
TOTAL				348	22	22	

Nota: ANA

También, es importante tener en cuenta en los 348 registros de pozos de data histórica existente sobre el nivel estático del acuífero del valle Chancay Lambayeque, según la data faltante por año.

Tabla 14

Datos faltantes en data histórica del nivel estático desde 1996 hasta 2023 de los pozos del valle Chancay Lambayeque

N°	Año	Nivel estático		Datos faltantes
		Datos	Mes	
1	1996	1	diciembre	241
2	1997	1	julio	237
3	1998	1	diciembre	221
4	1999	3	marzo, octubre, diciembre	660
5	2000	3	mayo, septiembre, diciembre	582
6	2001	3	marzo, septiembre, diciembre	590
7	2002	3	abril, septiembre, diciembre	646
8	2003	3	marzo, septiembre, diciembre	582
9	2004	1	septiembre	84
10	2005	2	abril, octubre	150
11	2006	2	abril, octubre	146
12	2007	2	abril, octubre	172
13	2008	1	abril	96
14	2009	1	noviembre	60
15	2010	2	mayo, septiembre	148
16	2011	1	diciembre	69
17	2012	2	junio, noviembre	202
18	2013	2	abril, noviembre	262
19	2014	2	mayo, octubre	326
20	2015	2	mayo, noviembre	298
21	2016	2	mayo, noviembre	322
22	2017	2	junio, noviembre	306
23	2018	1	junio	205
24	2019	2	junio, octubre	399
25	2020	1	noviembre	204
26	2021	1	junio	210
27	2022	1	junio	211
28	2023	2	junio, noviembre	384
TOTAL		50		8013

Resumen General

Frecuencia: Varía entre 1 y 3 meses

Período: 31/12/1996 a 31/12/2023

Duración (años): 27

Total, de pozos: 348

Total, de registros: 348

Total, de fechas: 50

Columnas principales: ID_Pozo, Propietario, Distrito, Zona, Fecha

Tabla 15
Formato de presentación original de la data histórica de 1996 a 2023, con un total de 348 registros de nivel estático del acuífero del valle Chancay Lambayeque

ID_Pozo	PROPIETARIO	DISTRITO	ZONA	Dic-96	Jul-97	Dic-98	Mar-99		Jun-22	Jun-23	Nov-23
I-68	El Palmo N° 11	Chongoyape	I	2.96	3.44	4.08	4.17				
I-84	Cuculi N° 8	Chongoyape	I			2.58	2.33		2.01	2.13	2.02
.....											
IV-58	MVS	Morrope	IV		3.20	1.40	0.71				

Nota: (ANA, 2023)

3.2.2 Pre procesamiento de los datos
Análisis exploratorio de datos (EDA)

Resumen General

Frecuencia: Varía entre 1 y 3 meses

Período: 31/12/1996 a 31/12/2023

Duración (años): 27

Total, de pozos: 22

Total, de registros: 22

Columnas principales: ID_Pozo, Propietario, Distrito, Zona, Fecha, Nivel_Estatico

Análisis por zona

A continuación, se presenta un análisis descriptivo del nivel estático (en metros) de los veintidós pozos de agua subterránea, considerando las medidas de tendencia central (media, desviación estándar, mínimo, máximo, mediana) y desviación estándar, por cada zona del acuífero del valle Chancay Lambayeque.

Tabla 16
Análisis descriptivo del nivel estático

ZONA	N_Pozos	N_Registros	Porcentaje	Nivel_Promedio	Nivel_Std	Nivel_Min	Nivel_Max	Nivel_Median	Años_Cobertura
I	4	200	18.18%	3.858	1.767	0.42	13.20	3.605	26.92
II	4	200	18.18%	2.482	1.831	0.19	14.66	2.200	26.92
III	7	350	31.82%	2.652	1.634	0.03	8.40	2.300	26.92
IV	7	350	31.82%	1.554	0.747	0.00	4.40	1.600	26.92

Observaciones por zona:

Zona I tiene el nivel promedio más alto y mayor variabilidad.

Zona II tiene la mayor variabilidad (posiblemente más inestable).

Zona III y IV tienen más datos, más estables para modelar.

3.2.2.1 Paso de formato ancho a largo de las fechas

A partir, de la data histórica y considerando la cantidad de datos faltantes por año, se definió un criterio de depuración de la data: data de pozos que tuviera el mínimo de datos faltantes y en lo posible que exista por lo menos un registro en cada año de la serie correspondiente al periodo 1996 hasta 2023, con lo cual solamente se consideró un total de 22 registros de pozos en las cuatro zonas, que cumplen con este requerimiento.

Originalmente el campo fecha estaba en un total de cincuenta columnas, como se puede ver en la siguiente tabla. Luego, utilizando un script en Python, se llevaron todas las fechas a una columna y el nivel estático en una nueva columna, quedando los datos como se puede apreciar en la tabla.

Tabla 17

Formato de presentación original de la data histórica de 1996 a 2023, con un total de 22 registros de nivel estático del acuífero del valle Chancay Lambayeque

ID_Pozo	PROPIETARIO	DISTRITO	ZONA		Abr-02	Set-02	Dic-02		Jun-22	Jun-23	Nov-23
I-39	Pucala 9	Pucala	I		2.25	3.40	3.30		2.88	2.75	3.00
I-9	AVD	Patapo	I		2.30	3.50	NaN		2.90	3.00	3.00
I-11	Tuman 601	Patapo	I		2.10	2.33	NaN		2.88	3.20	3.30
I-67	Tuman 2301	Tuman	I		5.70	5.15	NaN		2.60	8.97	8.81
II-19	FSE	Chiclayo	II		NaN	2.55	3.85		3.06	1.30	1.45
II-32	JLM	Pimentel	II		0.70	2.06	1.28		2.26	1.30	1.40
II-58	CEI	Pimentel	II		0.58	1.49	0.95		3.48	2.10	2.00
II-49	Pomalca N 126	Pomalca	II		0.75	2.17	3.01		6.92	0.70	0.75
III-16	LPVT	Ferreñafe	III		3.20	4.15	2.40		2.88	3.80	4.20
III-8	Fundo LR	Lambayeque	III		2.05	2.25	0.96		2.77	3.35	3.65
III-10	Caserio Y	Lambayeque	III		1.65	2.43	2.94		2.60	2.90	3.40
III-28	Comunidad B	Lambayeque	III		0.80	1.35	1.31		1.38	1.48	2.02
III-36	MRS	Lambayeque	III		0.35	1.54	1.69		1.60	1.28	1.40
III-67	MAP	Lambayeque	III		0.46	2.15	2.75		1.30	0.94	1.20
III-11	RAP	Mesones Muro	III		4.60	4.83	5.41		6.98	7.15	8.20
IV-3	JGL	Mochumi	IV		0.44	1.33	2.27		1.55	1.15	4.40
IV-9	RCB	Mochumi	IV		0.45	1.60	1.55		0.54	0.20	NaN
IV-17	JSS	Tucume	IV		0.64	1.03	1.42		2.42	2.38	3.28

IV-73	NGA	Tucume	IV		0.87	0.90	1.80		1.16	1.42	2.25
IV-86	ARB	Tucume	IV		0.30	1.45	1.90		1.40	1.50	1.90
IV-15	VM	Pitipo	IV		1.16	2.23	1.99		1.50	1.70	2.40

Estas fechas son las de monitoreo realizado por parte de la ANA y que existen en el dataset, que ahora está mejor presentado para su procesamiento.

Tabla 18

Formato de presentación largo de la data histórica de 1996 a 2023, con un total de 1100 registros de nivel estático del acuífero del valle Chancay Lambayeque

N°	ID_Pozo	PROPIETARIO	DISTRITO	ZONA	Fecha	Nivel_Estatico
1	I-39	PUCALA 9	PUCALA	I	Dic-96	3.15
2	I-39	PUCALA 9	PUCALA	I	Jul-97	3.77
3	I-39	PUCALA 9	PUCALA	I	Dic-98	3.52
4	I-39	PUCALA 9	PUCALA	I	Mar-99	2.94
5	I-39	PUCALA 9	PUCALA	I	Oct-99	3.77
6	I-39	PUCALA 9	PUCALA	I	Dic-99	4.36
7	I-39	PUCALA 9	PUCALA	I	May-00	2.95
8	I-39	PUCALA 9	PUCALA	I	Set-00	3.75
9	I-39	PUCALA 9	PUCALA	I	Dic-00	3.65
10	I-39	PUCALA 9	PUCALA	I	Mar-01	2.33
11	I-39	PUCALA 9	PUCALA	I	Set-01	3.80
12	I-39	PUCALA 9	PUCALA	I	Dic-01	4.05
13	I-39	PUCALA 9	PUCALA	I	Abr-02	2.25
14	I-39	PUCALA 9	PUCALA	I	Set-02	3.40
15	I-39	PUCALA 9	PUCALA	I	Dic-02	3.30
16	I-39	PUCALA 9	PUCALA	I	Mar-03	NaN
17	I-39	PUCALA 9	PUCALA	I	Set-03	4.15
18	I-39	PUCALA 9	PUCALA	I	Dic-03	3.70
19	I-39	PUCALA 9	PUCALA	I	Set-04	3.85
20	I-39	PUCALA 9	PUCALA	I	Abr-05	3.22
21	I-39	PUCALA 9	PUCALA	I	Oct-05	3.75
22	I-39	PUCALA 9	PUCALA	I	Abr-06	2.83
23	I-39	PUCALA 9	PUCALA	I	Oct-06	3.61
24	I-39	PUCALA 9	PUCALA	I	Abr-07	4.15
25	I-39	PUCALA 9	PUCALA	I	Oct-07	4.15
26	I-39	PUCALA 9	PUCALA	I	Abr-08	3.10
27	I-39	PUCALA 9	PUCALA	I	Nov-09	3.98
28	I-39	PUCALA 9	PUCALA	I	May-10	3.85
29	I-39	PUCALA 9	PUCALA	I	Set-10	4.40
30	I-39	PUCALA 9	PUCALA	I	Dic-11	7.40
31	I-39	PUCALA 9	PUCALA	I	Jun-12	6.70
32	I-39	PUCALA 9	PUCALA	I	Nov-12	8.00
33	I-39	PUCALA 9	PUCALA	I	Abr-13	3.60
34	I-39	PUCALA 9	PUCALA	I	Nov-13	3.65

35	I-39	PUCALA 9	PUCALA	I	May-14	NaN
36	I-39	PUCALA 9	PUCALA	I	Oct-14	3.65
37	I-39	PUCALA 9	PUCALA	I	May-15	NaN
38	I-39	PUCALA 9	PUCALA	I	Nov-15	3.50
39	I-39	PUCALA 9	PUCALA	I	May-16	2.80
40	I-39	PUCALA 9	PUCALA	I	Nov-16	2.95
41	I-39	PUCALA 9	PUCALA	I	Jun-17	4.10
42	I-39	PUCALA 9	PUCALA	I	Nov-17	3.80
43	I-39	PUCALA 9	PUCALA	I	Jun-18	3.62
44	I-39	PUCALA 9	PUCALA	I	Jun-19	3.81
45	I-39	PUCALA 9	PUCALA	I	Oct-19	2.20
46	I-39	PUCALA 9	PUCALA	I	Nov-20	2.00
47	I-39	PUCALA 9	PUCALA	I	Jun-21	2.75
48	I-39	PUCALA 9	PUCALA	I	Jun-22	2.88
49	I-39	PUCALA 9	PUCALA	I	Jun-23	2.75
50	I-39	PUCALA 9	PUCALA	I	Nov-23	3.00
.....						
.....						
1051	IV-15	VM	PITIPO	IV	Dic-96	2.84
1052	IV-15	VM	PITIPO	IV	Jul-97	2.95
1053	IV-15	VM	PITIPO	IV	Dic-98	1.40
1054	IV-15	VM	PITIPO	IV	Mar-99	1.70
1055	IV-15	VM	PITIPO	IV	Oct-99	2.49
1056	IV-15	VM	PITIPO	IV	Dic-99	1.57
1057	IV-15	VM	PITIPO	IV	May-00	1.70
1058	IV-15	VM	PITIPO	IV	Set-00	1.80
1059	IV-15	VM	PITIPO	IV	Dic-00	2.40
1060	IV-15	VM	PITIPO	IV	Mar-01	1.37
1061	IV-15	VM	PITIPO	IV	Set-01	2.51
1062	IV-15	VM	PITIPO	IV	Dic-01	1.45
1063	IV-15	VM	PITIPO	IV	Abr-02	1.16
1064	IV-15	VM	PITIPO	IV	Set-02	2.23
1065	IV-15	VM	PITIPO	IV	Dic-02	1.99
1066	IV-15	VM	PITIPO	IV	Mar-03	0.70
1067	IV-15	VM	PITIPO	IV	Set-03	2.87
1068	IV-15	VM	PITIPO	IV	Dic-03	2.90
1069	IV-15	VM	PITIPO	IV	Set-04	2.14
1070	IV-15	VM	PITIPO	IV	Abr-05	0.95
1071	IV-15	VM	PITIPO	IV	Oct-05	2.20
1072	IV-15	VM	PITIPO	IV	Abr-06	0.58
1073	IV-15	VM	PITIPO	IV	Oct-06	1.85
1074	IV-15	VM	PITIPO	IV	Abr-07	0.82
1075	IV-15	VM	PITIPO	IV	Oct-07	2.11
1076	IV-15	VM	PITIPO	IV	Abr-08	0.50
1077	IV-15	VM	PITIPO	IV	Nov-09	2.28
1078	IV-15	VM	PITIPO	IV	May-10	1.05
1079	IV-15	VM	PITIPO	IV	Set-10	1.73
1080	IV-15	VM	PITIPO	IV	Dic-11	2.55

1081	IV-15	VM	PITIPO	IV	Jun-12	2.18
1082	IV-15	VM	PITIPO	IV	Nov-12	2.20
1083	IV-15	VM	PITIPO	IV	Abr-13	2.17
1084	IV-15	VM	PITIPO	IV	Nov-13	2.19
1085	IV-15	VM	PITIPO	IV	May-14	1.20
1086	IV-15	VM	PITIPO	IV	Oct-14	2.22
1087	IV-15	VM	PITIPO	IV	May-15	1.70
1088	IV-15	VM	PITIPO	IV	Nov-15	2.26
1089	IV-15	VM	PITIPO	IV	May-16	NaN
1090	IV-15	VM	PITIPO	IV	Nov-16	2.44
1091	IV-15	VM	PITIPO	IV	Jun-17	1.34
1092	IV-15	VM	PITIPO	IV	Nov-17	1.40
1093	IV-15	VM	PITIPO	IV	Jun-18	1.32
1094	IV-15	VM	PITIPO	IV	Jun-19	1.55
1095	IV-15	VM	PITIPO	IV	Oct-19	2.24
1096	IV-15	VM	PITIPO	IV	Nov-20	2.32
1097	IV-15	VM	PITIPO	IV	Jun-21	1.45
1098	IV-15	VM	PITIPO	IV	Jun-22	1.50
1099	IV-15	VM	PITIPO	IV	Jun-23	1.70
1100	IV-15	VM	PITIPO	IV	Nov-23	2.40

3.2.2.2 Tratamiento de valores faltantes

Dado que los algoritmos requieren secuencias continuas de datos. En la data a utilizar, existe en la data depurada una cantidad de datos faltantes equivalente a cuarenta, en este apartado se realizará el tratamiento de estos valores. En la siguiente table se pueden distinguir la distribución en el tiempo de los valores faltantes (NaN).

Tabla 19

Datos faltantes en data histórica apta del nivel estático desde 1996 hasta 2023 de los pozos del valle Chancay Lambayeque

N°	Año	Nivel estático		Datos faltantes
		Datos	Mes	
1	1996	1	diciembre	0
2	1997	1	julio	0
3	1998	1	diciembre	0
4	1999	3	marzo, octubre, diciembre	0
5	2000	3	mayo, septiembre, diciembre	1

6	2001	3	marzo, septiembre, diciembre	0
7	2002	3	abril, septiembre, diciembre	4
8	2003	3	marzo, septiembre, diciembre	2
9	2004	1	septiembre	0
10	2005	2	abril, octubre	4
11	2006	2	abril, octubre	0
12	2007	2	abril, octubre	4
13	2008	1	abril	1
14	2009	1	noviembre	1
15	2010	2	mayo, septiembre	0
16	2011	1	diciembre	1
17	2012	2	junio, noviembre	1
18	2013	2	abril, noviembre	6
19	2014	2	mayo, octubre	6
20	2015	2	mayo, noviembre	1
21	2016	2	mayo, noviembre	4
22	2017	2	junio, noviembre	2
23	2018	1	junio	0
24	2019	2	junio, octubre	1
25	2020	1	noviembre	0
26	2021	1	junio	0
27	2022	1	junio	0
28	2023	2	junio, noviembre	1
TOTAL		50		40

Los datos faltantes identificados, fueron completados mediante imputación con el método de interpolación lineal

Ejemplo de este proceso con un dato nulo

El valor NaN que se aprecia en la siguiente tabla se obtiene mediante el promedio de los valores del nivel estático antes y después.

Tabla 20
Ejemplo para determinar un valor faltante

N°	ID_Pozo	PROPIETARIO	DISTRITO	ZONA	Fecha	Nivel_Estatico
....						
15	I-39	PUCALA 9	PUCALA	I	1/12/2002	3.30
16	I-39	PUCALA 9	PUCALA	I	1/03/2003	NaN
17	I-39	PUCALA 9	PUCALA	I	1/09/2003	4.15
....						

$$NE = \frac{3.30 + 4.15}{2} = 3.725$$

3.2.2.3 Remuestreo temporal

En las mediciones originales del nivel estático en el ámbito del Valle Chancay-Lambayeque (1,100 registros primarios), se observa que los intervalos de tiempo no son regulares (mensual, bimestral, trimestral) sino que presentan una marcada asincronía en las fechas de monitoreo, brechas de datos en pozos específicos y discontinuidad en la frecuencia de muestreo de campo.

Para transformar estas observaciones heterogéneas en una base de datos estructurada, completa y balanceada de 2,398 registros trimestrales, se diseñó e implementó un marco de procesamiento secuencial basado en Remuestreo (Resampling), Interpolación Temporal por Splines e Imputación Espacial Ponderada.

3.2.2.3.1 Muestreo temporal uniforme e interpolación temporal

Para convertir la serie histórica irregular a una rejilla temporal discreta de paso uniforme $\Delta t = 1$ trimestre (frecuencia trimestral Q1, Q2, Q3, Q4), se aplicó un protocolo de regularización de series de tiempo.

- Mapeo a estándar trimestral: Cada observación $y(t_i)$ tomada en la fecha de campo t_i fue mapeada al trimestre discreto correspondiente Q_k .
- Interpolación temporal por splines cúbicos: Para reconstruir valores faltantes breves en la serie individual de un pozo p , se utilizó una función de interpolación por spline cúbico suavizado, la cual preserva la continuidad de la primera y segunda derivada del nivel freático:

$$y_p(t) = a_i(t - t_i)^3 + b_i(t - t_i)^2 + c_i(t - t_i) + d_i, \quad \forall t \in [t_i, t_{i+1}]$$

Donde a_i , b_i , c_i , d_i son los coeficientes polinómicos calculados asegurando suavidad local en las fronteras entre intervalos adyacentes t_i y t_{i+1} .

En casos de discontinuidades puntuales simples de corta duración, la interpolación se simplifica a la forma lineal ponderada por el intervalo de tiempo:

$$y_p(t) = (1 - \lambda) \cdot y_p(t_a) + \lambda \cdot y_p(t_b)$$

Donde t_a y t_b representan los trimestres observados límites más cercanos al periodo t , y $\lambda = \frac{t - t_a}{t_b - t_a}$ $\lambda \in [0,1]$ determina la distancia temporal relativa.

3.2.2.3.2 Imputación espacial ponderada por subcuencas y vecindad

Para resolver los periodos con brechas prolongadas donde no existían registros anteriores o posteriores para un pozo en particular, se aprovechó la autocorrelación espacial existente entre puntos de monitoreo de la misma zona hidrográfica:

Imputación por Vecinos más cercanos (KNN / Distance-Based Imputation): Asumiendo homogeneidad en la dinámica hidrodinámica del acuífero por zona, el valor faltante del nivel estático en el pozo p durante el trimestre t ($\hat{y}_{p,t}$) fue estimado mediante la combinación ponderada de los K pozos de control adyacentes pertenecientes a la misma zona geográfica Z_k

$$\hat{y}_{p,t} = \frac{\sum_{j \in Z_k} w_{p,j} \cdot y_{j,t}}{\sum_{j \in Z_k} w_{p,j}}$$

Donde $y_{j,t}$ es el nivel medido en el pozo vecino j en el trimestre t , y el factor de ponderación espacial $w_{p,j}$ corresponde al inverso de la distancia euclidiana geodésica $d(p,j)$ entre las coordenadas del pozo p y el pozo j :

$$w_{p,j} = \frac{1}{d(p,j)^2}$$

3.2.2.3.3 Matriz espacio-temporal balanceada (N = 2,398 registros)

Como resultado de la combinación de la regularización por interpolación temporal y la imputación por correlación espacial, el dataset original pasó de 1,100 observaciones dispares a una matriz rectangular continua y balanceada:

$$Total\ de\ registros = (N_{pozos}) (T_{trimestres}) = 2,398\ datos$$

Esta etapa de preprocesamiento eliminó la presencia de valores nulos (NaNs) y garantizó secuencias temporales completas y equidistantes, requisito estructural indispensable para el correcto aprendizaje de las arquitecturas recurrentes de redes neuronales (LSTM, GRU y CNN-LSTM).

Tabla 21
Resumen del proceso de remuestreo

Etapa	Técnica Aplicada	Fundamento Matemático	Propósito
1. Dataset Inicial	Muestreo irregular de campo	1,100 registros	Datos primarios desestructurados.
2. Regularización Temporal	Interpolación por Splines Cúbicos / Lineal	$y_p(t) = (1 - \lambda)y_p(t_a) + \lambda y_p(t_b)$	Proyectar observaciones a intervalos trimestrales uniformes (Q1-Q4).
3. Imputación Espacial	KNN-Spatial / Ponderación Geográfica	$\hat{y}_{p,t} = \frac{\sum w_{p,j} y_{j,t}}{\sum w_{p,j}}$	Reconstruir brechas largas usando la autocorrelación de pozos adyacentes de la zona.
4. Dataset Final	Matriz Espacio-Temporal Continua	N = 2,398 registros completos	Base de datos uniforme balanceada para entrenamiento profundo.

Tabla 22

Formato de presentación largo de la data histórica trimestral de 1996 a 2023, con un total de 2398 registros de nivel estático del acuífero del valle Chancay Lambayeque

N°	ID_Pozo	PROPIETARIO	DISTRITO	ZONA	Fecha	Nivel_Estatico
1	I-39	PUCALA 9	PUCALA	I	31/12/1996	3.15
2	I-39	PUCALA 9	PUCALA	I	31/03/1997	3.356666667
3	I-39	PUCALA 9	PUCALA	I	30/06/1997	3.563333333
4	I-39	PUCALA 9	PUCALA	I	30/09/1997	3.77
5	I-39	PUCALA 9	PUCALA	I	31/12/1997	3.72
6	I-39	PUCALA 9	PUCALA	I	31/03/1998	3.67
7	I-39	PUCALA 9	PUCALA	I	30/06/1998	3.62
8	I-39	PUCALA 9	PUCALA	I	30/09/1998	3.57
9	I-39	PUCALA 9	PUCALA	I	31/12/1998	3.52
10	I-39	PUCALA 9	PUCALA	I	31/03/1999	2.94
11	I-39	PUCALA 9	PUCALA	I	30/06/1999	3.315
12	I-39	PUCALA 9	PUCALA	I	30/09/1999	3.69
13	I-39	PUCALA 9	PUCALA	I	31/12/1999	4.065
14	I-39	PUCALA 9	PUCALA	I	31/03/2000	3.5075
15	I-39	PUCALA 9	PUCALA	I	30/06/2000	2.95
16	I-39	PUCALA 9	PUCALA	I	30/09/2000	3.75
17	I-39	PUCALA 9	PUCALA	I	31/12/2000	3.65
18	I-39	PUCALA 9	PUCALA	I	31/03/2001	2.33
19	I-39	PUCALA 9	PUCALA	I	30/06/2001	3.065
20	I-39	PUCALA 9	PUCALA	I	30/09/2001	3.80
21	I-39	PUCALA 9	PUCALA	I	31/12/2001	4.05
22	I-39	PUCALA 9	PUCALA	I	31/03/2002	3.15
23	I-39	PUCALA 9	PUCALA	I	30/06/2002	2.25
24	I-39	PUCALA 9	PUCALA	I	30/09/2002	3.40
25	I-39	PUCALA 9	PUCALA	I	31/12/2002	3.30
26	I-39	PUCALA 9	PUCALA	I	31/03/2003	3.725
27	I-39	PUCALA 9	PUCALA	I	30/06/2003	3.9375
28	I-39	PUCALA 9	PUCALA	I	30/09/2003	4.15
29	I-39	PUCALA 9	PUCALA	I	31/12/2003	3.70
30	I-39	PUCALA 9	PUCALA	I	31/03/2004	3.75
31	I-39	PUCALA 9	PUCALA	I	30/06/2004	3.80
32	I-39	PUCALA 9	PUCALA	I	30/09/2004	3.85
33	I-39	PUCALA 9	PUCALA	I	31/12/2004	3.64
34	I-39	PUCALA 9	PUCALA	I	31/03/2005	3.43
35	I-39	PUCALA 9	PUCALA	I	30/06/2005	3.22
36	I-39	PUCALA 9	PUCALA	I	30/09/2005	3.485
37	I-39	PUCALA 9	PUCALA	I	31/12/2005	3.75
38	I-39	PUCALA 9	PUCALA	I	31/03/2006	3.29
39	I-39	PUCALA 9	PUCALA	I	30/06/2006	2.83
40	I-39	PUCALA 9	PUCALA	I	30/09/2006	3.22
41	I-39	PUCALA 9	PUCALA	I	31/12/2006	3.61
42	I-39	PUCALA 9	PUCALA	I	31/03/2007	3.88
43	I-39	PUCALA 9	PUCALA	I	30/06/2007	4.15
44	I-39	PUCALA 9	PUCALA	I	30/09/2007	4.15

45	I-39	PUCALA 9	PUCALA	I	31/12/2007	4.15
46	I-39	PUCALA 9	PUCALA	I	31/03/2008	3.625
47	I-39	PUCALA 9	PUCALA	I	30/06/2008	3.10
48	I-39	PUCALA 9	PUCALA	I	30/09/2008	3.246666667
49	I-39	PUCALA 9	PUCALA	I	31/12/2008	3.393333333
50	I-39	PUCALA 9	PUCALA	I	31/03/2009	3.54
51	I-39	PUCALA 9	PUCALA	I	30/06/2009	3.686666667
52	I-39	PUCALA 9	PUCALA	I	30/09/2009	3.833333333
53	I-39	PUCALA 9	PUCALA	I	31/12/2009	3.98
54	I-39	PUCALA 9	PUCALA	I	31/03/2010	3.915
55	I-39	PUCALA 9	PUCALA	I	30/06/2010	3.85
56	I-39	PUCALA 9	PUCALA	I	30/09/2010	4.40
57	I-39	PUCALA 9	PUCALA	I	31/12/2010	5.00
58	I-39	PUCALA 9	PUCALA	I	31/03/2011	5.60
59	I-39	PUCALA 9	PUCALA	I	30/06/2011	6.20
60	I-39	PUCALA 9	PUCALA	I	30/09/2011	6.80
61	I-39	PUCALA 9	PUCALA	I	31/12/2011	7.40
62	I-39	PUCALA 9	PUCALA	I	31/03/2012	7.05
63	I-39	PUCALA 9	PUCALA	I	30/06/2012	6.70
64	I-39	PUCALA 9	PUCALA	I	30/09/2012	7.35
65	I-39	PUCALA 9	PUCALA	I	31/12/2012	8.00
66	I-39	PUCALA 9	PUCALA	I	31/03/2013	5.80
67	I-39	PUCALA 9	PUCALA	I	30/06/2013	3.60
68	I-39	PUCALA 9	PUCALA	I	30/09/2013	3.625
69	I-39	PUCALA 9	PUCALA	I	31/12/2013	3.65
70	I-39	PUCALA 9	PUCALA	I	31/03/2014	3.65
71	I-39	PUCALA 9	PUCALA	I	30/06/2014	3.65
72	I-39	PUCALA 9	PUCALA	I	30/09/2014	3.65
73	I-39	PUCALA 9	PUCALA	I	31/12/2014	3.65
74	I-39	PUCALA 9	PUCALA	I	31/03/2015	3.6125
75	I-39	PUCALA 9	PUCALA	I	30/06/2015	3.575
76	I-39	PUCALA 9	PUCALA	I	30/09/2015	3.5375
77	I-39	PUCALA 9	PUCALA	I	31/12/2015	3.50
78	I-39	PUCALA 9	PUCALA	I	31/03/2016	3.15
79	I-39	PUCALA 9	PUCALA	I	30/06/2016	2.80
80	I-39	PUCALA 9	PUCALA	I	30/09/2016	2.875
81	I-39	PUCALA 9	PUCALA	I	31/12/2016	2.95
82	I-39	PUCALA 9	PUCALA	I	31/03/2017	3.525
83	I-39	PUCALA 9	PUCALA	I	30/06/2017	4.10
84	I-39	PUCALA 9	PUCALA	I	30/09/2017	3.95
85	I-39	PUCALA 9	PUCALA	I	31/12/2017	3.80
86	I-39	PUCALA 9	PUCALA	I	31/03/2018	3.71
87	I-39	PUCALA 9	PUCALA	I	30/06/2018	3.62
88	I-39	PUCALA 9	PUCALA	I	30/09/2018	3.6675
89	I-39	PUCALA 9	PUCALA	I	31/12/2018	3.715
90	I-39	PUCALA 9	PUCALA	I	31/03/2019	3.7625
91	I-39	PUCALA 9	PUCALA	I	30/06/2019	3.81
92	I-39	PUCALA 9	PUCALA	I	30/09/2019	3.005

93	I-39	PUCALA 9	PUCALA	I	31/12/2019	2.20
94	I-39	PUCALA 9	PUCALA	I	31/03/2020	2.15
95	I-39	PUCALA 9	PUCALA	I	30/06/2020	2.10
96	I-39	PUCALA 9	PUCALA	I	30/09/2020	2.05
97	I-39	PUCALA 9	PUCALA	I	31/12/2020	2.00
98	I-39	PUCALA 9	PUCALA	I	31/03/2021	2.375
99	I-39	PUCALA 9	PUCALA	I	30/06/2021	2.75
100	I-39	PUCALA 9	PUCALA	I	30/09/2021	2.7825
101	I-39	PUCALA 9	PUCALA	I	31/12/2021	2.815
102	I-39	PUCALA 9	PUCALA	I	31/03/2022	2.8475
103	I-39	PUCALA 9	PUCALA	I	30/06/2022	2.88
104	I-39	PUCALA 9	PUCALA	I	30/09/2022	2.8475
105	I-39	PUCALA 9	PUCALA	I	31/12/2022	2.815
106	I-39	PUCALA 9	PUCALA	I	31/03/2023	2.7825
107	I-39	PUCALA 9	PUCALA	I	30/06/2023	2.75
108	I-39	PUCALA 9	PUCALA	I	30/09/2023	2.875
109	I-39	PUCALA 9	PUCALA	I	31/12/2023	3.00
.....						
.....						
2290	IV-15	VM	PITIPO	IV	31/12/1996	2.84
2291	IV-15	VM	PITIPO	IV	31/03/1997	2.876666667
2292	IV-15	VM	PITIPO	IV	30/06/1997	2.913333333
2293	IV-15	VM	PITIPO	IV	30/09/1997	2.95
2294	IV-15	VM	PITIPO	IV	31/12/1997	2.64
2295	IV-15	VM	PITIPO	IV	31/03/1998	2.33
2296	IV-15	VM	PITIPO	IV	30/06/1998	2.02
2297	IV-15	VM	PITIPO	IV	30/09/1998	1.71
2298	IV-15	VM	PITIPO	IV	31/12/1998	1.40
2299	IV-15	VM	PITIPO	IV	31/03/1999	1.70
2300	IV-15	VM	PITIPO	IV	30/06/1999	1.81
2301	IV-15	VM	PITIPO	IV	30/09/1999	1.92
2302	IV-15	VM	PITIPO	IV	31/12/1999	2.03
2303	IV-15	VM	PITIPO	IV	31/03/2000	1.865
2304	IV-15	VM	PITIPO	IV	30/06/2000	1.70
2305	IV-15	VM	PITIPO	IV	30/09/2000	1.80
2306	IV-15	VM	PITIPO	IV	31/12/2000	2.40
2307	IV-15	VM	PITIPO	IV	31/03/2001	1.37
2308	IV-15	VM	PITIPO	IV	30/06/2001	1.94
2309	IV-15	VM	PITIPO	IV	30/09/2001	2.51
2310	IV-15	VM	PITIPO	IV	31/12/2001	1.45
2311	IV-15	VM	PITIPO	IV	31/03/2002	1.305
2312	IV-15	VM	PITIPO	IV	30/06/2002	1.16
2313	IV-15	VM	PITIPO	IV	30/09/2002	2.23
2314	IV-15	VM	PITIPO	IV	31/12/2002	1.99
2315	IV-15	VM	PITIPO	IV	31/03/2003	0.70
2316	IV-15	VM	PITIPO	IV	30/06/2003	1.785
2317	IV-15	VM	PITIPO	IV	30/09/2003	2.87
2318	IV-15	VM	PITIPO	IV	31/12/2003	2.90


2319	IV-15	VM	PITIPO	IV	31/03/2004	2.646666667
2320	IV-15	VM	PITIPO	IV	30/06/2004	2.393333333
2321	IV-15	VM	PITIPO	IV	30/09/2004	2.14
2322	IV-15	VM	PITIPO	IV	31/12/2004	1.743333333
2323	IV-15	VM	PITIPO	IV	31/03/2005	1.346666667
2324	IV-15	VM	PITIPO	IV	30/06/2005	0.95
2325	IV-15	VM	PITIPO	IV	30/09/2005	1.575
2326	IV-15	VM	PITIPO	IV	31/12/2005	2.20
2327	IV-15	VM	PITIPO	IV	31/03/2006	1.39
2328	IV-15	VM	PITIPO	IV	30/06/2006	0.58
2329	IV-15	VM	PITIPO	IV	30/09/2006	1.215
2330	IV-15	VM	PITIPO	IV	31/12/2006	1.85
2331	IV-15	VM	PITIPO	IV	31/03/2007	1.335
2332	IV-15	VM	PITIPO	IV	30/06/2007	0.82
2333	IV-15	VM	PITIPO	IV	30/09/2007	1.465
2334	IV-15	VM	PITIPO	IV	31/12/2007	2.11
2335	IV-15	VM	PITIPO	IV	31/03/2008	1.305
2336	IV-15	VM	PITIPO	IV	30/06/2008	0.50
2337	IV-15	VM	PITIPO	IV	30/09/2008	0.796666667
2338	IV-15	VM	PITIPO	IV	31/12/2008	1.093333333
2339	IV-15	VM	PITIPO	IV	31/03/2009	1.39
2340	IV-15	VM	PITIPO	IV	30/06/2009	1.686666667
2341	IV-15	VM	PITIPO	IV	30/09/2009	1.983333333
2342	IV-15	VM	PITIPO	IV	31/12/2009	2.28
2343	IV-15	VM	PITIPO	IV	31/03/2010	1.665
2344	IV-15	VM	PITIPO	IV	30/06/2010	1.05
2345	IV-15	VM	PITIPO	IV	30/09/2010	1.73
2346	IV-15	VM	PITIPO	IV	31/12/2010	1.894
2347	IV-15	VM	PITIPO	IV	31/03/2011	2.058
2348	IV-15	VM	PITIPO	IV	30/06/2011	2.222
2349	IV-15	VM	PITIPO	IV	30/09/2011	2.386
2350	IV-15	VM	PITIPO	IV	31/12/2011	2.55
2351	IV-15	VM	PITIPO	IV	31/03/2012	2.365
2352	IV-15	VM	PITIPO	IV	30/06/2012	2.18
2353	IV-15	VM	PITIPO	IV	30/09/2012	2.19
2354	IV-15	VM	PITIPO	IV	31/12/2012	2.20
2355	IV-15	VM	PITIPO	IV	31/03/2013	2.185
2356	IV-15	VM	PITIPO	IV	30/06/2013	2.17
2357	IV-15	VM	PITIPO	IV	30/09/2013	2.18
2358	IV-15	VM	PITIPO	IV	31/12/2013	2.19
2359	IV-15	VM	PITIPO	IV	31/03/2014	1.695
2360	IV-15	VM	PITIPO	IV	30/06/2014	1.20
2361	IV-15	VM	PITIPO	IV	30/09/2014	1.71
2362	IV-15	VM	PITIPO	IV	31/12/2014	2.22
2363	IV-15	VM	PITIPO	IV	31/03/2015	1.96
2364	IV-15	VM	PITIPO	IV	30/06/2015	1.70
2365	IV-15	VM	PITIPO	IV	30/09/2015	1.98
2366	IV-15	VM	PITIPO	IV	31/12/2015	2.26

2367	IV-15	VM	PITIPO	IV	31/03/2016	2.305
2368	IV-15	VM	PITIPO	IV	30/06/2016	2.35
2369	IV-15	VM	PITIPO	IV	30/09/2016	2.395
2370	IV-15	VM	PITIPO	IV	31/12/2016	2.44
2371	IV-15	VM	PITIPO	IV	31/03/2017	1.89
2372	IV-15	VM	PITIPO	IV	30/06/2017	1.34
2373	IV-15	VM	PITIPO	IV	30/09/2017	1.37
2374	IV-15	VM	PITIPO	IV	31/12/2017	1.40
2375	IV-15	VM	PITIPO	IV	31/03/2018	1.36
2376	IV-15	VM	PITIPO	IV	30/06/2018	1.32
2377	IV-15	VM	PITIPO	IV	30/09/2018	1.3775
2378	IV-15	VM	PITIPO	IV	31/12/2018	1.435
2379	IV-15	VM	PITIPO	IV	31/03/2019	1.4925
2380	IV-15	VM	PITIPO	IV	30/06/2019	1.55
2381	IV-15	VM	PITIPO	IV	30/09/2019	1.895
2382	IV-15	VM	PITIPO	IV	31/12/2019	2.24
2383	IV-15	VM	PITIPO	IV	31/03/2020	2.26
2384	IV-15	VM	PITIPO	IV	30/06/2020	2.28
2385	IV-15	VM	PITIPO	IV	30/09/2020	2.30
2386	IV-15	VM	PITIPO	IV	31/12/2020	2.32
2387	IV-15	VM	PITIPO	IV	31/03/2021	1.885
2388	IV-15	VM	PITIPO	IV	30/06/2021	1.45
2389	IV-15	VM	PITIPO	IV	30/09/2021	1.4625
2390	IV-15	VM	PITIPO	IV	31/12/2021	1.475
2391	IV-15	VM	PITIPO	IV	31/03/2022	1.4875
2392	IV-15	VM	PITIPO	IV	30/06/2022	1.50
2393	IV-15	VM	PITIPO	IV	30/09/2022	1.55
2394	IV-15	VM	PITIPO	IV	31/12/2022	1.60
2395	IV-15	VM	PITIPO	IV	31/03/2023	1.65
2396	IV-15	VM	PITIPO	IV	30/06/2023	1.70
2397	IV-15	VM	PITIPO	IV	30/09/2023	2.05
2398	IV-15	VM	PITIPO	IV	31/12/2023	2.40

Con los datos ya listos, se procede a realizar un análisis gráfico de la data obtenida, este análisis se realiza por zonas y distritos del valle Chancay Lambayeque.

En la figura se observa en el caso de estos pozos (I-11 e I-9), una dinámica del nivel freático, caracterizada por la presencia de eventos hidrológicos extremos episódicos (picos de recarga en el año 2000 y 2015) superpuestos a una tendencia de fondo estable a largo plazo, donde las variaciones se han atenuado hacia un nivel promedio constante de ~3.2 m hacia el final de la serie histórica (2024).


Figura 13
Tendencia de pozos de la zona Pátapo



Nota: data histórica de ANA

La dinámica del pozo I-39 en Pucalá se caracteriza por tres fases bien diferenciadas: un periodo base de fluctuación regular (años 1996–2010), una anomalía de recarga extraordinaria que duplicó el nivel estático habitual (años 2011–2013), y un ciclo posterior de abatimiento con recuperación reciente hacia los 3.0 m, lo que confirma la capacidad de respuesta y resiliencia del acuífero en esta zona frente a ciclos hidrológicos secos y húmedos.


Figura 14
Tendencia de pozos de la zona Pucala



Nota: data histórica de ANA

A diferencia de otras zonas del valle, la Zona Tumán (Pozo I-67) exhibe un régimen altamente dinámico con marcados ciclos multianuales de recarga y descarga. Se destacan tres grandes picos históricos de recarga que bordean los 9.0 m a 10.0 m (1998, 2006 y 2012), seguidos por una fase de sequía/depresión entre 2018 y 2022, y una reactivación reactiva abrupta en el bienio 2023–2024 que retorna los niveles estáticos a su cota máxima histórica.


Figura 15
Tendencia de pozos de la zona Tumán



Nota: data histórica de ANA

La Zona Chiclayo (Pozo II-19) presenta una dinámica freática somera altamente sensible a periodos secos y de explotación, caracterizada por descensos marcados en 2006 (0.2 m) y 2010 (1.0 m). Aunque el sistema mostró una sólida capacidad de recuperación y estabilidad continua entre 2012 y 2021 (manteniéndose por encima de los 2.7 m), el reciente abatimiento registrado en el periodo 2022–2024 sugiere la necesidad de monitoreo continuo ante posibles ciclos de déficit o mayor extracción en la zona.


Figura 16
Tendencia de pozos de la zona Chiclayo



Nota: data histórica de ANA

La Zona Pimentel se caracteriza por un comportamiento freático somero y estable a largo plazo (0.5 m – 3.0 m), interrumpido por un evento anómalo de recarga masiva en 2003 que afectó principalmente al pozo II-32 (14.5 m). En el quinquenio reciente (2020–2024), ambos pozos han mostrado una dinámica desfasada pero convergente, estabilizándose hacia el final del periodo entre los 1.4 m y 2.0 m de Nivel Estático.


Figura 17
Tendencia de pozos de la zona Pimentel



Nota: data histórica de ANA

La Zona Pomalca (Pozo II-49) presenta un comportamiento freático altamente variable con fluctuaciones de gran amplitud (entre 0.6 m y 9.3 m). Destaca el alcance de su máximo nivel histórico durante el bienio 2020–2021 (9.3 m), seguido de un rápido abatimiento hacia el cierre de la serie (2023–2024), situando la freática en niveles críticos someros similares a los registrados a inicios de la década del 2000.


Figura 18
Tendencia de pozos de la zona Pomalca



Nota: data histórica de ANA

La Zona Ferreñafe (Pozo III-16) mantiene un régimen freático predominantemente estable (3.0 m – 4.8 m) con buena capacidad de recarga estacional, aunque es susceptible a eventos puntuales de abatimiento severo (como los registrados en 2003, 2010 y 2017 con niveles inferiores a 1.5 m). La tendencia observada en el trienio reciente (2022–2024) confirma una recuperación activa hacia los niveles promedio históricos (4.2 m).


Figura 19
Tendencia de pozos de la zona Ferreñafe



Nota: data histórica de ANA

La Zona Lambayeque presenta una red freática altamente acoplada y somera (predominantemente entre 0.5 m y 3.5 m), caracterizada por respuestas colectivas frente a eventos climáticos e hidrológicos. Destaca el máximo histórico registrado en el bienio 2011–2012 (hasta 4.9 m en el pozo III-8) y una sólida reactivación de recarga al cierre del periodo 2023–2024, recuperando niveles freáticos elevados en toda la batería de pozos monitoreados.


Figura 20
Tendencia de pozos de la zona Lambayeque



Nota: data histórica de ANA

La Zona Mesones Muro (Pozo III-11) exhibe un comportamiento de recarga continua con tendencia secular ascendente, habiendo elevado sustancialmente su nivel estático desde la franja de 2.3 m – 5.0 m (1996–2000) hasta valores superiores a los 8.0 m en la actualidad. A pesar de haber experimentado un abatimiento crítico puntual en 2010 (1.35 m), el acuífero mostró una alta capacidad de resiliencia, consolidando en el periodo 2020–2024 sus niveles freáticos más profundos y estables de todo el registro histórico (7.0 m – 8.4 m).


Figura 21
Tendencia de pozos de la zona Mesones Muro



Nota: data histórica de ANA

La Zona Mochumí exhibe históricamente un comportamiento freático somero y dinámico (0.5 m – 2.5 m), pero el trienio reciente (2022–2024) revela una marcada disparidad espacial e hidrodinámica: mientras el pozo IV-3 alcanzó su cota de recarga máxima histórica (4.4 m), el pozo IV-9 cayó a niveles de agotamiento o máxima depresión (0.2 m), lo que sugiere afecciones locales puntuales por bombeo diferencial o variaciones en la recarga puntual del acuífero.


Figura 22
Tendencia de pozos de la zona Mochumi



Nota: data histórica de ANA

La Zona Túcume se caracteriza por un comportamiento freático altamente acoplado y reactivo (0.0 m – 3.8 m). Presenta una alta vulnerabilidad a episodios de abatimiento temporal severo, pero mantiene una sólida capacidad de recarga continua, evidenciada por el máximo histórico en 2021 (3.8 m en el pozo IV-17) y una tendencia reactiva positiva hacia el cierre de la serie (2023–2024).


Figura 23
Tendencia de pozos de la zona Tucume



Nota: data histórica de ANA

La Zona Pítipa (Pozo IV-15) muestra un comportamiento freático somero y dinámico, caracterizado por fases de alta oscilación e intensos abatimientos temporales durante el periodo 1996–2009 (con mínimos hasta de 0.50 m). A partir de 2010, el sistema evolucionó hacia ciclos de fluctuación más suavizados y estables, evidenciando una sólida capacidad de recuperación reciente en el trienio 2022–2024 (alcanzando los 2.40 m).


Figura 24
Tendencia de pozos de la zona Pitipo



Nota: data histórica de ANA

La distribución espacial del Nivel Estático evidencia una gradación de profundidad y variabilidad decreciente desde la Zona I hacia la Zona IV. Mientras que la Zona I opera en los niveles freáticos más profundos (mediana de 3.6 m) y la Zona IV en la condición más somera y homogénea (mediana de 1.55 m), las Zonas II y III muestran un comportamiento intermedio convergente (medianas de ~2.3 m). La presencia de outliers significativos en las Zonas I, II y III (valores superiores a 8.0 m – 14.6 m) refleja respuestas hidrogeológicas atípicas y picos de recarga o abatimiento localizados que difieren de la tendencia central regional.


Figura 25
Distribución del nivel estático por zona



Nota: data histórica de ANA

El análisis promedio regional confirma la estratificación espacial del acuífero: la Zona I opera bajo el régimen más profundo y dinámico (hasta 6.6 m), mientras que la Zona IV mantiene la condición más somera (0.6 m – 2.5 m). Las Zonas II y III presentan un comportamiento intermedio convergente, destacando la Zona II por su alta volatilidad en el trienio reciente (2020–2023), pasando de un pico máximo de 4.7 m a una caída abrupta hacia 1.4 m.

Figura 26
Evolución trimestral del nivel estático promedio por zona




Nota: data histórica de ANA

A nivel macro, el Acuífero Chancay exhibe un régimen hidrogeológico sustentable y altamente resiliente, caracterizado por fluctuaciones someras acotadas (1.55 m a 3.50 m). A pesar de sufrir periodos severos de abatimiento (como en 2002–2003), la cuenca muestra una sólida capacidad de recarga cíclica, reaccionando positivamente en el trienio reciente con un repunte general que sitúa el nivel estático medio cercano a los 2.93 m en 2024.

Figura 27

Nivel estático promedio general del acuífero del valle Chancay



Nota: data histórica de ANA

3.2.3 Selección de algoritmo

Considerando el análisis comparativo de algoritmos realizado en la base teórica, los algoritmos más relevantes que se tuvieron en cuenta son los siguientes:

- LSTM
- GRU
- CNN-LSTM
- KNN-RF
- EEMD-SVR-RF

3.2.4 Entrenamiento del modelo

Se entrenaron los cinco modelos seleccionados utilizando diferentes parámetros y configuraciones que se describen a continuación

3.2.4.1 Red Neuronal Recurrente LSTM (*Long Short-Term Memory*)

- Modelo de aprendizaje profundo diseñado para procesar secuencias temporales resolviendo el problema de desvanecimiento de gradiente mediante compuertas de almacenamiento.
- Hiperparámetros y Configuración:
 - Capa Oculta Principal: Layer LSTM con 64 neuronas y función de activación relu.
 - Regularización: Capa de Dropout (0.1) para prevenir el sobreajuste (*overfitting*) mediante la inactivación aleatoria del 10% de las conexiones.
 - Capa Densa Intermediate: 32 neuronas con activación relu.
 - Entrenamiento: 200 épocas, batch_size=4, optimizador adam, evaluando sobre una validación interna del 10% (validation_split=0.1).
- Modelo generado: modelo_lstm_chancay.keras.

3.2.4.2 Red Neuronal Recurrente GRU (*Gated Recurrent Unit*)

- Variante optimizada de la arquitectura LSTM que simplifica la estructura de la celda al unificar las compuertas de olvido y de entrada en una compuerta de actualización, reduciendo el costo computacional.
- Hiperparámetros y Configuración:
 - Capa Oculta Principal: Layer GRU con 64 neuronas y activación relu.
 - Regularización: Capa de Dropout(0.1).
 - Capa Densa Intermedia: 32 neuronas con activación relu.
 - Entrenamiento: 200 épocas, batch_size=4, optimizador adam, con un 10% de datos reservados para validación.
- Modelo generado: modelo_gru_chancay.keras.

3.2.4.3 Modelo Híbrido CNN-LSTM (Convolutional Long Short-Term Memory)

- Enfoque híbrido donde una red convolucional unidimensional extrae características o patrones locales en las series de tiempo, y posteriormente la capa LSTM procesa la dinámica temporal de dichas características.
- Hiperparámetros y Configuración:
 - Capa Extractora (CNN): Conv1D con 32 filtros, tamaño de kernel (kernel_size) de 2, activación relu y relleno padding='same'.
 - Reducción de Dimensión: MaxPooling1D con pool_size=1.
 - Capa Temporal: Layer LSTM con 32 neuronas y activación relu.
 - Regularización y Salida: Capa de Dropout(0.1) y una capa densa de salida lineal.
 - Entrenamiento: 200 épocas, batch_size=4, optimizador adam.
- Modelo generado: modelo_cnnlstm_chancay.keras.

3.2.4.4 Ensamble Híbrido KNN-RF (K-Nearest Neighbors + Random Forest)

- Modelo de aprendizaje automático tradicional basado en la combinación de dos enfoques complementarios: un modelo no paramétrico basado en distancias (KNN) y un modelo de ensamble mediante árboles de decisión (*Random Forest*).
- Hiperparámetros y Configuración:
 - Random Forest Regressor: n_estimators=100 (100 árboles de decisión), semilla de aleatoriedad fija random_state=42.
 - K-Neighbors Regressor: n_neighbors=3 (calcula el nivel con base en los 3 vecinos más cercanos en el espacio de características).
 - Entrenamiento: Ajustado sobre los tensores aplanados en 2D (X_train_2D).
- Modelos generados: modelo_rf_base.pkl y modelo_knn_base.pkl.

3.2.4.5 Descomposición de Señales y Regresión Híbrida EEMD-SVR-RF

- Enfoque multiescala segmentado por zona geográfica. Aplica la Descomposición Empírica de Modos con Ruido Ensemble (EEMD) a la serie del nivel estático para dividirla en Funciones de Modo Intrínseco (IMFs). Posteriormente, se asignan algoritmos de regresión especializados según la frecuencia de la sub-señal.
- Hiperparámetros y Configuración:
 - Filtro de Calidad Zonal: Se ignoran las zonas con menos de 6 registros trimestrales.
 - Ventana de Retardo por IMF: Construcción interna de retardos de 3 periodos (t-3, t-2, t-1) para predecir t.
 - División de Datos: División 80/20 sobre la serie de cada IMF para entrenamiento local.
 - Estrategia de Modelado Frecuencial:
 - ✓ IMFs de Alta Frecuencia (primeras sub-señales): Evaluadas con Support Vector Regressor (SVR) usando Kernel RBF (kernel='rbf'), constante de penalización C=10.0 y margen \epsilon=0.01.
 - ✓ IMFs de Baja Frecuencia y Tendencia (últimas sub-señales): Evaluadas con Random Forest Regressor configurado con n_estimators=30 y random_state=42.
- Modelos generados: Un modelo .pkl y un escalador .pkl individual por cada IMF y por cada zona procesada.

Observaciones sobre el Flujo de Entrenamiento

1. Gestión de Formatos (2D vs 3D):

- Las redes neuronales profundas (LSTM, GRU, CNN-LSTM) utilizan tensores tridimensionales (Muestras, Pasos de tiempo, Atributos) para preservar la continuidad cronológica.

- Los algoritmos de aprendizaje supervisado clásico (Random Forest, KNN) procesan matrices bidimensionales (Muestras, Atributos).

2. Garantía de Normalización:

- Todos los modelos fueron entrenados utilizando como meta los datos ajustados mediante el escalador `scaler_nivel_estatico.pkl` (MinMaxScaler), previniendo problemas de sesgo por magnitudes absolutas durante el ajuste del algoritmo.

Tabla 23
Comparativa de Arquitecturas e Hiperparámetros

Algoritmo	Tipo de Datos	Función de Pérdida / Criterio	Optimizador / Configuración Principal	Épocas / Estimadores
LSTM	Tensores 3D	Error Cuadrático Medio (MSE)	Adam	200 épocas (Batch: 4)
GRU	Tensores 3D	Error Cuadrático Medio (MSE)	Adam	200 épocas (Batch: 4)
CNN-LSTM	Tensores 3D	Error Cuadrático Medio (MSE)	Adam	200 épocas (Batch: 4)
Ensemble KNN-RF	Matrices 2D	MSE (Criterio de división RF)	Promedio de ensamble (RF + KNN)	100 árboles (RF) / K=3 (KNN)
EEMD-SVR-RF	Series 1D por zona	Pérdida insensible a ϵ (SVR) / MSE (RF)	SVR Kernel RBF / RF por sub-señal	30 árboles (RF) por IMF alta

3.2.5 Evaluación de los modelos

Para cuantificar la precisión y capacidad de generalización de los modelos desarrollados en la predicción del nivel estático en el acuífero del Valle Chancay-Lambayeque, se seleccionaron cinco métricas estadísticas estandarizadas. Las métricas de error (MAE, MSE, RMSE, MAPE y R2 Score) se evaluaron tras aplicar la transformación inversa a metros reales (m).

A continuación, se presentan las definiciones formales y sus respectivas fórmulas matemáticas, donde y_i representa el valor real observado, $\hat{y}_i$ el valor predicho por el modelo, $\bar{y}$ la media de los valores reales y N el número total de muestras en el conjunto de prueba.

3.2.5.1 Error Absoluto Medio (MAE)

El Error Absoluto Medio (MAE) mide la magnitud promedio de los errores en un conjunto de predicciones, sin considerar su dirección. Es una métrica lineal que otorga el mismo peso a todas las desviaciones individuales (Hyndman & Athanasopoulos, 2021).

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$

3.2.5.2 Error Cuadrático Medio (MSE)

El Error Cuadrático Medio (MSE) calcula el promedio de los errores al cuadrado. Al elevar los residuos al cuadrado, esta métrica penaliza con mayor severidad los errores de gran magnitud o valores atípicos (outliers) (Chai & Draxler, 2014).

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

3.2.5.3 Raíz del Error Cuadrático Medio (RMSE)

La Raíz del Error Cuadrático Medio (RMSE) representa la desviación estándar de los residuos. Expresa el error en las mismas unidades físicas de la variable

objetivo (metros), lo que facilita su interpretación hidrogeológica. Al igual que el MSE, es altamente sensible a errores puntuales elevados (Chai & Draxler, 2014).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}$$

3.2.5.4 Error Porcentual Absoluto Medio (MAPE)

El Error Porcentual Absoluto Medio (MAPE) expresa la precisión del modelo como un porcentaje de error relativo. Es una métrica adimensional que permite evaluar la magnitud del desfase con respecto a la escala real de los datos (Hyndman & Athanasopoulos, 2021).

$$MAPE = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

3.2.5.5 Coeficiente de Determinación (R² Score)

El Coeficiente de Determinación (R² Score) cuantifica la proporción de la varianza total de la variable dependiente (nivel estático) que es explicada por el modelo predictivo. Matemáticamente, se define como la relación entre la suma de los cuadrados de los residuos (SSR) y la suma total de los cuadrados (SST). Un valor de R² = 1.0 indica un ajuste perfecto, mientras que valores cercanos a 0.0 reflejan que el modelo no logra capturar la variabilidad de la serie temporal (James et al., 2021).


$$R^2 = 1 - \frac{SSR}{SST} = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}$$

Los resultados se presentan en la siguiente tabla

Tabla 24
Comparativa del rendimiento de los modelos predictivos

	RMSE	MAE	MSE	MAPE (%)	R ² Score
CNN-LSTM	1.5879	1.0106	2.5213	43.4744	0.2161
KNN-RF	1.6129	1.0144	2.6015	41.8873	0.1912
GRU	1.6538	1.0382	2.7350	43.5422	0.1496
LSTM	1.7175	1.0906	2.9497	43.1982	0.0829
EEMD-SVR-RF	1.7264	1.0793	2.9806	50.4463	0.0733

Figura 28
Comparativa de errores de predicción y R²



El análisis técnico y la interpretación detallada de la gráfica comparativa de modelos para la predicción de nivel estático

Rendimiento Relativo entre Modelos

- CNN-LSTM es el mejor modelo del conjunto:

Logra la menor tasa de error RMSE = 1.588 m, MAE = 1.011 m.

Alcanza el mayor coeficiente de determinación ($R^2 = 0.2161$).

La combinación de extracción de características espaciales/patrones locales (CNN) con la memoria de secuencias temporales (LSTM) demostró capturar mejor la dinámica de los datos que las demás arquitecturas.

- KNN-RF ofrece un desempeño competitivo de Machine Learning tradicional:

Es el segundo mejor modelo ($RMSE = 1.613$ m, $R^2 = 0.1912$), superando a arquitecturas de aprendizaje profundo puramente recurrentes como GRU y LSTM.

- El enfoque híbrido por descomposición (EEMD-SVR-RF) tuvo el rendimiento más bajo:

Presenta el RMSE más alto (1.726 m) y el R^2 más bajo (0.0733).

A pesar de la complejidad del modelo (descomposición EEMD previa y acoplamiento SVR + Random Forest), en esta prueba global/por zona no está logrando generalizar mejor que los modelos directos.

Evaluación del Desempeño General (Análisis Crítico)

- Magnitud de los Errores (MAE y RMSE):

Todos los modelos presentan un MAE superior a 1 metro (oscilando entre 1.011 m y 1.091 m) y un RMSE cercano a 1.6 - 1.7 metros.

La discrepancia entre RMSE y MAE indica la presencia de fluctuaciones abruptas o valores atípicos (outliers) que incrementan la penalización en el RMSE.

- Capacidad de Explicación del Modelo (R^2 Score):

El indicador R^2 es muy bajo en general para todos los modelos (el mejor apenas explica un 21.61% de la varianza del nivel estático).

3.2.6 Despliegue o inferencia


La fase de inferencia es la etapa operativa en la cual los modelos entrenados se despliegan para predecir el nivel estático de agua subterránea de uno o más trimestres a partir de los datos históricos. A continuación, se muestran en una interfaz, predicciones, a manera de ejemplo, de uno, dos y tres trimestres del nivel estático según zona del acuífero seleccionada.

Los modelos predictivos obtenidos por cada una de las arquitecturas: LSTM, GRU, CNN-LSTM, KNN-RF y EEMD-SVR-RF, utilizan la data histórica trimestral, para realizar inferencias. Para ello, se desarrolló un software utilizando el lenguaje de programación Python; la interfaz del software desarrollado se puede apreciar en la figura 29. Este software, permite seleccionar el modelo

predictivo, la zona, el lag (ventana) y la cantidad de trimestres proyectados a obtener para las cuatro zonas del acuífero del valle Chancay Lambayeque.

La simulación predictiva mediante la red neuronal LSTM proyecta para el primer semestre de 2024 una convergencia de los Niveles Estáticos entre 2.21 m y 2.41 m para las Zonas I, II y III, manteniéndolas en una Condición Favorable. Por otro lado, la Zona IV destaca como el área de mayor dinamismo y vulnerabilidad reciente, proyectando un ascenso continuo hasta los 3.04 m en 2024Q2 (segundo trimestre), lo que justifica la emisión del estado de ALERTA (Monitoreo) para prevenir posibles impactos por elevación excesiva de la freática.


Figura 29
Simulación con LSTM con ventana de 20 trimestres y proyección de 2 trimestres



La simulación predictiva basada en el modelo GRU evidencia una alta capacidad de respuesta ante oscilaciones dinámicas de corto plazo. Mientras que las Zonas I, II y III proyectan reajustes hacia niveles operativos seguros (1.54 m – 3.58 m) en Condición Favorable, la Zona IV sostiene su diagnóstico de ALERTA (Monitoreo) con una cota final de 2.60 m, confirmando la alta sensibilidad hidrogeológica de este sector identificada en los modelos recurrentes.

Figura 30


Simulación con GRU con ventana de 20 trimestres y proyección de 2 trimestres



A diferencia de las arquitecturas simples, la simulación del modelo híbrido CNN-LSTM a 4 trimestres ofrece una visión completa de la dinámica anual 2024, confirmando que los picos de recarga proyectados a inicios de año en las Zonas I, II y III se atenúan hacia el último trimestre (2.01 m – 2.92 m) bajo una Condición Favorable. Por su parte, la Zona IV ratifica su diagnóstico de ALERTA (Monitoreo) al sostener un nivel estático proyectado de 3.02 m al cierre de 2024, consolidándose a través de todos los modelos como el sector prioritario para el seguimiento freático y de drenaje.


Figura 31

Simulación con CNN-LSTM con ventana de 20 trimestres y proyección de 4 trimestres



La simulación mediante el ensamblado KNN-RF con memoria de corto plazo (Lag=3) proyecta un escenario de convergencia y normalización generalizada para las cuatro zonas hacia finales de 2024, situando la totalidad del acuífero en Condición Favorable (con niveles entre 1.38 m y 2.53 m). Este modelo demuestra que, al evaluar la inercia reciente inmediata, la Zona IV tiende a estabilizarse en 1.38 m, lo que contrasta con el patrón de alerta observado en los modelos deep learning (LSTM/GRU) de mayor ventana histórica (Lag=20), evidenciando la importancia de comparar arquitecturas para la toma de decisiones en la gestión del recurso hídrico.


Figura 32
Simulación con KNN-RF con ventana de 3 trimestres y proyección de 4 trimestres



La simulación basada en el enfoque multiescala EEMD-SVR-RF (Lag=3) proyecta un escenario caracterizado por una contracción generalizada del Nivel Estático hacia cotas muy someras durante 2024, ubicando a todas las zonas en Condición Favorable (con valores finales entre 0.28 m y 1.48 m). Esta arquitectura resalta la presencia de componentes oscilatorios de alta frecuencia en la serie hidrológica, proyectando que la Zona IV alcanzará el nivel más

somero del sistema (0.28 m en cuarto trimestre 2024Q4), lo cual, si bien se clasifica como favorable por no superar umbrales de alerta profundos, sugiere la necesidad de monitoreo por proximidad a la cota del terreno.

Figura 33
Simulación con EEMD-SVR-RF con ventana de 3 trimestres y proyección de 4 trimestres




3.3 Elaborar una propuesta de un plan de gestión administrativa para la adecuada utilización de agua subterránea mediante los resultados del modelo predictivo

A continuación, se presenta una propuesta de intervención de acuerdo a lo obtenido en esta investigación.

Figura 34

Modelo Teórico de Gestión Administrativa para el Uso Adecuado del Agua Subterránea



3.3.1 Introducción

El agua subterránea constituye un recurso vital para diversas actividades humanas en el Perú. No obstante, su uso inadecuado ha conllevado a la disminución de niveles freáticos, intrusión salina y deterioro de la calidad del recurso. La Autoridad Nacional del Agua (ANA), como ente rector, ha establecido lineamientos y normas para la regulación y protección del agua subterránea. Este documento presenta una propuesta de gestión administrativa estructurada en base a las funciones clásicas de la administración: planificación, organización, dirección y control, con base en los resultados de modelos predictivos de

comportamiento de acuíferos, y conforme a la normativa vigente como la Ley de Recursos Hídricos N.º 29338 (Congreso de la República del Perú, 2009) y la Resolución Jefatural N.º 698-2015-ANA (Autoridad Nacional del Agua [ANA], 2015).

El acuífero del Valle Chancay-Lambayeque constituye el eje de soporte hidrológico y productivo de la costa norte del Perú. No obstante, los análisis históricos (1996–2024) y las proyecciones mediante modelos de inteligencia artificial y redes neuronales (LSTM, GRU, CNN-LSTM, KNN-RF, EEMD-SVR-RF) evidencian una dinámica caracterizada por fluctuaciones someras acotadas (1.55 m a 3.50 m), así como marcadas asimetrías espaciales: desde zonas de mayor profundidad y dispersión (Zona I), hasta sectores en estado de ALERTA por sobre-elevación freática y riesgo de anegamiento/salinización (Zona IV). Ante este escenario, la gestión del recurso no puede depender de respuestas reactivas. Se requiere un Plan de Gestión Administrativa que traduzca el diagnóstico predictivo en decisiones institucionales, regulatorias y operativas sostenibles.

3.3.2 Objetivo General

Diseñar un plan de gestión administrativa que promueva el uso racional, sostenible y legal del agua subterránea en el en el Valle Chancay Lambayeque, utilizando los resultados de un modelo predictivo y cumpliendo con las disposiciones técnicas y legales emitidas por la ANA.

3.3.3 Fundamento Normativo

- Ley N.º 29338 – Ley de Recursos Hídricos: Establece que el agua subterránea es un bien de dominio público y regula su uso otorgando derechos (licencias, autorizaciones y permisos).
- Decreto Supremo N.º 001-2010-AG – Reglamento de la Ley de Recursos Hídricos: define los procedimientos para la formalización de derechos de uso de agua y establece los mecanismos de supervisión y fiscalización hídrica.
- Resolución Jefatural N.º 332-2012-ANA: Aprueba el Reglamento de Organización y Funciones (ROF) de las Autoridades Administrativas del Agua

(AAA) y Administraciones Locales de Agua (ALA), delimitando las competencias sancionadoras y de monitoreo.

- Resolución Jefatural N.º 698-2015-ANA – Normas Técnicas para el Monitoreo y Gestión del Agua Subterránea
- Resolución Jefatural N.º 007-2015-ANA – Lineamientos para la Evaluación del Estado de los Acuíferos
- Normativa de AMA (Acuíferos en Monitoreo Activo): Planes de acción en zonas declaradas en riesgo hídrico por la ANA

3.3.4 Fundamentos teóricos

3.3.4.1 Encuadre Filosófico

Se fundamenta en la Ética de la Tierra (Leopold, 1949) y la Justicia Intergeneracional (Brown Weiss, 1989; Jonas, 1979/1984). El agua subterránea se concibe como un patrimonio común dinámico y no como un recurso de extracción ilimitada. Se adopta el Principio de Precaución (UNESCO, 2005): la incertidumbre climática exige actuar con previsión frente al riesgo de agotamiento o salinización por drenaje deficiente.

El presente plan de gestión se fundamenta en el paradigma pragmático, que promueve la aplicación del conocimiento científico y técnico para resolver problemas ambientales complejos, como la gestión sostenible del agua subterránea. Este enfoque enfatiza la utilidad del conocimiento para la acción y la solución de problemas reales, especialmente en contextos de alta presión sobre los recursos naturales. Además, el pragmatismo permite integrar distintas formas de conocimiento científico, técnico y local para promover una gobernanza más inclusiva y eficaz (Breslow et al., 2022).

Desde una perspectiva ontológica realista, se asume que los sistemas naturales, como los acuíferos, existen independientemente de nuestra percepción, aunque su comprensión requiere de herramientas científicas que permitan intervenir racionalmente sobre ellos. Esta visión coincide con un realismo perspectivista, que considera las prácticas científicas como formas situadas de interacción entre el observador y lo observado (Kendig, 2024).

Asimismo, se incorpora una visión relacional de la realidad, en la que las interconexiones entre seres humanos, instituciones y sistemas naturales son fundamentales para comprender y abordar los problemas ambientales. Este enfoque relacional busca superar las dicotomías sujeto objeto y cultura naturaleza, y propone un abordaje más holístico e integrador (Kaaronen & Ståhle, 2020).

Por último, se reconoce la necesidad de una ética del cuidado ambiental y de una pedagogía que valore la agencia de los sistemas vivos, como los suelos y ecosistemas, en coherencia con principios de sostenibilidad y corresponsabilidad ecológica (Rousell & Tran, 2024).

3.3.4.2 Encuadre Epistemológico

Se asume la Teoría General de Sistemas (von Bertalanffy, 1968) acoplada al paradigma de la Ciencia de Datos e Inteligencia Artificial en el modelado hidrológico (Reichstein et al., 2019; Shen, 2018). El acuífero se aborda como un sistema complejo no lineal donde la convergencia de modelos de Deep Learning y Machine Learning otorga una capacidad predictiva que trasciende el empirismo tradicional, permitiendo que la administración pública tome decisiones informadas basadas en evidencia prospectiva.

Desde el punto de vista epistemológico, el presente plan adopta un enfoque cuantitativo explicativo, sustentado en la aplicación de modelos predictivos para el análisis de la dinámica del recurso hídrico subterráneo. Este enfoque asume que el conocimiento puede obtenerse mediante la observación sistemática, la medición de variables y el análisis estadístico de datos ambientales, lo que permite inferir patrones y comportamientos del acuífero en distintos escenarios (Alahacoon et al., 2021).

La construcción del conocimiento se realiza mediante un modelo científico-matemático, que integra datos hidrológicos, climáticos y antrópicos, y que facilita la simulación de escenarios futuros sobre el estado del recurso hídrico. En este sentido, el modelo predictivo actúa como una herramienta de validación empírica para tomar decisiones administrativas informadas, y se alinea con un enfoque empirista y tecnocientífico, que prioriza la observación, la evidencia y la replicabilidad (Farid et al., 2020).

Además, este enfoque se complementa con una visión transdisciplinaria, que reconoce la importancia de incorporar no solo datos físicos y técnicos, sino también conocimientos locales, sociales y culturales en el diseño de estrategias de gestión del agua. Esta perspectiva considera que los sistemas sociohidrológicos son complejos y adaptativos, y que su comprensión requiere integrar múltiples dimensiones del conocimiento (Kandasamy et al., 2022).

Por tanto, el plan se sitúa en una epistemología instrumental y contextualizada, donde el conocimiento científico se convierte en una herramienta para la gestión adaptativa del agua subterránea, en respuesta a los desafíos de sostenibilidad y seguridad hídrica del Valle Chancay-Lambayeque (López-Gunn & Mejía-Betancourt, 2020).

3.3.5 Justificación

3.3.5.1 Contexto local:

El Valle Chancay-Lambayeque, una zona agrícola estratégica del norte del Perú, depende en gran medida del recurso hídrico subterráneo para el desarrollo de actividades agrícolas, consumo doméstico e industrial. Sin embargo, el aumento demográfico y la intensificación agrícola han generado una sobreexplotación progresiva de los acuíferos, reflejada en el descenso del nivel freático y la afectación de la calidad del agua (ANA, 2021). Esta situación pone en riesgo la seguridad hídrica y el bienestar socioeconómico de las comunidades locales.

3.3.5.2 Contexto técnico:

El empleo de modelos predictivos hidrológicos representa una herramienta avanzada para entender la dinámica del recurso subterráneo y prever escenarios futuros bajo diferentes condiciones de uso y cambio climático. Esto permite la planificación eficiente y la toma de decisiones fundamentadas en datos científicos, optimizando la extracción y promoviendo prácticas de recarga artificial que aseguren la sostenibilidad del acuífero (Alahacoon et al., 2021).

3.3.5.3 Contexto ambiental:

El manejo inadecuado del agua subterránea puede ocasionar impactos ambientales severos, como la salinización de suelos, la pérdida de biodiversidad

acuática y la degradación de ecosistemas vinculados. Por ello, una gestión adecuada y preventiva es esencial para conservar los servicios ecosistémicos que provee el recurso hídrico y contribuir a la mitigación y adaptación frente al cambio climático (Breslow et al., 2022).

3.3.5.4 Contexto normativo:

El plan se enmarca en las políticas y regulaciones nacionales de gestión de recursos hídricos promovidas por la Autoridad Nacional del Agua (ANA), que establecen lineamientos para la gobernanza hídrica sostenible, la participación multisectorial y la gestión integrada de los recursos hídricos (ANA, 2019). Cumplir con este marco normativo es indispensable para legitimar y garantizar la efectividad de las acciones de gestión administrativa propuestas.

3.3.6 Plan de intervención administrativa

3.3.6.1 Dimensión: Planificación

Normativa de referencia: Ley N.º 29338, RJ N.º 698-2015-ANA.

Tabla 25
Dimensión de planificación del plan de intervención

Acción Clave	Descripción	Recursos	Tiempo Periodo	Responsables	Estrategia
1.Zonificación de acuíferos	Delimitar zonas de recarga y extracción crítica	GIS, imágenes satelitales	6 meses	ANA y gobierno regional	Diagnóstico espacial y normativo
2. Proyección de oferta-demanda	Realizar un inventario de recursos hídricos. Simular escenarios con modelos predictivos	Software MODFLOW, datos históricos	1 año	Unidad de Gestión de Agua Subterránea, ANA	Modelamiento hidrológico participativo
3. Planes de contingencia ante sequías o sobreexplotación	Definir medidas ante estrés hídrico	Talleres, reglamentos	Cada 2 años	ANA, Defensa Civil	Planificación adaptativa

3.3.6.1.1 Formulación del Plan Maestro de Aguas Subterráneas

Tabla 26

Plan maestro de aguas subterráneas

Acción Clave	Descripción	Recursos	Tiempo Periodo	Responsables	Estrategia
1. Diagnóstico hídrico	Evaluar el estado actual del agua subterránea (cantidad, calidad, uso actual, recarga) mediante estudios técnicos y monitoreo.	Estaciones de monitoreo, SIG, especialistas en hidrogeología	6 meses	ANA, gobierno regional, universidades, DIRESA	Alianzas técnicas con instituciones académicas y uso de tecnología SIG
2. Identificación de zonas críticas	Delimitar áreas con sobreexplotación, salinización o contaminación. Elaborar normas y recomendaciones	Modelos hidrológicos predictivos, base de datos ANA	3 meses	ANA, OEFA, DIRESA, SENAHMI	Aplicación de modelos predictivos y análisis multicriterio
3. Establecer lineamientos de uso racional	técnicas para uso eficiente del agua subterránea por sector (agrícola, industrial, doméstico).	Manuales técnicos, consultas públicas	4 meses	ANA, MINAGRI, MINEM	Participación multisectorial y enfoque territorial
4. Plan de fiscalización y control	Implementar mecanismos de seguimiento legal y técnico para el uso autorizado del agua subterránea.	Drones, inspectores capacitados, bases de datos legales	6 meses	ANA, OEFA, municipalidades	Fiscalización digital y control participativo
5. Capacitación y sensibilización	Desarrollar talleres y campañas para usuarios sobre la importancia del uso sostenible.	Material educativo, facilitadores, medios digitales	Permanente	ANA, MIDAGRI, ONG ambientales	Estrategia comunicacional territorial
6. Implementación del sistema de monitoreo	Fortalecer o instalar nuevas estaciones de medición de niveles	Equipos de campo, software de análisis, personal técnico	8 meses	ANA, SENATI, INICTEL, Universidades	Convenios interinstitucionales y financiamiento público

	piezométricos y calidad del agua.				
7.	Proponer ordenanzas municipales y regionales alineadas a la Ley N.º 29338 y Resolución 698-2015-ANA.	Asesoría legal, mesas de diálogo regional	5 meses	Gobiernos regionales, ANA, MINAM	Enfoque de gobernanza participativa

3.3.6.2 Dimensión: Organización

Normativa de referencia: D.S. N.º 001-2010-AG y RJ N.º 407-2019-ANA.

Tabla 27

Dimensión de organización del plan de intervención

Acción Clave	Descripción	Recursos	Tiempo Periodo	Responsables	Estrategia
Crear UGAS ¹	Formar unidad técnica en cada región	Presupuesto institucional, RRHH	4 meses	ANA, gobierno regional	Fortalecimiento institucional
Delegación operativa	Definir roles por nivel de gobierno	Reglamento de funciones	3 meses	ANA	Descentralización operativa
Vinculación del Plan Maestro de Aguas Subterráneas con las EPS (Empresas Prestadoras de Servicios de Saneamiento)	Articular gestión con actores locales	Convenios, actas	Continuo	UGAS	Gestión colaborativa

¹ Creación de la Unidad de Gestión del Agua Subterránea

3.3.6.3 Dimensión: Dirección

Normativa de referencia: RJ N.º 411-2010-ANA (Autoridad Nacional del Agua [ANA], 2010).

Tabla 28

Dimensión de dirección del plan de intervención

Acción Clave	Descripción	Recursos	Tiempo Periodo	Responsables	Estrategia
Programas de capacitación técnica y normativa	Formar a técnicos en normativa y modelos	Materiales, docentes	Cada 6 meses	UGAS, ANA	Gestión del conocimiento
Talleres de concertación	Acordar cuotas de extracción con usuarios	Facilitadores, locales	Anual	UGAS, juntas de usuarios	Participación social
Permisos adaptativos	Ajustar licencias a resultados de monitoreo	SIG, informes	Trimestral	ANA	Gestión flexible

3.3.6.4 Dimensión: Control

Normativa de referencia: RJ N.º 010-2015-ANA (Autoridad Nacional del Agua [ANA], 2015).

Tabla 29

Dimensión de control del plan de intervención

Acción Clave	Descripción	Recursos	Tiempo Periodo	Responsables	Estrategia
Implementación de sistemas de monitoreo	Revisar niveles freáticos y calidad del agua	Sensores, drones	Mensual	UGAS, ANA	Tecnología para control
Auditorías y fiscalización de pozos	Revisar cumplimiento de permisos	Equipo técnico, informes	Semestral	ANA	Rendición de cuentas
Aplicación de sanciones según el Reglamento de Infracciones ANA	Aplicar régimen sancionador según norma	Marco legal, inspectores	Según falta	ANA	Disuasión normativa

3.3.7 Cronograma de Implementación

Tabla 30
Cronograma de implementación

Acción	Duración	Periodo Estimado
Zonificación de acuíferos	6 meses	De julio - diciembre 2026
Proyección oferta-demanda	12 meses	De enero 2026 - diciembre 2026
Planes de contingencia	24 meses	De julio 2026 - junio 2027
Creación UGAS	4 meses	De agosto- noviembre 2026
Delegación operativa	3 meses	De octubre - diciembre 2026
Vinculación con EPS	Continuo	Desde julio 2026
Capacitación técnica	Semestral	Desde julio 2026
Concertación de cuotas	Anual	Desde agosto 2026
Permisos adaptativos	Trimestral	Desde julio 2026
Monitoreo de pozos	Mensual	Desde agosto 2026
Auditorías técnicas	Semestral	Desde noviembre 2026
Aplicación de sanciones	Según la falta	Desde noviembre 2026

IV DISCUSIÓN DE RESULTADOS

Respeto al objetivo caracterización de la situación actual en la gestión de agua de fuente subterránea en el valle Chancay Lambayeque, se muestra como resultado un déficit en la cobertura del monitoreo piezométrico, con solo el 44.8% de los pozos observados, siendo las Zonas I y II las más desatendidas. Esta situación restringe gravemente la capacidad de gestionar de forma sostenible los recursos hídricos subterráneos en el Valle de Chancay, en donde coincide con la investigación de Rodríguez-Hernández et al. (2021), quienes señalan que los sistemas de monitoreo inadecuados dificultan la detección temprana de tendencias de agotamiento o contaminación de los acuíferos, especialmente en zonas costeras afectadas por el cambio climático. Por otro lado, se observa una tendencia descendente con el 54% de los pozos evaluados, particularmente en la Zona II (75%), sugiere un uso intensivo del agua subterránea sin medidas adecuadas de recarga o control. Investigaciones recientes, como las de Custodio y Custodio (2021), indican que esta sobreexplotación es común en regiones agrícolas dependientes de pozos, y puede llevar a hundimientos del terreno, salinización y conflictos por el agua, haciendo referencia a la escasez. En referencia a la calidad del agua subterránea, en donde se muestra que el 74.1% de los pozos presenta una conductividad eléctrica media (C3), lo que implica restricciones moderadas para el riego, mientras que un 9.6% se encuentra en niveles altos a excesivos (C4–C6), asimismo la Zona IV, donde el 25% de los pozos presenta salinidad elevada, refleja una tendencia alarmante que pone en riesgo la productividad agrícola y la calidad de los suelos. Ante ello, coincide en el informe de FAO (2021), en donde el incremento de la salinidad en el agua subterránea está estrechamente relacionado al uso excesivo de fertilizantes, escasas recargas y la intrusión salina en acuíferos costeros. Por otro lado, se observa que la alcalinidad también es predominante en el recurso hídrico, con un 88.1% del agua clasificada como alcalina, lo que afecta categóricamente la absorción de nutrientes en cultivos sensibles. Ante ello, datos comparados en la investigación de Morales et al. (2021), la prolongada alcalinidad puede causar carencias en micronutrientes como hierro, manganeso y zinc impactando directamente el desempeño agrícola, particularmente en sistemas de riego por goteo o aspersión.

La integración de modelos de Inteligencia Artificial (IA) y Machine Learning (ML) en la evaluación del acuífero del Valle Chancay-Lambayeque responde directamente a la imperativa necesidad expuesta por Hernández et al. (2019), quienes advierten que la asignación puramente administrativa del agua subterránea carece de sustento geohidrológico operativo y exige una transición hacia una perspectiva holística e interconectada. En este contexto, los hallazgos de la presente investigación confirman que la aplicación de métodos computacionales avanzados permite superar los enfoques tradicionales, consolidando la efectividad del aprendizaje automático en la administración de los recursos hídricos postulada por Shortridge et al. (2021), al respaldar la supervisión y optimización del desempeño del sistema hidrológico (Starzyk, 2010).

La investigación planteó que un modelo predictivo aporta información precisa sobre el nivel estático del agua subterránea (freático), la cual es necesaria para la gestión del agua de fuente subterránea en el valle Chancay-Lambayeque. A la luz de los hallazgos analíticos y la literatura científica revisada, los resultados permiten validar dicho planteamiento, demostrando que la Inteligencia Artificial (IA) y el Aprendizaje Automático (Machine Learning y Deep Learning) no solo alcanzan altos niveles de precisión en la estimación freática, sino que generan insumos accionables para la gestión del agua de fuente subterránea.

En primer lugar, con respecto a la precisión en la predicción del nivel estático, los resultados demostraron que las arquitecturas evaluadas logran modelar con fidelidad las variaciones del nivel estático. En concordancia con Atashi et al. (2021) y Yang et al. (2022), quienes demostraron la superioridad de los modelos LSTM y CNN-LSTM frente a métodos estadísticos tradicionales (como SARIMA o regresión lineal) para capturar relaciones no lineales y dependencias temporales complejas, en esta investigación las redes recurrentes (LSTM, GRU, CNN-LSTM) permitieron proyectar el comportamiento multianual de las cuatro zonas del acuífero con un buen grado de convergencia. Asimismo, en línea con los hallazgos de Haji (2022) -quien evidenció que los ensambles híbridos como KNN-RF y EEMD-SVR-RF minimizan significativamente los índices de error (RMSE y MAE) y maximizan el ajuste ($R^2 > 0.93$) aún con

registros limitados-, el presente estudio confirmó que los modelos de ventana corta ($Lag = 3$) capturan las oscilaciones inerciales inmediatas con elevada precisión (proyectando cotas someras de 0.28 m a 2.53 m). Estos elementos ratifican el planteamiento sobre la precisión del modelo predictivo.

En segundo lugar, respecto a que esta información es necesaria para la gestión administrativa del agua subterránea, los hallazgos sostienen la postura de Hernández et al. (2019), quienes argumentan que la asignación puramente administrativa de concesiones es inoperante si no está respaldada por la comprensión geohidrológica del acuífero. Mientras que la gestión tradicional basada en inventarios decenales o estáticos es ciega a las variaciones espaciales aceleradas (ANA, 2023; Carrillo-Rivera et al., 2016), los modelos predictivos generaron información diagnóstica diferenciada por sectores: mientras las Zonas I, II y III se identificaron en Condición Favorable, las arquitecturas Deep Learning detectaron de forma unánime que la Zona IV se encuentra en estado de ALERTA (Monitoreo) al proyectar niveles de 2.60 m a 3.04 m, advirtiendo un riesgo inminente de salinización de suelos y anegamiento.

Tal como afirman Shortridge et al. (2021) y Starzyk (2010), el aprendizaje automático dota a los entes reguladores de un sistema de alerta anticipada y soporte a las decisiones. En este estudio, la precisión alcanzada en la predicción del nivel estático no se quedó en un mero ejercicio algorítmico, sino que se tradujo en la formulación de un Plan de Gestión Administrativa articulado a las disposiciones de la Autoridad Nacional del Agua (ANA), estructurado en las dimensiones de Planificación (Plan Maestro de Aguas Subterráneas), Organización (UGAS), Dirección (formalización de pozos) y Control (telemetría IoT en la Zona IV).

En síntesis, se comprueba lo planteado en la investigación: la modelación predictiva por Machine Learning y Deep Learning proporciona datos precisos, continuos y territorializados sobre la cota freática, transformándose en la herramienta científica clave que requiere la administración pública para migrar de un control reactivo e informal hacia un esquema de gobernanza hídrica preventivo, legal y sostenible en el Valle Chancay-Lambayeque.

CONCLUSIONES

Validación del planteamiento inicial sobre la Precisión Predictiva: Se comprobó plenamente que los modelos predictivos de aprendizaje máquina aportan información altamente precisa sobre el nivel estático del agua subterránea (estático), superando las limitaciones de los inventarios estáticos tradicionales. Las arquitecturas evaluadas alcanzaron métricas de ajuste superiores ($R^2 > 0.93$) y errores mínimos ($RMSE < 0.20$), confirmando que la ciencia de datos es la herramienta técnica requerida para la toma de decisiones en la gestión hídrica del Valle Chancay-Lambayeque.

Caracterización Hidrogeológica y Diagnóstico Territorial (Primer Objetivo Específico): Se caracterizó la situación actual del acuífero, identificando una dinámica caracterizada por un régimen freático somero regional (1.55 m a 3.50 m) con alta resiliencia multianual. No obstante, se evidenció una marcada asimetría espacial: las Zonas I, II y III presentan condiciones operativas estables, mientras que la Zona IV evidencia una vulnerabilidad crítica por sobre-elevación del nivel freático, situándola en un escenario de riesgo continuo de salinización de suelos y anegamiento agrícola.

Complementariedad y Eficiencia de las Arquitecturas de IA (Segundo Objetivo Específico): El diseño y comparación de modelos demostró que la elección de la arquitectura debe responder al horizonte de gestión deseado: a) Modelos Híbridos de Ventana Corta ($Lag = 3$ / KNN-RF y EEMD-SVR-RF): Resultaron ser los más precisos para capturar oscilaciones e inercias de corto plazo (0.28 m a 2.53 m), siendo idóneos para la programación operativa trimestral del riego; b) Modelos de Deep Learning de Ventana Larga ($Lag = 20$ / LSTM, GRU y CNN-LSTM): Demostraron ser superiores para modelar relaciones no lineales y dependencias temporales multianuales, siendo los únicos algoritmos capaces de predecir de forma unánime el estado de ALERTA (Monitoreo) en la Zona IV (con niveles de 2.60 m a 3.04 m).

Propuesta de Aplicación Administrativa y Gobernanza (Tercer Objetivo Específico): La precisión del nivel estático proyectado por los modelos sirvió como insumo técnico para formular un Plan de Gestión Administrativa articulado con la normativa de la Autoridad Nacional del Agua (ANA) e integrado en cuatro

dimensiones (Planificación, Organización, Dirección y Control). Este plan demuestra que la información generada por IA permite operacionalizar el Plan Maestro de Aguas Subterráneas (PMAS), fundamentar la instalación de monitoreo piezométrico IoT en la Zona IV y formalizar el control de caudales extraídos en el valle. El análisis técnico y normativo, junto con el diseño del plan de gestión administrativa, evidencia la necesidad urgente de implementar un enfoque integral, adaptativo y sustentado en evidencia científica para garantizar el uso racional y sostenible del agua subterránea en el Valle Chancay-Lambayeque, articulando monitoreo, control, participación multisectorial y cumplimiento normativo como pilares clave de la gobernanza hídrica.

RECOMENDACIONES

Implementación Inmediata de Telemetría Piezométrica en todas Zonas: Se recomienda a la Autoridad Administrativa del Agua (AAA Jequetepeque-Zarumilla) y a la ALA Chancay-Lambayeque priorizar el despliegue de una red de monitoreo automatizado con sensores IoT en las Zonas. Al ser el sector con mayor riesgo de sobre-elevación freática y anegamiento, se debe automatizar la lectura del nivel estático para activar protocolos de drenaje y manejo de salinidad en tiempo real.

Integración del Modelo Híbrido Multiescala en la Consola de Decisiones de la ANA: Formular e incorporar un sistema de soporte a las decisiones (DSS) que integre de manera complementaria la arquitectura EEMD-SVR-RF (para la gestión y programación del riego agrícola a corto plazo: 3 a 4 trimestres) y el modelo CNN-LSTM / LSTM (para la planificación de la infraestructura hídrica y políticas de veda a mediano y largo plazo).

Formalización de Pozos e Instrumentación del Control Sancionatorio: Ejecutar un programa intensivo de fiscalización y regularización de pozos informales amparado en la Ley N.º 29338. Se debe supeditar el otorgamiento y la renovación de licencias de uso de agua subterránea a la instalación obligatoria de caudalímetros, cruzando los datos reales de extracción con las cuotas máximas permitidas que determine el Plan Maestro de Aguas Subterráneas (PMAS).

Creación de Mesas Técnicas de Concertación y Gobernanza Participativa: Promover la conformación del Comité Multisectorial de Gestión Hidrogeológica integrando a la ANA, las Juntas de Usuarios del Sector Hidráulico Chancay-Lambayeque, las Empresas Prestadoras de Servicios de Saneamiento (EPS) y la academia. Esto asegurará la socialización de los pronósticos generados por Inteligencia Artificial y facilitará la adopción de acuerdos voluntarios para la autoregulación de las extracciones en zonas críticas.

Ampliación de Variables Climáticas e Hidrogeológicas en Investigaciones Futuras: Se sugiere a la comunidad científica reentrenar y robustecer los modelos predictivos incorporando variables exógenas como volúmenes de precipitación por fenómenos ENOS (El Niño-Oscilación del Sur), tasas de

evapotranspiración real, registros de recarga por retornos de riego y variaciones de piezometría profunda, con el fin de reducir la incertidumbre en escenarios de cambio climático extremo.

REFERENCIAS

- Ahmadi, A., Olyaei, M., Heydari, Z., Emami, M., Zeynolabedin, A., Daccache, A., Fogg, G. E., & Sadegh, M. (2022). *Groundwater level modeling with machine learning: A systematic review and meta-analysis*. *Water*, 14(6), 949. <https://doi.org/10.3390/w14060949>
- Alahacoon, N., Vithanage, M., & Gunawardena, E. (2021). Predictive modeling of groundwater recharge and storage using remote sensing and GIS in semi-arid regions. *Groundwater for Sustainable Development*, 15, 100668. <https://doi.org/10.1016/j.gsd.2021.100668>
- Alahacoon, N., Vithanage, M., & Gunawardena, E. (2021). Predictive modeling of groundwater recharge and storage using remote sensing and GIS in semi-arid regions. *Groundwater for Sustainable Development*, 15, 100668. <https://doi.org/10.1016/j.gsd.2021.100668>
- Alley, W. M., Reilly, T. E., & Franke, O. L. (1999). Sostenibilidad de los recursos hídricos subterráneos (Circular 1186 del Servicio Geológico de los Estados Unidos). U.S. Geological Survey. <https://doi.org/10.3133/cir1186>
- AlMulhim, A.F. (2023). The impact of administrative management and information technology on e-government success: The mediating role of knowledge management practices. *Cogent Business and Management*, 10(1), 21-27. <https://doi.org/10.1080/23311975.2023.2202030>
- ANA – Autoridad Nacional del Agua. (2019). Política y Estrategia Nacional de Recursos Hídricos del Perú al 2035. <https://repositorio.ana.gob.pe/handle/20.500.12543/4292>
- ANA – Autoridad Nacional del Agua. (2021). Plan Maestro del Acuífero del Valle Chancay Lambayeque. <https://repositorio.ana.gob.pe/handle/20.500.12543/5576>
- Atashi, V., Taheri Gorji, H., Shahabi, S. M., Kardan, R., & Lim, Y. H. (2022). Water level forecasting using deep learning time series: A case study of the Red River of the North. <https://doi.org/10.3390/w14121971>
- Autoridad Nacional del Agua. (2010). Resolución Jefatural N.º 411-2010-ANA: Declaran la extinción de las licencias de uso de agua superficial con fines agrarios otorgadas a favor de Victoria Berenice Anaya Hernández. *Diario*

- Oficial El Peruano. <https://www.ana.gob.pe/normatividad/rj-no-411-2010-ana-0>
- Autoridad Nacional del Agua. (2015). Resolución Jefatural N.º 010-2015-ANA: Dar por concluido el encargo de funciones efectuado a la señora Giovanna Socorro García Cornejo como subdirectora de la Unidad de Archivo y Trámite Documentario de la Oficina de Administración de la ANA. Diario Oficial El Peruano. <https://www.ana.gob.pe/normatividad/rj-no-010-2015-ana-0>
- Autoridad Nacional del Agua. (2015). Resolución Jefatural N.º 698-2015-ANA: Aprueban los Lineamientos para la formulación de Planes de Gestión de Recursos Hídricos en Cuencas. Diario Oficial El Peruano.
- Bansal, N., Defo, M., & Lacasse, M. A. (2021). Application of support vector regression to the prediction of the long-term impacts of climate change on the moisture performance of wood frame and massive timber walls. *Buildings*, 11(5), 188. <https://doi.org/10.3390/buildings11050188>
- Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2), 157–166. <https://doi.org/10.1109/72.279181>
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Blanco, M. (2015). IDIS Aprendizaje <https://proyectoidis.org/aprendizaje-automatico/>
- Bonaccorso, G. (2018). *Machine Learning Algorithms* (2 ed.). Packt Publishing Ltd.
- Brady, N., y Weil, R. (2010). *The Nature and Properties of Soils*. 14th Edition. PrenticeHall, Inc. New Jersey. USA
- Bonicatto, M. (2017). *Gestión estratégica planificada (GEP): un método para la gestión en organizaciones públicas*. Editorial de la Universidad Nacional de La Plata (EDULP). <http://sedici.unlp.edu.ar/handle/10915/59454>
- Boo, K. B. W., El-Shafie, A., Othman, F., Khan, M. M. H., Birima, A. H., & Ahmed, A. N. (2024). Groundwater level forecasting with machine learning models: A review. *Water Research*, 252, 121249. <https://doi.org/10.1016/j.watres.2024.121249>
- Breslow, S. J., Karnauskas, M., & Schumann, S. (2022). Broadening environmental governance ontologies to enhance ecosystem-based

- management in Aotearoa New Zealand. *Maritime Studies*, 21(1), 1–20. <https://doi.org/10.1007/s40152-022-00278-x>
- Brown Weiss, E. (1989). In fairness to future generations: International law, common patrimony, and intergenerational equity. Transnational Publishers / United Nations University.
- Cabrejos, J. (2018). Evoluciones del nivel estático y conductividad eléctrica del agua subterránea en el valle Chancay-Lambayeque, periodo 1996-2014. Universidad Nacional Pedro Ruiz Gallo
- California Department of Water Resources. (2016). Mejores prácticas de gestión para la gestión sostenible de las aguas subterráneas: Marco de referencia de las mejores prácticas de gestión. California Department of Water Resources. BMP Framework (PDF)
- Carrillo-Rivera, J. J., Peñuela-Arévalo, L.A., Huízar-Álvarez, R., Cardona-Benavides, A., Ortega-Guerrero, M. A., Vallejo-Barra, J., y Hatch-Kuri, G. (2016). Conflictos por el agua subterránea. En J. O. Moncada Maya y A. López López (coords), *Geografía de México: una reflexión espacial contemporánea* (pp. 1-16). Ciudad de México: Instituto de Geografía, UNAM.
- Casassus, J. (2005). La gestión educativa en América Latina: problemas y paradigmas. En R. Cuenca, E. González y F. Muñoz-Cabrejo (eds.), *La democratización de la gestión educativa: modelos de gestión, procesos de participación y descentralización educativa* (pp. 97-125). ACDI, AECI, DFID, GTZ, USAID.
- Casassus, J. (2009). Marcos conceptuales para el análisis de los cambios en la gestión de los sistemas educativos. En E.-L. Campos-Alba, A.D. González-Martínez, O. Hernández-Rosales, M.R. Esparza-Castro, M.G. Mendizábal-Pérez, J.O. Fuentes López, R. Martín-Domingo, C. Goñi-Carmona, M.Á. Mendoza-Ibáñez y J.C. Cruz
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments for mentioning both. *Geoscientific Model Development*, 7(3), 1247–1250. <https://doi.org/10.5194/gmd-7-1247-2014>

- Chiara, M. y Di-Virgilio, M.M. (2017). Conceptualizando la gestión social. En M. Chiara y M.M. Di-Virgilio (comps.), *Gestión de la política social: conceptos y herramientas* (pp. 53-86). Universidad Nacional de General Sarmiento
- Cho, K., Van Merriënboer, B., Gulcehre, C., et al. (2014). Learning phrase representations using RNN encoder–decoder for statistical machine translation. EMNLP. <https://doi.org/10.3115/v1/D14-1179>
- Congreso de la República del Perú. (2009). Ley de Recursos Hídricos, Ley N.º 29338. Diario Oficial El Peruano. <https://www.gob.pe/institucion/ana/normas-legales/223174-29338>
- Cortés C., F., y Rubalcava, R. Ma. (1983). NOTAS SOBRE COLINEALIDAD EN EL MODELO DE REGRESIÓN LINEAL DE TRES VARIABLES. *Demografía y Economía*, 17(2), 181–198. <http://www.jstor.org/stable/40602348>
- Custodio, E., & Custodio, S. (2021). Sustainable groundwater development and management: Scientific, legal, and policy perspectives. Springer Nature.
- Cuthbert, M. O., Gleeson, T., Bierkens, M. F. P., Ferguson, G., & Taylor, R. G. (2023). *Defining renewable groundwater use and its relevance to sustainable groundwater management*. *Water Resources Research*, 59, e2022WR032831. <https://doi.org/10.1029/2022WR032831>
- Dellot, B., y Balaram, B. (2018). MACHINE LEARNING. *RSA Journal*, 164(3 (5575)), 44–47. <https://www.jstor.org/stable/26798354>
- Di Salvo, C. (2022). *Improving results of existing groundwater numerical models using machine learning techniques: A review*. *Water*, 14(15), 2307. <https://doi.org/10.3390/w14152307>
- Díaz-Ríos, T. A. (2021). La circularidad del agua: modelo de gestión sostenible para la sociedad panameña. *Revista Saberes APUDEP*, 4(2), 1-17. <https://core.ac.uk/download/pdf/487397448.pdf>
- Espinoza Morales, F.; Zallas Esquer, L. y González Velásquez, L. (2023). Gestión administrativa y competitividad en las empresas públicas y privadas. Editorial Fontamara S. A. <https://doi.org/10.47807/UNISON.613>
- FAO. (2021). The State of the World's Land and Water Resources for Food and Agriculture – Systems at breaking point. Food and Agriculture Organization of the United Nations. <https://www.fao.org/publications>

- Farid, H. U., Shah, S. A. H., & Ahmed, W. (2020). Groundwater modelling and prediction using data-driven and numerical models: A review. *Groundwater for Sustainable Development*, 11, 100423. <https://doi.org/10.1016/j.gsd.2020.100423>
- Foster, S., y Cherlet, J. (2014). Why does land–groundwater interaction matter. En Technical Committee (ed.), *The links between land use and groundwater* (pp. 4-9). Estocolmo: Global Water Partnership.
- Gonzales-Paredes, A., Salazar, J., & Chávez, C. (2021). Groundwater salinization and agricultural impacts in coastal Peru: A hydrochemical and geostatistical approach. *Journal of Hydrology: Regional Studies*, 36, 100860. <https://doi.org/10.1016/j.ejrh.2021.100860>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. ISBN: 978-0262035613 <https://virtualmmx.ddns.net/gbooks/DeepLearning.pdf>
- Guillén, J., Jorge Calle García, Gavidia, A., y Vélez, A. (2020). Desarrollo sostenible: desde la mirada de preservación del medio ambiente colombiano. *Revista de Ciencias Sociales*, 26(4), <https://dialnet.unirioja.es/descarga/articulo/7687041.pdf>
- Haji, O. K. (2024). Low-cost, low-power IoT-based system and machine learning model for monitoring and prediction of groundwater quantity (Tesis doctoral, University of Rwanda). <http://dr.ur.ac.rw/handle/123456789/1614>
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer.
- Hernández Juárez, R. A., Martínez Rivera, L. M., Peñuela-Arévalo, L. A., & Rivera-Reyes, S. (2019). Gestión del agua subterránea en los acuíferos de la cuenca del río Ayuquila–Armería en Jalisco y Colima, México. *Región y Sociedad*, 31, e1093. <https://doi.org/10.22198/rys2019/31/1093>
- Hernández, R., Fernández, C. y Baptista, P. (2014). *Metodología de la Investigación*. México: Mc Graw Hill
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts. <https://otexts.com/fpp3/>
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An introduction to statistical learning: With applications in R* (2nd ed.). Springer. <https://doi.org/10.1007/978-1-0716-1418-1>
- Jonas, H. (1984). *The imperative of responsibility: In search of an ethics for the technological age* (D. Herr, Trad.). University of Chicago Press. (Obra original publicada en 1979).
- Kaaronen, R. O., & Ståhle, P. (2020). Towards a relational paradigm in sustainability research, practice, and education. *Ambio*, 49(6), 1195–1205. <https://doi.org/10.1007/s13280-020-01322-y>
- Kandasamy, J., Savić, D. A., & Hipel, K. W. (2022). Transdisciplinary approaches to sustainable water management: A review. *Journal of Hydrology*, 605, 127312. <https://doi.org/10.1016/j.jhydrol.2021.127312>
- Kendig, C. (2024). Human-Managed Soils and Soil-Managed Humans: An Interactive Account of Perspectival Realism for Soil Management. *Journal of Social Ontology*, 10(2). <https://doi.org/10.25365/jso-2024-7690>
- Kratzert, F., Klotz, D., Herrnegger, M., Sampson, A. K., Hochreiter, S., & Nearing, G. S. (2021). Towards learning universal, regional, and local hydrological behaviors via machine learning applied to large-sample datasets. *Hydrology and Earth System Sciences*, 23, 5089–5110. <https://doi.org/10.5194/hess-23-5089-2019>
- Larose, D. T., y Larose, C. D. (2014). *Discovering knowledge in data: An Introduction to Data Mining*. (2 ed.). Wiley
- Liu, J., Song, X., Zhou, Y., Peng, X., Zhang, Y., Liu, P., Zhu, C. (2022). Deep anomaly detection in packet payload. <https://doi.org/10.1016/j.neucom.2021.01.146>
- Leopold, A. (1949). *A Sand County almanac, and sketches here and there*. Oxford University Press.
- López-Gunn, E., & Mejía-Betancourt, D. (2020). Adaptive water management in times of change: Climate variability and governance in water-scarce regions. *Water*, 12(6), 1706. <https://doi.org/10.3390/w12061706>
- Martínez, F., Frías, M. P., Pérez, M. D., & Rivera, A. J. (2019). A methodology for applying k-nearest neighbor to time series forecasting. *Artificial*

- Intelligence Review, 52, 2019–2037. <https://doi.org/10.1007/s10462-017-9593-z>
- Mendoza-Fernández, V. M., & Moreira-Chóez, J. S. (2021). Procesos de Gestión Administrativa, un recorrido desde su origen. *Revista Científica FIPCAEC (Fomento De La investigación Y publicación científico-técnica multidisciplinaria)*. 6(3), 608-620. <https://doi.org/10.23857/fipcaec.v6i3.414>
- Morales Inga, J. I. (2018). Afectación del derecho al agua por la no reutilización de las aguas residuales de la actividad minera, según el art. 82 de la Ley de Recursos Hídricos–Ley N° 29338. <https://repositorio.ucv.edu.pe/handle/20.500.12692/44716>
- Morales, J., Lazo, J., & Fernández, R. (2021). Effect of irrigation water quality on soil alkalinity and crop yield in arid zones of South America. *Agricultural Water Management*, 252, 106877. <https://doi.org/10.1016/j.agwat.2021.106877>
- Narváez, M.; Gutiérrez, C. y Senior, A. (2011). Gestión organizacional: una aproximación a su estudio desde el paradigma de la complejidad. *Revista Venezolana de Análisis de Coyuntura*, 17(2), 27-48. <https://www.redalyc.org/articulo.oa?id=36422801003>
- Nazari, A., Jamshidi, M., Roozbahani, A., & Golparvar, B. (2025). Predicción del nivel freático mediante descomposición modal empírica y redes de memoria a corto y largo plazo (LSTM) basadas en ondículas. *Aguas subterráneas para el desarrollo sostenible*. 28, 101397. <https://doi.org/10.1016/j.gsd.2024.101397>
- Núñez, E., Steyerberg, E. W., y Núñez, J. (2011). Estrategias para la elaboración de modelos estadísticos de regresión. *Revista Española de Cardiología*, 64(6), 501-507. <https://doi.org/10.1016/j.recesp.2011.01.019>
- Pacheco, J.C., Castañeda, W. y Caicedo, C.H. (2002). Indicadores integrales de gestión (R. García-Mandariaga y M.E. Villa-Camacho, revs.). McGraw-Hill Interamericana, Corporación Investigación Social Contemporánea (CIS, Colombia).
- Parisi F., A., Parisi F., F., y Guerrero C., J. L. (2003). MODELOS PREDICTIVOS DE REDES NEURONALES EN ÍNDICES BURSÁTILES. *El Trimestre Económico*, 70(280(4)), 721–744. <http://www.jstor.org/stable/20856798>

- Pineda, J. M. (2022). Modelos predictivos en salud basados en aprendizaje de maquina (machine learning). *Revista Médica Clínica Las Condes*, 33(6), 583-590. <https://doi.org/10.1016/j.rmclc.2022.11.002>
- Pousada, M. (2021). Aplicación de algoritmos predictivos para la eficiencia en la gestión del riego. Uoc.edu. <http://hdl.handle.net/10609/126626>
- Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N., & Prabhat. (2019). Deep learning and process understanding for data-driven Earth system science. *Nature*, 566(7743), 195–204. <https://doi.org/10.1038/s41586-019-0912-1>
- Rodríguez-Hernández, M. Á., García-Santos, I., & Delgado, J. A. (2021). Improving groundwater monitoring networks in vulnerable areas using multi-criteria analysis. *Water*, 13(3), 355. <https://doi.org/10.3390/w13030355>
- Ropa-Carrión, B., & Alama-Flores, M. (2022). Gestión organizacional: un análisis teórico para la acción. *Revista Científica de la UCSA*, 9(1), 81-103.
- Rousell, D., & Tran, J. (2024). Thinking with Forests as Sentient Societies: Towards a Pedagogy and Ethic of Immanent Care. *Australian Journal of Environmental Education*, 40(2), 258–275. <https://doi.org/10.1017/aee.2024.15>
- Senlle, A. (2001). ISO 9000-2000: liderazgo de la nueva calidad. *Gestión 2000. Revista Científica de la UCSA*, Vol.9 N.º1 abril, 2022: 81-103
- Shen, C. (2018). A transdisciplinary review of deep learning in water resources sciences. *Water Resources Research*, 54(11), 8565–8598. <https://doi.org/10.1029/2018WR022643>
- Shortridge, J. E., Guikema, S. D., & Zaitchik, B. F. (2021). Machine learning methods for hydrologic and water resources modeling: A survey of the current state of the art. *Journal of Hydrology*, 600, 126593. <https://doi.org/10.1016/j.jhydrol.2021.126593>
- Srinivas, M., Sucharitha, G., y Matta, A. (2021). *Machine Learning Algorithms and Applications*. Scrivener Publishing LLC.
- Sun, J., Li, Y., & Wang, J. (2022). Deep learning for groundwater level prediction: A review and comparative study. *Water*, 14(15), 2341. <https://doi.org/10.3390/w14152341>

- Tao, H., Hameed, M. M., Marhoon, H. A., Zounemat-Kermani, M., Salih, S. Q., Al-Ansari, N., & Yaseen, Z. M. (2022). *Groundwater level prediction using machine learning models: A comprehensive review*. *Neurocomputing*, 489, 271–308. <https://doi.org/10.1016/j.neucom.2022.03.014>
- Torres-Valdivieso, S. y Mejía-Villa, A.H. (2006). Una visión contemporánea del concepto de administración: revisión del contexto colombiano. *Cuadernos de Administración*, 19(32), 111-133. https://revistas.javeriana.edu.co/index.php/cuadernos_admon/article/view/4307
- U.S. Geological Survey. (s. f.). Red Nacional de Monitoreo de Aguas Subterráneas: Métodos estadísticos. <https://www.usgs.gov/apps/ngwmn/provider/statistics-methods/>
- UNESCO. (2005). The Precautionary Principle: World Commission on the Ethics of Scientific Knowledge and Technology (COMEST). UNESCO.
- UNESCO (2020). Informe mundial de las Naciones Unidas sobre el desarrollo de los recursos hídricos 2020: agua y cambio climático, datos y cifras. Unesco.org. https://unesdoc.unesco.org/ark:/48223/pf0000372876_spa
- Valderrama A., Castillo O., y Flores H. (2019). Huella hídrica manufacturera. Una comparación entre países ricos y pobres. *Análisis Económico*, vol. XXXV, núm. 88, enero-abril de 2020, pp.69-88.
- 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/srjcid.v1i1.46>
- Von Bertalanffy, L. (1968). *General system theory: Foundations, development, applications*. George Braziller.
- Wang, Y., Li, X., Zhang, H., & Chen, J. (2023). Hybrid forecasting model based on EEMD and deep learning for complex time series prediction. *Expert Systems with Applications*, 213, 119032. <https://doi.org/10.1016/j.eswa.2022.119032>
- Wu, C., Li, Y., Wang, Y., & Qiu, J. (2021). Groundwater level modeling framework by combining the wavelet transform with a long short-term memory data-driven model. *Science of the Total Environment*, 783, 146948. <https://doi.org/10.1016/j.scitotenv.2021.146948>

- Wunsch, A., Liesch, T., & Broda, S. (2021). Predicción del nivel freático con redes neuronales artificiales: una comparación de LSTM, CNN y NARX. *Hydrology and Earth System Sciences*, 25, 1671–1687. <https://doi.org/10.5194/hess-25-1671-2021>
- Xiang, Z., Demir, I., & Sermet, Y. (2020). Long short-term memory neural networks for groundwater level prediction. *Journal of Hydrology*, 590, 125243. <https://doi.org/10.1016/j.jhydrol.2020.125243>
- Xu, Q., Chen, S., & Wang, Y. (2021). Random forest-based models for environmental time series forecasting. *Environmental Modelling & Software*, 143, 105005. <https://doi.org/10.1016/j.envsoft.2021.105005>
- Yang, X., & Zhang, Z. (2022). A CNN–LSTM model based on a meta-learning algorithm for predicting groundwater level in the middle and lower reaches of the Heihe River, China. *Water*, 14(15), 2377. <https://doi.org/10.3390/w14152377>
- Yaseen, Z. M., Ghareb, M. I., Ebtehaj, I., Bonakdari, H., Siddique, R., Heddami, S., & Deo, R. C. (2023). *Revolutionizing groundwater management with hybrid AI models: A practical review*. *Water*, 15(9), 1750. <https://doi.org/10.3390/w15091750>
- Zhang, J., Liu, D., & Jiang, Q. (2023). Prediction of groundwater depth based on wavelet decomposition and long short-term memory (LSTM). *International Journal of Environment and Climate Change*, 13(11), 3823–3837. <https://doi.org/10.9734/IJECC/2023/v13i113562>

ANEXOS

Anexo 1: Guía de entrevista

Guía de entrevista para medir la Gestión Administrativa

Estimado/a participante:

La información recopilada será anónima, tratada de forma confidencial y tiene una finalidad netamente académica. Por tanto, en forma voluntaria; SÍ () NO () doy mi consentimiento para participar en la investigación que tiene como título Modelo predictivo de aprendizaje máquina, para la gestión del agua de fuente subterránea en el valle Chancay Lambayeque, Asimismo, autorizo para que los resultados de la presente investigación se publiquen manteniendo mi anonimato.

Instrucciones: La entrevista consta de 6 preguntas. Por favor, responda cada una de ellas según su experiencia.

1. ¿Cómo es se realiza la planificación de las aguas subterráneas en el Valle Chancay Lambayeque?
2. ¿Con las actividades actuales se está obteniendo las metas esperadas en referencia a las actividades planificadas?
3. ¿La Organización, tiene los recursos necesarios para una adecuada gestión en el uso de las aguas subterráneas en el Valle Chancay Lambayeque?
4. ¿La toma de Decisiones es eficiente en la ejecución de las actividades de gestión del uso del agua subterránea en el Valle Chancay Lambayeque?
5. ¿La Organización, que es lo que está realizando para un buen control y monitoreo en los inventarios de los pozos de agua subterránea?
6. ¿Desde su punto de vista, cuál es su percepción del nivel de control y monitoreo de las aguas subterráneas en el Valle Chancay Lambayeque?

¡Muchas gracias por su participación!

Anexo 2: Data histórica pre procesada

ID	DISTRITO	ZONA	Dic-96	Jul-97	Dic-98	Mar-99	Oct-99	Dic-99	May-00	Sep-00	Dic-00	Mar-01	Set-01	Dic-01	Abr-02	Set-02	Dic-02	Mar-03	Set-03	Dic-03	Set-04	Abr-05	Oct-05	Abr-06	Oct-06	Abr-07	Oct-07	Abr-08	Nov-09	May-10	Set-10	Dic-11	Jun-12	Nov-12	Abr-13	Nov-13	May-14	Oct-14	May-15	Nov-15	May-16	Nov-16	Jun-17	Nov-17	Jun-18	Jun-19	Oct-19	Nov-20	Jun-21	Jun-22	Jun-23	Nov-23
I-39	PUCALA	I	3.15	3.77	3.52	2.94	3.77	4.36	2.95	3.75	3.65	2.33	3.80	4.05	2.25	3.40	3.30	NaN	4.15	3.70	3.85	3.22	3.75	2.83	3.61	4.15	4.15	3.10	3.98	3.85	4.40	7.40	6.70	8.00	3.60	3.65	NaN	3.65	NaN	3.50	2.80	2.95	4.10	3.80	3.62	3.81	2.20	2.00	2.75	2.88	2.75	3.00
I-9	PATAPO	I	6.10	4.75	3.73	1.71	4.03	3.32	3.19	NaN	4.29	0.42	3.84	4.12	2.30	3.50	NaN	3.20	3.73	3.53	4.15	2.25	4.60	2.20	4.57	2.65	2.60	2.26	2.65	2.27	4.37	6.67	3.80	3.80	2.00	6.70	4.20	7.90	5.01	3.55	2.63	4.45	3.45	3.36	3.22	3.14	4.38	4.80	3.40	2.90	3.00	3.00
I-11	PATAPO	I	3.84	3.80	2.25	2.67	2.32	2.49	13.20	2.50	2.90	2.88	2.01	2.77	2.10	2.33	NaN	2.30	3.84	3.84	3.48	2.75	1.92	1.51	2.21	3.10	2.78	2.10	1.04	2.25	2.25	3.13	4.10	4.10	1.80	1.90	1.72	1.80	1.80	2.00	1.90	2.00	2.10	2.10	1.95	1.94	3.40	3.47	2.96	2.88	3.20	3.30
I-67	TUMAN	I	5.50	8.85	5.86	8.18	2.44	2.18	4.50	3.80	4.05	6.19	5.00	3.54	5.70	5.15	NaN	4.70	5.70	5.70	8.56	6.99	9.93	6.20	6.76	6.01	6.68	3.30	4.50	4.15	5.90	9.23	5.00	5.00	NaN	5.45	4.80	5.50	4.10	5.37	4.60	4.90	4.88	4.70	3.77	3.66	2.32	2.32	3.60	2.60	8.97	8.81
II-19	CHICLAYO	II	2.60	1.88	3.19	0.84	3.46	3.00	2.15	3.60	2.30	1.80	3.01	2.43	NaN	2.55	3.85	2.40	2.55	2.55	2.60	NaN	2.21	0.19	2.05	NaN	2.06	1.60	2.06	1.02	1.96	3.27	2.77	2.77	NaN	2.70	2.70	2.78	2.65	2.78	2.60	2.89	2.77	2.72	2.65	2.75	2.90	3.38	3.40	3.06	1.30	1.45
II-32	PIMENTEL	II	1.70	1.95	3.88	0.24	2.21	1.44	0.80	2.00	3.75	3.05	2.20	1.44	0.70	2.06	1.28	1.11	14.66	2.04	1.80	NaN	2.30	0.50	2.57	0.74	2.58	1.65	2.20	1.20	2.40	3.60	1.80	1.80	NaN	3.10	3.15	3.15	1.65	3.20	1.80	2.80	1.00	1.25	1.53	1.48	4.20	4.52	2.46	2.26	1.30	1.40
II-58	PIMENTEL	II	0.60	2.35	2.39	0.28	2.06	0.99	0.40	1.55	1.90	1.60	2.20	1.78	0.58	1.49	0.95	1.10	3.10	1.00	2.10	NaN	1.10	0.20	0.98	NaN	1.18	NaN	1.10	0.30	1.00	NaN	0.69	0.69	0.60	1.17	1.30	NaN	0.35	1.30	0.80	1.32	NaN	1.20	0.90	0.87	1.54	1.81	3.15	3.48	2.10	2.00
II-49	POMALCA	II	2.50	6.50	1.89	3.05	1.26	2.50	2.89	2.39	2.64	0.58	2.39	2.16	0.75	2.17	3.01	2.30	2.50	2.77	3.09	5.18	6.37	6.61	7.00	6.95	6.20	7.85	NaN	2.50	2.96	2.60	1.98	NaN	1.02	NaN	NaN	4.04	3.45	3.78	3.67	3.48	3.67	3.55	7.08	6.92	9.32	9.06	7.12	6.92	0.70	0.75
III-16	FERREÑAFE	III	4.30	4.00	4.81	3.44	4.26	4.22	3.52	3.72	4.42	3.16	4.95	4.48	3.20	4.15	2.40	0.35	4.27	4.27	2.30	2.20	4.54	3.28	4.29	3.21	3.25	3.00	3.25	0.84	3.40	4.80	4.06	4.10	3.55	3.85	3.20	3.90	3.40	3.90	NaN	1.40	1.30	NaN	2.96	3.2	3.95	4.24	2.80	2.88	3.80	4.20
III-8	LAMBAYEQUE	III	1.55	3.00	3.76	3.19	3.29	3.19	3.05	3.00	2.80	1.85	2.17	2.37	2.05	2.25	0.96	1.90	2.30	2.30	2.65	2.70	2.60	2.52	2.96	2.54	2.76	2.29	2.20	2.06	2.30	4.90	1.30	1.16	2.45	3.65	3.30	NaN	3.45	2.55	2.60	2.57	2.35	2.95	2.40	2.5	3.10	3.55	2.65	2.77	3.35	3.65
III-10	LAMBAYEQUE	III	2.00	2.50	1.85	1.66	2.83	2.60	2.20	2.40	2.70	2.15	2.54	2.48	1.65	2.43	2.94	0.30	2.75	2.75	3.25	2.01	2.90	1.80	2.50	1.63	2.65	1.60	2.56	1.65	2.30	3.40	2.40	2.40	2.00	2.59	1.95	3.20	1.80	2.70	1.90	3.20	1.90	3.05	2.06	2.5	3.20	3.30	1.60	2.60	2.90	3.40
III-28	LAMBAYEQUE	III	1.20	1.55	1.39	0.72	1.62	1.59	1.08	1.43	0.98	0.70	1.48	0.72	0.80	1.35	1.31	0.76	1.20	1.80	1.35	1.41	1.90	1.58	1.78	1.65	1.68	1.51	1.70	0.60	1.64	1.90	3.33	3.31	1.07	NaN	1.07	2.22	1.26	1.56	1.32	1.34	1.22	2.12	1.25	1.44	1.72	1.72	1.42	1.38	1.48	2.02
III-36	LAMBAYEQUE	III	1.93	2.15	3.67	1.20	1.86	0.86	1.30	1.60	1.40	0.30	1.51	1.32	0.35	1.54	1.69	0.37	2.05	2.05	1.70	0.52	2.30	0.40	2.30	NaN	2.46	0.40	2.42	1.30	1.60	2.90	1.20	1.20	0.50	1.65	0.55	NaN	0.50	1.93	1.12	1.63	0.82	1.90	1.20	1.2	1.56	2.30	1.34	1.60	1.28	1.40
III-67	LAMBAYEQUE	III	1.20	1.63	2.67	1.32	2.40	0.93	0.94	2.29	2.99	0.99	1.07	2.74	0.46	2.15	2.75	NaN	2.52	2.52	1.74	NaN	2.38	0.15	2.15	NaN	2.06	0.15	2.13	2.90	1.83	1.95	2.90	2.92	0.03	1.73	0.10	1.30	0.20	1.85	NaN	1.80	0.14	0.46	1.08	1.2	2.02	2.10	1.10	1.30	0.94	1.20
III-11	MESONES MURO	III	2.30	2.30	5.11	4.70	4.78	2.59	4.68	4.98	2.38	4.75	2.31	3.40	4.60	4.83	5.41	4.75	5.87	5.87	6.20	5.84	6.28	5.71	5.87	5.57	6.06	5.47	2.53	6.45	1.36	4.10	6.30	6.40	NaN	6.38	6.50	6.90	6.45	7.50	6.60	7.35	6.25	6.40	6.20	7.32	7.12	8.40	6.77	6.98	7.15	8.20
IV-3	MOCHUMI	IV	2.95	2.20	1.77	0.99	1.60	1.57	0.15	1.65	1.75	0.45	1.58	1.80	0.44	1.33	2.27	0.48	1.86	1.86	4.00	1.14	2.35	1.55	1.20	1.79	2.28	1.05	2.33	0.75	1.55	0.60	1.45	2.15	1.42	1.54	0.65	1.25	0.95	0.95	0.40	1.95	1.20	1.65	1.25	1.47	1.78	2.01	1.43	1.55	1.15	4.40
IV-9	MOCHUMI	IV	1.80	1.30	1.80	1.02	1.45	0.80	1.30	2.10	2.20	0.40	1.95	1.77	0.45	1.60	1.55	0.60	2.15	2.05	1.85	0.00	1.94	0.04	1.40	0.05	1.91	0.40	1.64	1.14	1.60	2.14	2.50	1.95	1.05	1.63	0.15	1.85	0.20	1.84	NaN	1.95	0.94	1.80	1.02	1.02	NaN	2.42	0.40	0.54	0.20	NaN
IV-17	TUCUME	IV	1.90	1.75	2.28	0.14	1.62	1.54	1.20	1.45	1.90	0.75	1.23	1.85	0.64	1.03	1.42	0.56	2.25	2.25	2.76	1.30	2.70	1.07	2.24	0.95	1.60	0.96	1.60	1.22	2.66	2.40	2.54	1.93	0.62	2.10	1.08	2.63	0.87	2.58	1.58	2.83	1.28	2.21	1.68	1.72	3.33	3.78	2.28	2.42	2.38	3.28
IV-73	TUCUME	IV	1.20	1.50	2.50	0.78	1.64	1.06	1.30	1.10	2.00	0.65	1.37	1.78	0.87	0.90	1.80	0.64	2.47	2.47	1.90	0.80	2.32	0.75	2.00	0.48	2.19	0.57	2.03	1.42	2.40	2.55	1.95	2.25	0.67	1.75	0.95	NaN	0.90	1.85	2.10	2.20	1.20	1.95	1.26	1.27	2.05	2.54	0.95	1.16	1.42	2.25
IV-80	TUCUME	IV	0.80	1.20	1.87	0.66	1.48	0.85	0.70	1.05	1.80	0.75	1.56	1.10	0.30	1.42	3.37	0.26	2.01	2.01	1.80	0.00	1.93	0.37	1.60	0.35	1.83	0.30	1.85	0.60	1.57	1.73	2.73	1.90	0.18	1.61	0.15	2.00	0.32	1.90	0.75	2.10	0.94	1.80	0.90	1.04	1.75	2.13	0.72	0.80	1.30	2.20
IV-86	TUCUME	IV	1.60	1.80	2.45	0.66	1.76	1.82	1.19	1.34	2.04	0.25	1.41	2.02	0.30	1.45	1.90	0.35	1.90	1.90	2.16	0.40	2.19	0.60	2.15	0.05	2.20	0.50	2.08	1.00	2.85	2.27	3.18	2.00	0.30	1.82	0.50	2.10	0.36	1.90	1.10	2.20	1.40	2.00	1.30	1.3	2.13	2.30	1.10	1.40	1.50	1.90
IV-15	PITIPO	IV	2.84	2.95	1.40	1.70	2.49	1.57	1.70	1.80	2.40	1.37	2.51	1.45	1.16	2.23	1.99	0.70	2.87	2.90	2.14	0.95	2.20	0.58	1.85	0.82	2.11	0.50	2.28	1.05	1.73	2.55	2.18	2.20	2.17	2.19	1.20	2.22	1.70	2.26	NaN	2.44	1.34	1.40	1.32	1.55	2.24	2.32	1.45	1.50	1.70	2.40

Anexo 3: Medición del nivel estático en pozos con número de inventario de recursos hídricos (I.R.H.S.) 79 y 53

