



**CENTRO DE INVESTIGACIÓN EN
CIENCIAS DE INFORMACIÓN GEOESPACIAL, A.C.**

CentroGeo

Centro Público de Investigación SECIHTI

Red Neuronal Convolucional Recurrente para la predicción
del almacenamiento de agua subterránea en áreas
de sistemas acuíferos de México, en función de variables climáticas.

TESIS

Que para obtener el grado de
Doctora en Ciencias de Información Geoespacial

Presenta

Aura Ramos Lora

Directora de Tesis:

Dra. Daniela Alejandra Moctezuma Ochoa

**CENTRO DE INVESTIGACIÓN EN
CIENCIAS DE INFORMACIÓN GEOESPACIAL, A.C.**

CentroGeo

Centro Público de Investigación SECIHTI

Red Neuronal Convolutiva Recurrente para la predicción
del almacenamiento de agua subterránea en áreas
de sistemas acuíferos de México, en función de variables climáticas.

TESIS

Que para obtener el grado de
Doctora en Ciencias de Información Geoespacial

Presenta

Aura Ramos Lora

Directora de Tesis:

Dra. Daniela Alejandra Moctezuma
Ochoa

Sinodales:

Dra. Tania Ramírez de Real
Dr. José Miguel Salazar Montiel

CoDirector de Tesis:

Dr. Cesaré Moisés Ovando Vázquez

Examinador Externo:

Dr. Eric Sadit Téllez Ávila

Abril, 2025

Dedicatorias

***A mi madre,** pilar de fortaleza,
consuelo y amor incondicional en la vida.*

***† A mi esposo,** quien me brindó su amor eterno
y me motivó para emprender este proyecto.*

***A mi universo finito,**
mis hijos Diego y Esteban.*

***A mis amigos,** cuyo apoyo y
aceptación constante enriquecen mi camino.*

Reconocimientos

Expreso mi más sincero agradecimiento a mi directora de tesis, la Dra. Daniela Alejandra Moctezuma Ochoa, por su profesionalismo y apoyo incondicional. Su creencia en la viabilidad de esta investigación, su guía constante y motivación fueron esenciales para llevar a cabo y culminar este trabajo.

Mi gratitud también al Dr. Cesaré Moisés Ovando Vázquez, mi codirector de tesis, quien ha mostrado una paciencia excepcional al revisar mis modelos de inteligencia artificial y su contribución significativa a los detalles técnicos de mi investigación.

Un reconocimiento especial al Dr. Guadalupe Ibarra Olivares, Doctor en Ciencia y Tecnología del Agua, y al Dr. Hiram Abif Meza Landero, Doctor en Meteorología, por sus enseñanzas esenciales en sus respectivas especialidades, que guiaron mi comprensión del marco teórico.

Agradezco al comité evaluador por sus valiosas observaciones y sugerencias, las cuales han enriquecido considerablemente este documento final. Su profesionalismo y experiencia fueron clave para aportar valor a este proyecto.

Mi reconocimiento al Instituto Potosino de Investigación Científica y Tecnológica (IPICYT) por brindarme la oportunidad de cursar el diplomado en Inteligencia Artificial. Este programa fue fundamental para el desarrollo del modelo empleado en esta investigación.

Finalmente, agradezco a la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI) y a los directivos del Servicio Geológico Mexicano, por la oportunidad brindada para cursar este Doctorado en Ciencias de Información Geoespacial. Su respaldo fue indispensable para mi formación académica y profesional.

Este documento se benefició del uso de herramientas tecnológicas avanzadas bajo licencia, incluyendo ChatGPT de OpenAI y Overleaf con asistencia de inteligencia artificial, que facilitaron la redacción, revisión ortográfica, fluidez y organización del texto.

Resumen

El agua subterránea es un recurso esencial para el consumo humano, la agricultura y la industria, tanto en México como en todo el mundo. Determinar su almacenamiento y volumen aproximado es crucial, especialmente en áreas donde la falta de información impide el uso de métodos tradicionales. En México, las mediciones del nivel de agua subterránea, aunque ampliamente utilizadas en estudios hidrológicos, son insuficientes para ofrecer una estimación cuantitativa sobre el vital recurso.

Esta falta de datos precisos y accesibles motivó la presente investigación a explorar alternativas en el campo de la teledetección y las ciencias climáticas. Se identificaron variables que cuantifican el almacenamiento de agua subterránea y variables meteorológicas que podrían ayudar a predecirla. Los repositorios de imágenes, que cuentan con registros históricos de al menos 20 años, ofrecen un gran volumen de datos que puede aprovecharse mediante modelos de inteligencia artificial, cumpliendo con la premisa de que la abundancia de datos es esencial para el aprendizaje automático.

Hoy en día, la inteligencia artificial y las redes neuronales profundas han sido utilizadas exitosamente en múltiples campos, cambiando positivamente la vida de las personas. Sin embargo, aún existe un amplio margen para proponer y explorar los beneficios de estas tecnologías en México. A pesar de nuestro rezago en datos hidrogeológicos históricos de campo, la combinación de inteligencia artificial con avances tecnológicos podría compensar esta deficiencia y ofrecer soluciones para la gestión del agua.

En este estudio, se probaron cinco arquitecturas de inteligencia artificial utilizando inicialmente tres tipos distintos de variables climáticas para predecir el Almacenamiento de Agua Subterránea (GWS, por sus siglas en inglés). Estas arquitecturas lograron captar las tendencias del GWS, obteniendo en su mayoría correlaciones por encima del 90 %. Las Redes Neuronales Convolucionales Recurrentes (CRNN), en particular, integraron múltiples variables de evaporación y aprendieron de la secuencia temporal de sus características geográficas para lograr una estimación muy aproximada del GWS. Los resultados fueron validados contra un conjunto de datos de prueba reservado para este fin.

Este enfoque no solo proporciona una solución a la escasez de datos convencionales, sino que también ofrece una herramienta replicable para la gestión y planificación de recursos hídricos en regiones del país donde la falta de información ha impactado negativamente la administración sostenible de los acuíferos.

Abstract

Groundwater is an essential resource for human consumption, agriculture, and industry in Mexico and worldwide. Determining its storage and approximate volume is crucial, especially in areas where the lack of information prevents the use of traditional methods. In Mexico, while groundwater level measurements are widely used in hydrological studies, they are insufficient to provide a quantitative estimate of this vital resource.

The lack of precise and accessible data prompted this research to explore alternatives in the field of remote sensing and climate sciences. Variables quantifying groundwater storage and meteorological variables that could help predict it were identified. Image repositories, with historical records spanning at least 20 years, provide a vast volume of data that can be leveraged using artificial intelligence models, meeting the premise that data abundance is essential for machine learning.

Today, artificial intelligence and deep neural networks have been successfully utilized in many fields, positively changing people's lives. However, there is still significant scope to propose and explore the benefits of these technologies in Mexico. Despite our lag in historical field data, the combination of artificial intelligence with technological advancements could compensate for this shortfall and provide solutions for water management.

In this study, five AI architectures were tested using initially three different types of climate variables to predict Ground Water Storage (GWS). These architectures successfully captured the trends in GWS, achieving correlations above 90 % in most cases. Convolutional Recurrent Neural Networks (CRNN), in particular, integrated multiple evaporation variables and learned from the temporal sequence of their geographical features to achieve an accurate estimation of GWS. The results were validated against a reserved test dataset for this purpose.

This approach not only provides a solution to the shortage of conventional data, but also offers a replicable tool for managing and planning water resources in regions of the country where the lack of information has negatively impacted the sustainable management of aquifers.

Índice General

Dedicatorias	I
Reconocimientos	II
Resumen	IV
Índice de Figuras	VIII
Índice de Tablas	XIX
1 Introducción	1
1.1 Planteamiento del problema	3
1.2 Objetivo	4
1.3 Justificación	4
1.4 Alcances y Limitaciones	5
1.5 Estructura del documento	5
2 Marco Teórico	6
2.1 La Hidrología en la era del Aprendizaje Profundo	6
2.2 Área de estudio	9
2.3 Recopilación de datos	12
2.3.1 Datos ERA	13
2.3.2 Datos CHIRPS	14
2.3.3 Datos GLEAM	14
2.3.4 Datos GRACE	15
2.3.4.1 De la gravedad terrestre a la estimación del almacenamiento de agua subterránea	17
2.3.4.2 Conversión del almacenamiento al volumen de agua subterránea.	18
2.4 Métodos de Inteligencia Artificial (IA)	21
2.4.1 Multilayer Perceptron (MLP)	22
2.4.2 Random Forest (RF)	30
2.4.3 Convolutional Neural Networks (CNN)	31
2.4.4 Long Short-Term Memory (LSTM)	38
2.4.5 Convolutional Recurrent Neural Network (CRNN)	43
2.5 Trabajos relacionados	43
3 Metodología	48
3.1 Exploración de datos	49
3.1.1 Selección espacial y temporal	49
3.1.2 División del conjunto de datos para entrenamiento, validación y prueba del modelo	55

3.1.3	Normalización de los conjuntos de datos	56
3.2	MLP para estimar el GWS	57
3.2.1	MLP para estimar el GWS con Temperatura	58
3.2.2	MLP para estimar el GWS con Precipitación	59
3.2.3	MLP para estimar el GWS con Evaporación	60
3.3	RFR para estimar GWS	61
3.4	CNN para estimar el GWS	64
3.5	LSTM para estimar el GWS	66
3.6	CRNN para estimar el GWS	69
4	Resultados y análisis	73
4.1	MLP para estimar el GWS con Temperatura	74
4.2	MLP para estimar el GWS con Precipitación	76
4.3	MLP para estimar el GWS con Evaporación	77
4.4	RFR para obtener las variables predictoras	80
4.5	CNN para estimar el GWS	81
4.6	LSTM para estimar el GWS	82
4.7	CRNN para estimar el GWS	84
4.8	Análisis de los resultados	88
5	Conclusiones	96
5.1	Trabajos futuros	97
	Referencias	98

Índice de Figuras

1.1.1	Mapa de los acuíferos de México y Estados Unidos, elaborado a partir de los límites vectoriales disponibles en las bases de datos de la Comisión Nacional del Agua (CONAGUA, 1960) y el gobierno de Estados Unidos (USDATA.GOV, 2020). El mapa muestra 653 polígonos en México y 60 en Estados Unidos, reflejando las diferencias en los criterios de demarcación utilizados en cada país.	4
2.1.1	Variables de entrada más utilizadas en modelos de IA para la predicción del nivel de agua subterránea (IA-GWL), basadas en el estudio de (Taher y cols., 2019) . . .	7
2.2.1	Delimitación del área de estudio correspondiente al acuífero Conejos-Médanos. Mapa vectorial basado en datos de (CONAGUA, 2023).	10
2.3.1	Descripción del archivo NetCDF generado por ERA5, mostrando dimensiones, coordenadas y variables de datos relevantes. Datos leídos y visualizados utilizando la librería xarray en Python.	13
2.3.4.1	Imagen de la NASA que muestra las dos naves espaciales del proyecto GRACE-FO orbitando sobre la Tierra. Fuente: (GRACE-FO, 2024).	16
2.3.4.2	Representación gráfica de cómo la misión GRACE mide las variaciones en la gravedad terrestre. Fuente: (NASA, 2024).	16
2.3.4.1.1	Representación de cómo la misión GRACE mide cambios en el almacenamiento de agua terrestre, incluyendo agua superficial, nieve, humedad del suelo y aguas subterráneas. <i>Copyright 2016 California Institute of Technology. Patrocinio gubernamental reconocido.</i> Fuente: (ARSET, 2020).	17
2.3.4.2.1	Ráster del área de estudio mostrando la distribución espacial del Almacenamiento de Agua Subterránea (GWS) el día 2019-09-02, en una cuadrícula de 6×6 . Cada píxel está etiquetado con los valores de GWS, representados mediante una escala de grises donde los tonos más claros indican menor GWS y los más oscuros, mayor GWS. Las coordenadas en el eje X corresponden a la longitud y en el eje Y a la latitud.	19
2.4.1.1	Diagrama de un perceptrón, el núcleo de construcción fundamental de las redes neuronales. Los inputs X_1, X_2, X_3 son sumados ponderadamente junto con un sesgo b en la función de suma. El resultado es luego pasado a través de una función de activación f , produciendo la salida Y_{pred}	23
2.4.1.2	Estructura de una red neuronal artificial multicapa utilizada para predecir la temperatura basada en tres variables de entrada: temperatura mínima (X_1), temperatura media (X_2), y temperatura máxima (X_3). La red contiene dos capas ocultas (H_1 y H_2), cada una con 100 neuronas, indicando el proceso de transformación de datos a través de conexiones ponderadas (w_i) antes de llegar a la capa de salida. .	24

2.4.1.3	Diagrama de una red neuronal artificial que ilustra el proceso de transformación de la señal a través de la red. Las entradas X_1, X_2, X_3 son combinadas en una función suma ponderada por sus respectivos pesos W_1, W_2, W_3 y un sesgo b , cuyo resultado se pasa a través de una función de activación sigmoideal, $g(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$, para cada neurona en la capa oculta. Los resultados activados son luego sumados en la capa de salida para producir la señal final. Este modelo visualiza el flujo de datos y la transformación a lo largo de la red, destacando las operaciones clave en cada paso.	24
2.4.1.4	Función tangente hiperbólica, esta función transforma los valores de entrada en un rango entre -1 y 1, lo que ayuda a modelar decisiones no lineales en las neuronas artificiales.	25
2.4.1.5	Función de activación comúnmente usada en redes neuronales profundas. La ReLU activa una neurona solo cuando la entrada es positiva, lo que la hace eficiente para aumentar la no linealidad de los modelos sin afectar los valores de activación positivos.	26
2.4.2.1	Estructura de un Bosque Aleatorio aplicado a la predicción del clima, donde cada árbol se caracteriza por nodos que siempre se bifurcan en dos ramas. Esta representación muestra la importancia relativa de diferentes variables como precipitación, temperatura, evaporación, humedad y nieve. Las barras indican la influencia de cada variable, con valores más altos señalando una mayor contribución a la precisión del modelo.	30
2.4.3.1	Diagrama de la estructura básica de una Red Neuronal Convolutiva (CNN). Comienza con la capa de entrada que procesa las imágenes. Sigue con múltiples capas de convolución que detectan características visuales, seguidas de capas de agrupación (pooling) que reducen la dimensionalidad de los datos. La red concluye con capas completamente conectadas que facilitan la clasificación final en la capa de salida. Este flujo muestra cómo las imágenes son transformadas y categorizadas en una CNN.	32
2.4.3.2	Aplicación de <i>padding</i> de 1 a una matriz de entrada de tamaño 6×6 . Tras el <i>padding</i> , la matriz se expande a 8×8 , permitiendo que la aplicación del filtro de 3×3 genere una matriz de salida con las mismas dimensiones que la matriz original (6×6).	35
2.4.3.3	Representación gráfica del proceso de pooling en el tratamiento de imágenes, utilizando una ventana de 2×2 para la selección de características. Las flechas indican cómo los valores máximos de cada subregión son seleccionados para formar una nueva matriz reducida, optimizando la red para procesos posteriores de clasificación o reconocimiento.	36
2.4.3.4	Representación del proceso de <i>flattening</i> , este paso transforma la matriz de datos bidimensional resultante del pooling en un vector unidimensional, preparando los datos para la entrada en la capa completamente conectada.	37

2.4.3.5	Ejemplo de una capa completamente conectada en una red neuronal. El vector de entrada de dimensiones 1×9 es transformado a través de una matriz de pesos en un vector de salida de 1×4 . Cada elemento del vector de salida es una combinación lineal de los elementos del vector de entrada, ponderada por los pesos correspondientes de la matriz, demostrando cómo las capas completamente conectadas integran información a lo largo de la red.	37
2.4.4.1	Representación de una Red Neuronal Recurrente (RNN) estándar con una sola capa. Este diagrama muestra cómo la información fluye a través del tiempo: cada estado h_t recibe tanto la entrada actual x_t como el estado anterior h_{t-1} . La función de activación tanh se aplica en cada paso para combinar estas entradas antes de pasar al siguiente estado h_{t+1} . Este mecanismo permite que la RNN capture dependencias temporales en secuencias de datos.	38
2.4.4.2	Diagrama de una celda LSTM en una Red Neuronal Recurrente, ilustrando su estructura interna y mecanismos de control de flujo de información. Esta celda incluye puertas de olvido, entrada y salida, representadas respectivamente, que regulan el flujo de información permitiendo que la red recuerde y olvide información de manera selectiva. Cada puerta utiliza funciones de activación como la sigmoidea (σ) y la tangente hiperbólica (tanh) para procesar los datos de entrada (x_t) y los estados anteriores (h_{t-1}, C_{t-1}), generando un nuevo estado (h_t) y actualizando el estado de la celda (C_t).	39
2.4.4.3	Diagrama de una Red Neuronal Recurrente LSTM mostrando la reutilización de una misma celda A a lo largo de tres pasos de tiempo consecutivos. Cada celda procesa una entrada distinta (x_t, x_0, x_1, x_2) y actualiza su estado oculto (h_t, h_0, h_1, h_2) en cada paso, con cada estado alimentando al siguiente. Las salidas (O_1, O_2, O_3) son generadas en cada paso. Este proceso ilustra cómo la información es propagada y transformada en una secuencia, destacando la capacidad de la LSTM para manejar dependencias temporales en datos secuenciales.	42
2.4.4.4	Visualización del componente estacional en la serie temporal de temperatura. Esta gráfica muestra cómo los patrones de temperatura en grados <i>Kelvin</i> , fluctúan de manera regular, observando ciclos anuales consistentes a lo largo del intervalo de tiempo.	43
3.1	Esquema de las metodologías evaluadas en la tesis para la predicción del GWS. Este diagrama ilustra la secuencia desde la exploración de datos hasta la aplicación de diversas arquitecturas de aprendizaje automático: 1) Perceptrón Multicapa (MPL), 2) Bosques Aleatorios (RF), 3) Red Neuronal Convolucional (CNN), 4) Red de Memoria a Corto y Largo Plazo (LSTM), y 5) Red Neuronal Convolucional Recurrente (RCNN). Cada técnica se evaluó para determinar cuál resultaba más efectiva en el procesamiento y análisis de los datos específicos relacionados con el GWS.	49

3.1.1.1	Resoluciones espaciales de imágenes ajustadas a la misma área de estudio: (a) Temperatura medida en una resolución de 30×30 km con datos de CHIRPS, (b) Precipitación en una resolución de 12×13 km con datos de ERA, (c) Evaporación en una resolución de 6×6 km con datos de GLEAM, y (d) Almacenamiento de Agua Subterránea en una resolución de 6×6 km con datos de GRACE. Cada celda que integra el grid representa un dato individual, la densidad de los datos está en función directamente de su resolución.	50
3.1.1.2	Visualización de los intervalos de tiempo de la disponibilidad temporal de los conjuntos de datos utilizados en la investigación. Las líneas verticales indican los rangos de años activos para los conjuntos de datos de CHIRPS, GLEAM, GRACE y ERA. La línea más gruesa resalta el periodo de 7274 días seleccionado para el análisis detallado, abarcando las coincidencias temporales máximas entre las diferentes fuentes.	50
3.1.1.3	Proceso de vectorización de raster, el cual ilustra cómo se convierten las posiciones de los valores en cada píxel de la imagen en vectores unidimensionales, conservando el orden espacial para un análisis detallado posterior. De arriba a abajo: (1) Temperatura superficial el 19 de octubre de 2002, transformada de una matriz de 30×30 a un vector de 900 elementos; (2) Precipitación el 29 de julio de 2013, de 12×13 a 156 elementos; (3) Evaporación el 1 de febrero de 2003, de 6×6 a 36 elementos; y (4) Almacenamiento de agua subterránea el 1 de enero de 2003, también de 6×6 a 36 elementos. Las imágenes se muestran con leyendas en inglés, tal como aparecen en los archivos fuente, sin alteraciones.	52
3.1.1.4	Ejemplo del proceso de captura secuencial de los valores de píxeles en imágenes para dos días consecutivos, mostrando cómo los datos son organizados en matrices (E) y (Es), luego resumidos en vectores simplificados. Cada matriz representa un día de captura, con los números dentro de las celdas indicando el orden de captura.	53
3.1.1.5	Datos de precipitación del satélite CHIRPS organizados en una tabla indexada por tiempo, longitud y latitud. Este conjunto contiene registros diarios que suman un total de 6,218,100 filas, representando 900 mediciones diarias distribuidas geográficamente, registradas el 1 de febrero de 2003. Los valores de precipitación en cero indican ausencia de lluvia.	53
3.1.1.6	Serie temporal de los datos de precipitación diaria desde 2001 hasta 2022. En el eje X se muestran los años, y en el eje Y se presenta la precipitación en milímetros. La gráfica ilustra los valores promedio diarios consolidados a lo largo de 7274 días, mostrando variaciones y picos de precipitación a lo largo del tiempo.	54

3.1.1.7	Las gráficas representan, de arriba hacia abajo, la evolución de las temperaturas mínimas, medias y máximas registradas diariamente desde el 2004 hasta el año 2022 en unidades de grados <i>kelvin</i> . Cada panel muestra cómo los valores oscilan dentro de un rango específico, ilustrando las variaciones climáticas anuales y subrayando períodos de extremos térmicos.	54
3.1.1.8	Comparación diaria del almacenamiento de agua subterránea, desde 2004 hasta 2022. En la primera gráfica se muestra el promedio diario de GWS, mientras en la segunda gráfica, cada día está representado por 36 puntos de medición individuales, mostrando la variabilidad intradiaria y la respuesta del acuífero a condiciones específicas.	54
3.1.1.9	Series temporales de las variables de evaporación medidas a lo largo de los años 2004 a 2022. Cada panel, etiquetado desde E hasta SMurf, representa diferentes valores, mostrando variaciones estacionales y tendencias anuales. Los picos en los gráficos reflejan períodos de alta evaporación, que generalmente coinciden con los meses más cálidos, mientras que las partes más bajas indican menores tasas de evaporación durante los meses más fríos.	55
3.1.2.1	Esquema de división aleatoria de datos para procesos de aprendizaje automático, mostrando la asignación de conjuntos para entrenamiento (60.4 %), validación (10.6 %) y prueba (20 %). La segmentación de los datos garantiza que el entrenamiento, la validación y las pruebas se realicen en muestras únicas y no superpuestas.	56
3.1.3.2	Comparación de las trayectorias de descenso del gradiente con y sin normalización de datos. A la izquierda, los datos normalizados muestran una ruta de descenso más directa y eficiente hacia el mínimo global dentro de un rango de valores más restringido de θ . A la derecha, sin normalizar, la ruta de descenso es más errática y extendida, demostrando cómo la falta de normalización puede afectar la eficiencia y el comportamiento del algoritmo en la búsqueda del mínimo.	57
3.2.1.1	Comparación de dos arquitecturas del Perceptrón Multicapa (MLP) para la predicción del promedio del Volumen de Agua Subterránea. A la izquierda, el modelo utiliza una única variable de entrada, T_{med} , y consta de una única capa intermedia de 100 unidades antes de la capa de salida. A la derecha, el modelo incorpora tres variables de temperatura (T_{med} , T_{max} , T_{min}) y presenta tres capas intermedias, cada una con 100 unidades, antes de llegar a la capa de salida.	58
3.2.2.1	Dos arquitecturas de MLP para predecir el promedio de GWS utilizando 900 valores de Precipitación en la entrada. A la izquierda, el modelo (a) mlp_3 se desarrolla a través de cuatro capas densas. A la derecha, el modelo (b) mlp_4 presenta una configuración más simplificada con solo tres capas densas. Ambos modelos exploran cómo la cantidad y estructura de las capas afectan el rendimiento en la tarea de predicción del GWS.	59

3.2.3.1	Diversas configuraciones de Perceptrón Multicapa (MLP) evaluadas para la predicción del Volumen de Agua Subterránea usando variables de Evaporación. Los modelos difieren en la cantidad de datos de entrada, procesando de 36 o 360 valores respectivamente, lo que refleja las dimensiones detalladas en la tabla inmediata anterior. Cada modelo varía en profundidad y complejidad, desde arquitecturas más simples con una o dos capas densas hasta configuraciones más complejas con hasta cuatro capas densas, diseñadas para probar el impacto de la estructura del modelo en la precisión de las predicciones.	61
3.3.1	Tabla de datos utilizada para el análisis de importancia de variables en un modelo de Bosques Aleatorios. Las columnas representan las diferentes variables, como temperaturas media, máxima y mínima (t_mean, t_max, t_min), precipitación (precip), y diferentes componentes de la evaporación (E, Eb, Ei, Ep, Es, Et, Ew), junto con las variables de humedad del suelo (S, SMroot, SMSurf) y el promedio de Almacenamiento de Agua Subterránea (GWS_tavg). Esta tabla facilita la evaluación de qué variables contribuyen más significativamente a la predicción del GWS, permitiendo seleccionar las más predictivas para optimizar el modelo. . . .	62
3.3.2	Árbol de decisión con 3 niveles de profundidad y 1000 estimadores, utilizado para predecir el Almacenamiento de Agua Subterránea. Cada nodo del árbol muestra el valor de corte para una variable (Es, SMSurf, Et), el error cuadrático medio (MSE), el número de muestras en el nodo y el valor promedio de GWS en ese nodo. Este modelo facilita la identificación de las variables más importantes y cómo influyen en las predicciones del GWS.	63
3.3.3	Estructura del modelo de Perceptrón Multicapa <i>mlp_11</i> , configurado para utilizar las cinco variables identificadas como las más importantes por el modelo RFR. El modelo consta de una capa de entrada que recibe 180 datos (correspondientes a las cinco variables seleccionadas a lo largo de varios tiempos), seguido por tres capas densas con 300 neuronas cada una, y una capa de salida con una única neurona para predecir el Volumen de Agua Subterránea.	63
3.4.1	Modelo CNN para la estimación del Almacenamiento de agua subterránea. Este modelo integra tres flujos de entrada diferentes, cada uno correspondiente a una variable ambiental distinta (GLEAM, ERA, CHIRPS), procesadas a través de capas convolucionales y de agrupamiento, seguidas por capas densas. La fusión de las características extraídas se realiza antes de la capa de salida, que estima el almacenamiento de agua subterránea. Este enfoque permite capturar y combinar patrones espaciales y temporales críticos de cada conjunto de datos para mejorar la precisión de la estimación.	65

3.5.1	Esquema de la segmentación temporal de datos para un modelo LSTM, mostrando cómo se organizan los conjuntos de entrada X_1 y X_2 y los objetivos Y en ventanas de tiempo de tres pasos. Este método permite al modelo LSTM aprender dependencias a través del tiempo al correlacionar secuencias de entrada consecutivas con salidas futuras, crucial para la predicción precisa en series temporales.	67
3.5.2	Proceso de segmentación de series de tiempo para entrenamiento, validación y prueba en un modelo LSTM. Los datos se ordenan en secuencia cronológica descendente antes de dividirlos, asegurando que la temporalidad de los eventos se mantiene consistente a lo largo de las fases de entrenamiento (60.4 %), validación (10.6 %) y prueba (20 %).	68
3.5.3	Tres arquitecturas de modelos LSTM, cada uno configurado para diferentes entradas y salidas: (a) <i>lstm_1</i> con 31 pasos diarios, procesando 5 variables de evaporación, (b) <i>lstm_2</i> y (c) <i>lstm_3</i> ambos con 1 paso diario pero <i>lstm_2</i> usando 36 valores de GWS y <i>lstm_3</i> 36 valores de Smroot. Cada modelo apunta a predecir el GWS basados en sus configuraciones específicas.	68
3.6.1	La arquitecturas LSTM de tipo <i>many-to-many</i> mostrando dos enfoques: sincronizado, donde las salidas son generadas simultáneamente con las entradas, y asíncrono, donde las salidas dependen de todas las entradas previas sin sincronización inmediata con estas.	69
3.6.2	Comparación de dos arquitecturas LSTM, mostrando un modelo sincronizado con 31 pasos y un modelo asíncrono con 30 pasos. Cada paso representa un intervalo de tiempo en el procesamiento de la serie temporal, donde la sincronización refleja una alineación con intervalos regulares mientras que la asíncrona ajusta los pasos de acuerdo a criterios o pruebas específicas del modelo.	70
3.6.3	Detalle de la arquitectura CRNN utilizada para el entrenamiento de predicción a 30 pasos en modo asíncrono. La estructura incluye capas distribuidas en tiempo para manejar entradas multidimensionales específicas de series temporales, seguido de una capa LSTM para capturar dependencias a largo plazo y una capa densa para la predicción de salida.	71
3.6.4	Arquitectura CRNN para entrenamiento con 31 pasos en modo sincronizado. Esta configuración incorpora capas de convolución y pooling distribuidas en el tiempo para procesar secuencias de entradas temporales, seguido de una capa LSTM para capturar dependencias temporales y una capa densa para la predicción final del almacenamiento de agua subterránea.	72

4.1	Ejemplo de las gráficas que serán presentadas en la sección de resultados, mostrando: (a) la evolución de la función de pérdida durante el entrenamiento y validación del modelo, indicativa de la optimización del aprendizaje; (b) la correlación entre los valores de GWS predichos por el modelo y los valores reales, demostrando la precisión de las predicciones; y (c) una comparación temporal de los valores de GWS reales y estimados, proporcionando una visualización directa del rendimiento del modelo en el tiempo.	74
4.1.1	Evolución de la función de pérdida durante el entrenamiento y la validación de dos modelos MLP. (a) <i>mlp_1</i> utiliza una sola variable y 30 neuronas en cada una de sus capas ocultas. (b) <i>mlp_2</i> utiliza tres variables y 100 neuronas en sus capas. Cada gráfico muestra la pérdida en escala logarítmica frente al número de épocas, reflejando cómo la pérdida decrece a medida que el modelo aprende de los datos.	75
4.1.2	Gráficos de dispersión comparando los valores predichos contra los valores reales de prueba para dos configuraciones del modelo MLP. (a) <i>mlp_1</i> muestra los resultados usando una variable de entrada. (b) <i>mlp_2</i> utiliza tres variables. La línea diagonal representa la perfecta correlación entre predicciones y valores reales, sirviendo como referencia para evaluar la exactitud de cada modelo.	76
4.2.1	Evaluación de los modelos MLP para precipitación a través de gráficas de la función de pérdida y de dispersión. Las gráficas (a) y (b) muestran la función de pérdida (loss) a lo largo de las épocas de entrenamiento y validación para los modelos <i>mlp_3</i> y <i>mlp_4</i> , respectivamente. Las gráficas (c) y (d) corresponden a la dispersión de los valores predichos frente a los reales, demostrando la capacidad predictiva de cada modelo en el conjunto de prueba.	77
4.3.1	Evaluación de modelos MLP para la predicción utilizando variables de evaporación. Las subfiguras (a) a (c) y (g) a (i) muestran la función de pérdida a lo largo de las épocas de entrenamiento y validación para diferentes configuraciones de modelos, destacando cómo la pérdida decrece con el aumento de las épocas. Las subfiguras (d) a (f) y (j) a (l) ilustran gráficos de dispersión entre los valores predichos y los valores reales de prueba para cada modelo, indicando la precisión y el ajuste del modelo. Cada gráfico corresponde a una configuración diferente del modelo, desde (<i>mlp₅</i>) hasta (<i>mlp₁₀</i>), mostrando cómo varían las métricas de desempeño como la correlación y la precisión en función de las distintas configuraciones y profundidades de entrenamiento.	79
4.4.1	Importancia de las variables en la predicción del almacenamiento de agua subterránea utilizando un modelo de Random Forest Regressor (librería <i>feature_importances</i>). El gráfico muestra la relevancia asignada a cada variable, donde las barras más largas indican una mayor influencia en la capacidad predictiva del modelo. Variables como <i>E_s</i> , <i>E_t</i> y <i>E</i> se destacan como las más influyentes, mientras que otras, como <i>t_{min}</i> y <i>E_w</i> , tienen una importancia mínima. Esta información es crítica para entender qué factores contribuyen más a las predicciones del modelo.	80

4.4.2	Comparación de los diagramas de dispersión para las predicciones de los modelos <i>mlp_9</i> y <i>mlp_11</i> , que muestran los valores predichos (eje x) frente a los valores reales de prueba (eje y). Cada punto representa una observación individual, donde una alineación más cercana a la línea diagonal indica una mayor precisión en la predicción.	81
4.5.1	Resultados del entrenamiento y validación del modelo CNN con tres tipos diferentes de variables de entrada, evaluados a lo largo de diferentes periodos. La gráfica (a) muestra la curva de pérdida (loss) durante el entrenamiento frente al número de épocas; la gráfica (b) ilustra la correlación lineal de las predicciones para un día, destacando la precisión del modelo en un intervalo corto; mientras que la gráfica (c) muestra la dispersión de las predicciones frente a los valores reales durante 1382 días, proporcionando una visión a largo plazo de la consistencia y variabilidad del modelo.	82
4.6.1	Entrenamiento y correlación de las arquitecturas LSTM. Las gráficas (a), (b), y (c) muestran la función de pérdida durante el entrenamiento y validación para cada modelo LSTM, demostrando cómo se reduce la pérdida a lo largo de las épocas. Las gráficas (d), (e), y (f) exhiben la relación de dispersión entre los valores predichos por los modelos y los valores reales de los datos de prueba, reflejando la precisión y el ajuste de cada modelo.	84
4.7.1	Gráficas de la función de pérdida durante el entrenamiento y la validación para modelos CRNN asincrónicos y sincrónicos. Las gráficas (a) y (c) corresponden al entrenamiento y validación del modelo asincrónico, mientras que las gráficas (b) y (d) presentan los resultados para el modelo sincrónico. Estas visualizaciones destacan las diferencias en el comportamiento de la convergencia entre ambos enfoques a lo largo de 300 épocas.	86
4.7.2	Resultados del entrenamiento asincrónico para el modelo CRNN. (a) Correlación de los valores predichos frente a los valores reales para un período de prueba de 30 días, cada día con 36 valores de GWS. (b) Dispersión completa de las predicciones frente a los valores reales para el período completo de prueba. Debajo (c), se muestra la serie temporal de los valores de GWS reales y predichos, destacando la capacidad del modelo para seguir las fluctuaciones temporales en los datos.	87
4.7.3	Resultados del entrenamiento sincrónico para el modelo CRNN a 31 pasos. (a) Gráfica de correlación entre los valores predichos y los valores reales para un período de prueba de 31 días, mostrando una alta precisión en la predicción diaria. (b) Dispersión de todas las predicciones frente a los valores reales durante el período completo de prueba, destacando la densidad de puntos alrededor de la línea de perfecta correlación. La gráfica inferior muestra la serie temporal de los valores de GWS reales y predichos, ilustrando la capacidad del modelo para capturar las tendencias y variaciones diarias.	88

4.8.1	Gráfica de comparación entre los valores de GWS reales y los predichos por el modelo MLP utilizando cinco variables de evaporación seleccionadas a través de análisis de importancia de características con RFR. La gráfica muestra un periodo de tres meses y destaca la precisión del modelo en seguir las fluctuaciones de los datos reales.	90
4.8.2	Gráfica de los resultados de correlación entre los valores de GWS reales y predichos utilizando una arquitectura CNN sincronizada. La predicción utiliza tres variables climáticas: evaporación, temperatura y precipitación. Esta muestra aleatoria destaca la eficacia del modelo en capturar las tendencias y fluctuaciones de los niveles de GWS.	91
4.8.3	Gráfica de comparación de la correlación diaria de GWS utilizando una arquitectura LSTM que predice con base en una única variable de evaporación. Aunque las predicciones no coinciden perfectamente con los datos reales, el modelo logra seguir la tendencia general del GWS, destacando su capacidad para capturar la dinámica temporal del sistema.	91
4.8.4	Gráfica de correlación de la arquitectura LSTM para 31 días de predicción de GWS, mostrando datos cada 36 valores diarios. Esta visualización resalta la capacidad del modelo para seguir las variaciones diarias del GWS durante un mes. Se nota una diferencia consistente de aproximadamente 100mm entre las predicciones y los valores reales, lo que sugiere que el modelo podría no estar capturando adecuadamente la variabilidad espacial de los datos.	92
4.8.5	Comparativa de las métricas de rendimiento, específicamente el error absoluto medio (MAE) y la pérdida (loss), de los diferentes modelos incluyendo MLP, LSTM, CNN y CRNN. Estas gráficas muestran cómo cada modelo maneja los errores en la predicción del almacenamiento de agua subterránea. Los picos en la gráfica de pérdida indican modelos con mayores dificultades en la precisión de las estimaciones, mientras que los valores más bajos en la gráfica de MAE sugieren una mayor exactitud en las predicciones.	92
4.8.6	Estadísticas descriptivas de los datos de GWS correspondientes a cada píxel de las imágenes utilizadas en esta investigación. Este análisis incluye la media, desviación estándar, mínimos, máximos y percentiles para proporcionar una comprensión detallada de la distribución de los valores de GWS y su variabilidad, facilitando así la interpretación de errores y comparaciones con las muestras obtenidas. . . .	93
4.8.7	Distribución de la pérdida de los modelos MLP_5, CNN, LSTM y CRNN_30p. A la izquierda, la pérdida normalizada por el número de muestra. A la derecha, un boxplot detalla la variabilidad de la pérdida entre los diferentes conjuntos de muestras, con referencias a valores mínimos y máximos, mediana y los cuartiles. . . .	94

4.8.8	Comparación entre los valores reales del almacenamiento de agua subterránea y las predicciones del modelo CRNN a lo largo de 30 días. Esta gráfica destaca la precisión del modelo, que logra una correlación cercana al 100 % en la predicción de 30 días consecutivos, evidenciando su capacidad para capturar las dinámicas temporales del GWS con gran exactitud.	95
-------	---	----

Índice de Tablas

2.3.1	Detalles de las fuentes de datos para las variables de temperatura (T), evaporación (E), precipitación (P), y almacenamiento de agua subterránea (GWS). La tabla incluye las fuentes web, rangos de fechas de los datos disponibles, unidades de medición, periodos de recolección y resolución espacial.	13
2.4.3.1	Características de algunas de las funciones de activación más utilizadas	36
2.5.1	Investigaciones sobre datos de GRACE y arquitecturas de IA	47
3.1.1.1	Descripciones de las claves de variables y el número de puntos de observación para cada uno de los conjuntos de datos satelitales de CHIRPS, ERA, GLEAM y GRACE, utilizados en el área de estudio.	51
3.1.2.1	Distribución de los conjuntos de datos GLEAM y GRACE para entrenamiento, validación y prueba. $X = GLEAM$ y $Y = GRACE$ indican las variables independientes y dependientes respectivamente, con el conjunto completo consistiendo en 261864 muestras, y las divisiones de los tres subconjuntos estructurados para optimizar el aprendizaje y la validación del modelo.	56
3.2.1.1	Dimensión de las variables de temperatura antes y después de la reducción de datos. <i>Var</i> indica las variables consideradas; <i>Reducción</i> muestra las dimensiones de los datos tras aplicar un proceso de promedio (promedio de todos los puntos en el área de estudio), mientras que <i>Entradas</i> representa las dimensiones finales, adecuadas para su uso en arquitecturas de MLP.	58
3.2.2.1	Transformación de los datos de las variables de precipitación (P) y almacenamiento de agua subterránea (GWS). La columna <i>Matriz</i> indica las dimensiones originales de los datos, <i>Reducción</i> muestra cómo se multiplican estas dimensiones para eliminar tres. Finalmente la columna <i>Entradas</i> describe las dimensiones finales de los datos que alimentan al modelo.	59
3.2.3.1	La tabla muestra dos configuraciones: una con una sola banda de datos de evaporación y la segunda con diez. La columna <i>Matriz</i> , indica las dimensiones originales de los datos. El campo <i>Reducción</i> detalla como al multiplicarse las dimensiones estas se reducen a los valores de <i>Entradas</i> , 36 para cuando solo es una variable de evaporación y 360 valores cuando son 10 bandas de evaporación.	60
3.4.1	Dimensiones de los datos de entrada para el conjunto de entrenamiento de un modelo CNN, utilizando variables de los tres satélites. $X1$ <i>GLEAM</i> representa datos con dimensiones [4655, 6, 6, 5], $X2$ <i>ERA</i> con [4655, 16, 16, 3], y $X3$ <i>CHIRPS</i> con [4655, 30, 30, 3]. Cada conjunto de datos corresponde al número de muestras, altura, ancho y canales de características respectivamente, preparados específicamente para ser procesados por la primera capa convolucional del modelo. . . .	64

3.5.1	Configuración de las entradas para tres modelos LSTM distintos diseñados para predecir el almacenamiento de agua subterránea. Cada modelo tiene una estrategia diferente: <i>lstm_1</i> utiliza 31 pasos representando un mes con 5 variables de evaporación, <i>lstm_2</i> y <i>lstm_3</i> utilizan un paso por día con 36 valores diarios de GWS y Smroot, respectivamente.	67
3.6.1	Configuraciones de entrada para modelos CRNN sincronizados y asincrónicos. Se detalla el número de pasos y la estructura de las matrices de entrada [<i>None</i> que representa cualquier número de muestras, 6 latitud, 6 longitud, 5 variables de evaporación]. Se describe también la dimensión de salida para la predicción del GWS.	70
4.1.1	Métricas de evaluación de los modelos MLP para la predicción de GWS utilizando temperatura como variable de entrada. Cada modelo se diferencia por el número de variables de entrada (<i>var</i>), capas ocultas (<i>capas</i>), neuronas por capa (<i>h</i>), y épocas de entrenamiento (<i>epochs</i>). Se presentan los valores del error cuadrático medio (MSE), error absoluto medio (MAE), correlación entre los valores predichos y reales, y el valor-P asociado a la prueba de correlación.	75
4.2.1	Métricas de evaluación para los modelos MLP que utilizan la precipitación como variable de entrada. Los modelos se diferencian por el número de capas ocultas (<i>h</i>) y la cantidad de épocas durante las cuales se entrenaron. <i>MSE</i> indica el error cuadrático medio, <i>MAE</i> el error absoluto medio, y <i>Correlación</i> mide la relación lineal entre las predicciones y los valores reales. <i>P-value</i> evalúa la significancia estadística de la correlación observada.	76
4.3.1	Métricas de evaluación para diversos modelos MLP utilizando datos de evaporación como variable de entrada. La tabla incluye el identificador del modelo, el número de variables (<i>var</i> de E), la estructura de la entrada (<i>shape</i>), el número de neuronas en las capas ocultas (<i>h</i>), la cantidad de épocas durante las cuales se entrenó cada modelo, y las métricas de rendimiento incluyendo el error cuadrático medio (<i>loss</i>), el error absoluto medio (MAE), la correlación entre las predicciones y los valores reales, y el p-value asociado a esta correlación. Los modelos se diferencian por la cantidad de épocas y la configuración de las entradas y capas ocultas.	78
4.4.1	Comparación de las métricas de rendimiento entre los modelos <i>mlp₉</i> , que incluye las 10 variables de GLEAM y <i>mlp₁</i> , que se basa solo en las 5 variables más importantes según el análisis de RFR. Este cuadro resalta cómo la selección y reducción de variables afectan a la precisión del modelo, evidenciado por diferencias significativas en el error cuadrático medio (<i>loss</i>), error absoluto medio (MAE), correlación y el valor-p.	81

4.5.1	Resultados del aprendizaje con la arquitectura CNN utilizando variables de Evaporación, Temperatura y Precipitación como entradas (5,3,1, respectivamente). Se muestra la evaluación para configuraciones que varían por número de días considerados (1 día y 1382 días), número de variables (3 y 5), y dimensiones de las entradas (36, 256, y 900). Los resultados incluyen la pérdida (<i>loss</i>), el error medio absoluto (<i>MAE</i>), la correlación entre predicciones y valores reales, y el valor P para probar la significancia estadística de la correlación.	82
4.6.1	Resultados de los entrenamientos usando arquitectura LSTM para tres configuraciones diferentes. Cada fila corresponde a un modelo distinto identificado como <i>fit</i> , donde <i>var</i> representa el número de variables de entrada, <i>shape</i> la cantidad de datos en cada secuencia, <i>d</i> la dimensionalidad de la salida, <i>epochs</i> el número de épocas de entrenamiento, <i>loss</i> y <i>MAE</i> que indican el error medio y el error absoluto medio respectivamente, <i>correlation</i> la correlación entre las predicciones y los valores reales, y <i>P-value</i> la significancia estadística de la correlación.	83
4.7.1	Resultados de entrenamiento para modelos CRNN asincrónicos y sincrónicos. La tabla compara los dos modelos en términos de pasos temporales (30 y 31), número de épocas de entrenamiento (300), pérdida (<i>loss</i>), error absoluto medio (<i>MAE</i>), correlación entre las predicciones y valores reales, y el p-value asociado a la correlación. Todos los modelos fueron evaluados con la misma dimensionalidad de entrada, 36.	85
4.8.1	Comparación de métricas de desempeño para los modelos de aprendizaje automático aplicados en esta investigación para la predicción de GWS. La tabla presenta el número de variables <i>var</i> , la estructura de entrada <i>forma</i> , la cantidad de épocas <i>epochs</i> , junto con las métricas de evaluación: pérdida <i>loss</i> , error absoluto medio <i>MAE</i> , correlación y el <i>valor-p</i> . Los modelos incluyen MLP, CNN, y LSTM, tanto en configuraciones sincrónicas como asíncronas de la arquitectura CRNN, destacando sus eficacias relativas en términos de precisión y error.	89
4.8.2	Comparación de los modelos utilizados en términos de cantidad de datos de entrenamiento, valores de salida y el tipo de resultados generados. MPL 5 genera un valor único representando el promedio de la imagen, mientras que CNN y LSTM producen 36 valores correspondientes a una imagen de [6 x 6]. CRNN 30p, aunque muestra valores altos de pérdida y error absoluto medio (<i>MAE</i>), procesa una cantidad significativamente mayor de datos, con 1080 valores distribuidos en 30 imágenes de [6 x 6], lo que puede explicar la dispersión de errores observada. . .	93

1 Introducción

La escasez de agua subterránea es un problema mundial que afecta también a México (FAO, 2017), donde el aumento en las extracciones ha llevado a un descenso en los niveles de los acuíferos (Gleeson y cols., 2012). Factores como la alta demanda agrícola (Wada y cols., 2010; Siebert y cols., 2010) los impactos del cambio climático (Jyrkama y Sykes, 2007; WMO, 2020), el crecimiento poblacional (Robins, 1998; Bierkens y Wada, 2019) y el aumento en la demanda de alimentos (Godfray y cols., 2010) exacerban esta situación. Además, de considerar la conservación de los ecosistemas que dependen de la proximidad de los niveles freáticos (Eamus y cols., 2015; Derek y cols., 2016).

En México, el 39 % del agua dulce disponible proviene de fuentes subterráneas, cubriendo el 70 % de la demanda de industrias, agricultura y ciudades, además de proporcionar un suministro crítico en la mayoría de las poblaciones rurales y en las regiones donde el agua superficial es limitada (SINA, 2018).

Diversos estudios han destacado el uso excesivo de agua subterránea, situando a México y Estados Unidos entre los principales consumidores en América, superando incluso a regiones con poblaciones mayores como África (Y. Wada y Bierkens, 2014; Stone, 2018; UNESCO, 2021).

El manejo efectivo de los recursos hídricos subterráneos requiere de métricas actualizadas. Sin embargo, en coloquios y foros sobre la gestión del agua subterránea en México, como: *“no se puede gestionar lo que no se puede medir y hacer visible lo invisible”*, se ha argumentado que la insuficiencia de datos es una limitante crítica para una gestión adecuada (Álvarez y Antonio, 2021; Rivera y Joel, 2014; Galván y cols., 2018; IMTA, 2021; Barthel y cols., 2017). Este desafío destaca la necesidad urgente de mejorar los sistemas de recopilación y análisis de datos, con el objetivo de enfrentar los desafíos futuros en la administración del agua subterránea.

Esta investigación propone mitigar la carencia de datos mediante el uso accesible de información de sensores remotos (Aldorf y cols., 2007; Acuna, 2023), implementando arquitecturas de Inteligencia Artificial. Refiriendo la “implementación de arquitecturas de Inteligencia Artificial (IA)” en el contexto de utilizar algoritmos avanzados de machine learning y deep learning, diseñados para manejar diversas variables, procesar grandes volúmenes de datos y adaptarse a distintos formatos (K. Fang y Shen, 2020; Nearing y cols., 2021; Panahi y cols., 2020). Estas metodologías han demostrado ser eficaces en el monitoreo de la demanda de agua (Jae Young y Lee, 2019; W. Seyoum y cols., 2019; Guo y cols., 2018; Donkor y cols., 2014), el seguimiento de sequías e inundaciones (Long y cols., 2014), la medición de la humedad del suelo (Seonyoung y cols., 2017), y en la predicción confiable del almacenamiento de agua subterránea (A. Sun, 2013).

La aplicación de las Redes Neuronales Artificiales (RNA) en la estimación del volumen de agua subterránea lleva desarrollándose casi tres décadas (Hsu y cols., 1995). Estos estudios han progresado desde el uso básico de perceptrones multicapa hasta arquitecturas más complejas. Una investigación titulada: *“A review of the artificial intelligence methods in groundwater level modeling”* (Taher y cols., 2019) recopiló 67 estudios publicados entre 2001 y 2018, destacando las técnicas de IA más efectivas y las variables más relevantes para predecir el agua subterránea. Entre las investigaciones incluidas, incursionó una que utiliza datos del Almacenamiento de Agua Terrestre (GWT, por sus siglas en inglés *Ground Water Total*) proporcionados por los satélites GRACE (*Gravity Recovery and Climate Experiment*) (Mukherjee y Ramachandran, 2018).

Es probable que la escasa aplicación inicial de los datos de GRACE (Zlotnicki, 2020; B. Tapley y cols., 2004) en la recopilación anterior se deba a su reciente disponibilidad. Desde su lanzamiento en marzo de 2002, GRACE ha documentado significativas pérdidas de hielo en regiones polares y montañosas, y ha identificado que 13 de los 37 mayores acuíferos terrestres han sufrido pérdidas críticas debido al cambio climático y la presión antropogénica (B. D. Tapley y cols., 2019). Esta capacidad ha consolidado a GRACE como una herramienta crucial para monitorear los cambios espacio-temporales en los acuíferos y detectar zonas críticamente afectadas (Pang-Wei y cols., 2022; Acuna, 2023).

Este estudio se fundamenta en un análisis exhaustivo de investigaciones actuales sobre redes neuronales artificiales y su aplicación en el ámbito hidrológico, con especial énfasis en la predicción y estimación de la variación del almacenamiento del agua subterránea. De acuerdo con recomendaciones encontradas en la literatura científica, este trabajo ha optado por utilizar datos de sensores remotos como una alternativa viable para superar la limitada disponibilidad de datos in situ. Los datos climáticos empleados, que provienen de integraciones sofisticadas de observaciones satelitales, terrestres y modelos numéricos (como CHIRPS, GLEAM y ERA), representan uno de los repositorios más extensos y reflejan los avances tecnológicos significativos en el campo de la tele-detección. (Sahoo y cols., 2017).

Lejos de ser una limitación, el acceso a esta gran base de datos plantea oportunidades únicas para la implementación de modelos de IA, como lo son el Perceptrón Multicapa (MPL), las Redes Neuronales Convolucionales (CNN), las Redes de Memoria Larga a Corto Plazo (LSTM) y las Redes Neuronales Convolucionales Recurrentes (CRNN). Estos modelos permiten procesar información espaciotemporal para predecir el Almacenamiento de Agua Subterránea, registrado por el satélite GRACE. El uso de sensores remotos y la IA constituyen así una solución prometedora para mejorar la precisión en la gestión de los recursos hídricos (Bishop, 2006; Han y cols., 2011; Shah y Szeliski, 2012; Lillesand y cols., 2015; Du y Xie, 2019).

El área geográfica seleccionada para probar esta herramienta de predicción corresponde a la zona delimitada por el acuífero de Conejos Médanos, identificado con la clave 0833 por la Comisión Nacional del Agua (CONAGUA, 2024a), ubicada al norte de Chihuahua. Se ha elegido esta área principalmente porque ha sido objeto de diversos estudios por parte del Servicio Geológico Mexicano, debido a su naturaleza transfronteriza y a la intensa demanda de extracción de agua que enfrenta

actualmente.

1.1. Planteamiento del problema

La escasez de datos sobre el almacenamiento de agua subterránea dificulta significativamente su monitoreo eficaz. Tradicionalmente, la vigilancia se ha centrado en medir el nivel del agua en pozos de observación, cuya cobertura espacial es limitada y los registros suelen ser discontinuos y, en algunos casos, inaccesibles al público debido a factores políticos y económicos, incluidos los altos costos asociados con la perforación y el mantenimiento de la infraestructura hídrica (Shuhua y Cheng, 2007; Alsdorf y cols., 2007; NRC, 2008; Li y cols., 2019).

Otra crítica recurrente en la literatura sobre la gestión de acuíferos es la manera en que se han delimitado sus fronteras, tanto laterales como verticales, con fines administrativos y legales en México, tal como se establece en las leyes y reglamentos nacionales (Cubas y cols., 2017). Esta demarcación administrativa no siempre refleja la complejidad natural de los sistemas acuíferos, lo que crea problemas en la gestión eficiente de los recursos hídricos (ver Figura 1.1.1). En contraste, países como Estados Unidos aplican una visión más amplia y regional de los sistemas de flujo de agua subterránea. Con un territorio casi cinco veces mayor que el de México, Estados Unidos ha identificado solo 60 acuíferos principales, lo que refleja una aproximación más holística y eficiente de gestión.

Desde 1960, los acuíferos han sido conceptualizados de manera reduccionista, como contenedores que se llenan por infiltración y se vacían mediante la extracción de pozos, basándose en un enfoque de balance hídrico que solo considera la recarga y descarga del sistema (Rivera y cols., 2016; García y Castro, 2015; Molina, 2018; CONAGUA, 2024b). Sin embargo, este enfoque simplificado no aborda adecuadamente las complejas interacciones dentro de los sistemas acuíferos, ni su comportamiento dinámico. Se omiten factores cruciales como los sistemas de flujo, las características geológicas, hidráulicas, ambientales y las influencias antropogénicas, todos ellos esenciales para una gestión sostenible del agua subterránea (Perevochtchikova y cols., 2006). Esta visión fragmentada es una de las desventajas que ha limitado la capacidad para gestionar de manera sostenible los recursos hídricos subterráneos.

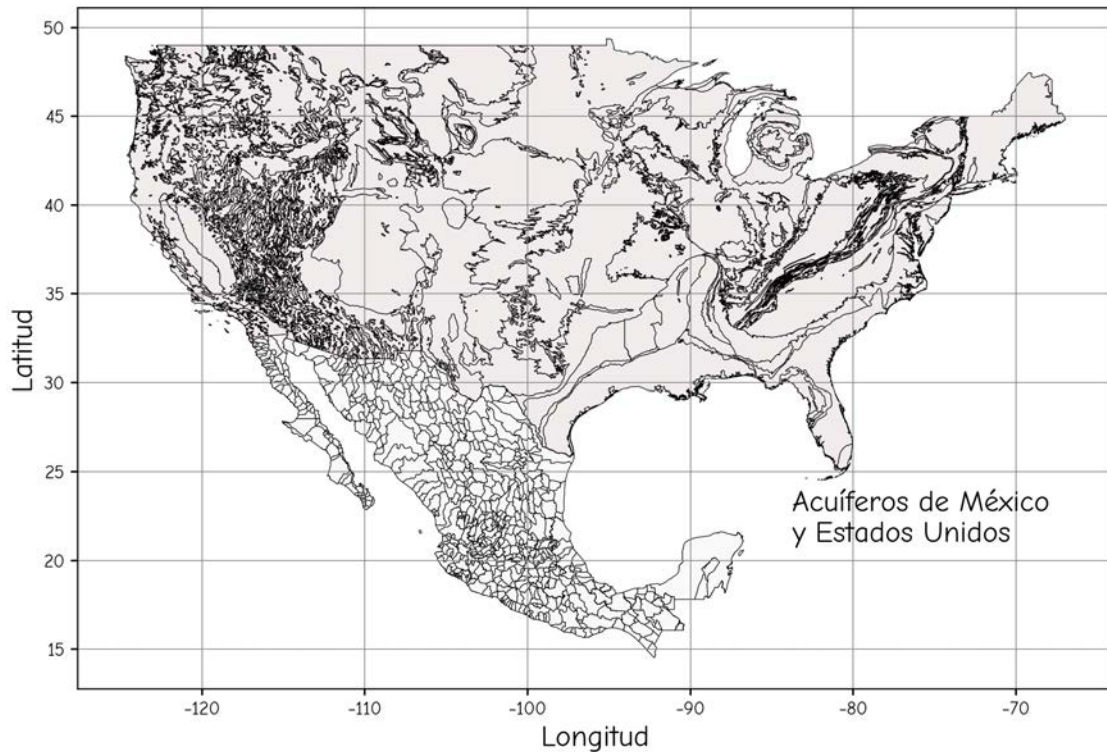


Figura 1.1.1: Mapa de los acuíferos de México y Estados Unidos, elaborado a partir de los límites vectoriales disponibles en las bases de datos de la Comisión Nacional del Agua (CONAGUA, 1960) y el gobierno de Estados Unidos (USDATA.GOV, 2020). El mapa muestra 653 polígonos en México y 60 en Estados Unidos, reflejando las diferencias en los criterios de demarcación utilizados en cada país.

Investigadores tanto en ciencias del agua como en ciencia de datos coinciden en que la singularidad geográfica de cada sitio y la escasez de datos constituyen dos de los principales obstáculos que impiden un monitoreo efectivo y la creación de modelos predictivos precisos para la gestión del agua subterránea (Nearing y cols., 2021; Úrsula Oswald, 2011; Connor y Miletto, 2022; Gonzalo, 2018).

1.2. Objetivo

El objetivo de esta investigación es predecir el almacenamiento del agua subterránea en un sistema hidrogeológico, explorando variables del ciclo del agua obtenidas mediante teledetección y utilizando Redes Neuronales Convolucionales Recurrentes (CRNN). Esta metodología pretende facilitar el monitoreo, la estimación y la predicción del almacenamiento de agua subterránea (GWS), así como su adaptación a cualquier área de los sistemas acuíferos en México.

1.3. Justificación

La gestión eficiente de los recursos hídricos subterráneos enfrenta desafíos significativos debido a la escasez de datos accesibles y homogéneos (Rivera, 2012). En México, la obtención de estos datos a través de estudios físicos resulta costosa y logísticamente compleja (Sahoo y cols., 2017). Ante

esta problemática, esta investigación propone una alternativa innovadora basada en la integración de datos de sensores remotos con técnicas avanzadas de IA. Mediante el uso de datos históricos y actuales del satélite GRACE, el estudio busca desarrollar un enfoque que permita el monitoreo y la estimación del almacenamiento de agua subterránea, proporcionando una herramienta valiosa que auxilie en la gestión sostenible de este recurso crítico (Soltani y cols., 2021).

1.4. Alcances y Limitaciones

El propósito principal de esta investigación es estimar de manera cuantitativa el cambio en el almacenamiento de agua subterránea en sistemas acuíferos, tomando como caso de estudio el acuífero de Conejos Médanos. Aunque el enfoque se centra en esta área específica, el modelo desarrollado tiene el potencial de ser replicado en otras regiones, ya que se cuenta con datos suficientes sobre las variables necesarias.

Cabe destacar que no se busca desarrollar un modelo conceptual ni profundizar en los procesos físicos detallados del sistema hidrológico. Este enfoque es particularmente valioso en situaciones donde los datos disponibles son limitados, pero es crucial obtener estimaciones de la disponibilidad de agua subterránea, más allá de la comprensión detallada de los mecanismos físicos subyacentes.

1.5. Estructura del documento

La tesis se organiza en cinco secciones principales. La primera sección está dedicada a establecer los objetivos, plantear el problema y definir los alcances de la investigación, sentando las bases conceptuales que guiaron el desarrollo del estudio.

La segunda sección corresponde al marco teórico, que incluye una revisión del estado del arte sobre la estimación y monitoreo de aguas subterráneas mediante algoritmos de inteligencia artificial y técnicas de teledetección. Además, se presenta una descripción geográfica del área de estudio y se detallan las variables empleadas junto con sus respectivas fuentes, obtenidas de sensores remotos. Posteriormente, se expone el fundamento teórico de los modelos metodológicos propuestos. Finalmente, se incluye una compilación tabular que resume las investigaciones más relevantes y relacionadas con este trabajo.

La tercera sección se enfoca en la metodología, describiendo en detalle los modelos utilizados y las diferentes pruebas experimentales realizadas con varios modelos de IA.

En la cuarta sección se presentan los resultados de dichas pruebas, siguiendo el mismo orden en el que se llevaron a cabo los experimentos. Se realiza un análisis conjunto de los resultados, comparándolos con parámetros de otras investigaciones relacionadas.

Finalmente, la quinta sección incluye las conclusiones derivadas de la investigación y ofrece sugerencias para posibles trabajos futuros.

2 Marco Teórico

Este capítulo presenta los conceptos teóricos y las metodologías que sustentan esta investigación. Inicia con una revisión del estado del arte sobre la aplicación de inteligencia artificial en hidrología, particularmente en la estimación del almacenamiento de agua subterránea (GWS, por sus siglas en inglés *Ground Water Storage*). Posteriormente, se describen los conceptos de las variables utilizadas, seguidos de las bases teóricas de las arquitecturas de redes neuronales artificiales aplicadas en la metodología. Finalmente, se incluye una sección que recopila investigaciones relevantes, alineadas con los objetivos, datos y arquitecturas de este estudio.

2.1. La Hidrología en la era del Aprendizaje Profundo

El aprendizaje profundo (DL por sus siglas en inglés, *Deep Learning*) incursionó en la Hidrología hace casi tres décadas con los investigadores Hsu y cols. en 1995, específicamente para abordar la relación entre la lluvia y la escorrentía en la cuenca del río Leaf en Mississippi, EE.UU. De acuerdo con los autores, el desafío principal radica en la dificultad para describir las características de los procesos mediante ecuaciones físicas. Aunque la opción de utilizar una Red Neuronal Artificial (ANN por sus siglas en inglés, *Artificial Neural Network*) con variables climáticas, en particular la precipitación (P) y datos piezométricos, no consigue describir la estructura interna de la cuenca. Su enfoque ANN proporciona una alternativa viable y eficaz para simular y pronosticar la respuesta de la lluvia y la escorrentía a escala de cuenca.

Actualmente, es posible abordar el estudio de teorías y modelos a escala de cuenca con los datos disponibles, empleando técnicas basadas en Aprendizaje Automático, particularmente con DL (Nearing y cols., 2021). Esta capacidad ha sido demostrada en un extenso estudio que aprovechó 30 años de datos lluvia-escorrentía de varias cientos de cuencas en los Estados Unidos. Los resultados de su modelo DL proporcionaron predicciones de caudal diario promedio superiores en cuencas no aforadas en comparación con los modelos hidrológicos tradicionales, especialmente cuando se calibraron con registros extensos de datos en cuencas aforadas (Kratzert y cols., 2019).

Dada la complejidad inherente a los modelos hidrológicos, ya sean conceptuales o numéricos, y considerando el creciente interés en la estimación del nivel de agua subterránea, se ha observado un aumento significativo en la aplicación de métodos de inteligencia artificial. Este fenómeno queda evidenciado en una investigación publicada por Taher y cols. en 2019, procedente de la Universidad de Qom, Irán. Este estudio compiló 67 artículos que abordan métodos de inteligencia artificial para el modelado y pronóstico del nivel de agua subterránea *Ground Water Level* (GWL). Dichas publicaciones fueron extraídas de 29 reconocidas revistas internacionales a lo largo de un

período que inició con una contribución en el año 2001, seguida de dos en 2005, siete en 2011, alcanzando un total de diez publicaciones para 2015 y manteniendo el mismo número para el año 2018.

El primer estudio presenta uno de los desafíos a los que también se enfrenta esta investigación: la escasez de datos para estimar el GWL. Ante la falta de información específica sobre los acuíferos, la investigación de Coulibaly, Anctil, Aravena, y Bobée propone el uso de una arquitectura de Red Neuronal Recurrente (*Recurrent Neural Network, RNN*), empleando únicamente tres variables para estimar el promedio mensual del nivel freático en el acuífero Gondo en Burkina. Aunque estas variables podrían parecer insuficientes para un modelado físico convencional, las variables meteorológicas diarias de temperatura y precipitación, junto con los niveles promedio semanales de agua del río Mouhoun, durante el período 1970-1997, demostraron ser suficientes para implementar un enfoque basado en modelos de redes neuronales.

Las variables más utilizadas de acuerdo con la investigación que revisó los 67 artículos, 52 han empleado el nivel de agua subterránea como variable de entrada, siendo incluso considerada como la única variable predictora en 12 de esos modelos. Después de los piezómetros, la precipitación fue la segunda variable más frecuentemente utilizada (48 veces) y continúan mencionando algunas otras variables como la temperatura, la descarga de ríos (escorrentía superficial), la evapotranspiración, el nivel de agua superficial (lago), las tasas de bombeo (extracción de pozos) y la humedad. Esto se detalla en la Figura 2.1.1, tomada del artículo original.




Figura 2.1.1: Variables de entrada más utilizadas en modelos de IA para la predicción del nivel de agua subterránea (IA-GWL), basadas en el estudio de (Taher y cols., 2019)

A pesar de ser una medida directa para conocer el nivel de agua subterránea y estar presente en la mayoría de los estudios, la piezometría en realidad no está disponible en numerosas regiones. Esto se debe a que su adquisición implica costos elevados, que van desde la perforación hasta el mantenimiento y monitoreo de pozos (Brookfield y cols., 2018). Sin embargo, en la actualidad, esta limitación no se considera una debilidad, ya que la esencia de los modelos que aplican inteligencia artificial (IA) radica en su capacidad para trabajar con diversos conjuntos de datos. Este concepto

se pone de manifiesto en un estudio propuesto por los investigadores Wunsch, Liesch, y Broda en el año 2021, en el área del Alto Rin Graben, el recurso de agua subterránea más significativo en Europa central. Los autores llevan a cabo estimaciones del nivel de agua subterránea, proponiendo la precipitación (P) como la recarga del acuífero, dada su relación directa con la dinámica del agua subterránea, y utilizando dos variables climáticas: la temperatura (T) y la humedad relativa (rH).

Otra alternativa que se está implementando en regiones con pocas o ninguna medida in situ son las investigaciones (Leblanc y cols., 2009; Famiglietti y cols., 2011; Huang y cols., 2015; Nanteza y cols., 2016; Castellazzi y cols., 2016; Li y cols., 2019) que ocupan las mediciones de la misión GRACE para el monitoreo de sequías y/o cuantificar el déficit hídrico. GRACE mide la gravedad de la Tierra con suficiente precisión como para mapear el movimiento estacional del agua (TELLUS, 2012). Numerosos estudios han demostrado que las variaciones de GRACE son confiables en comparación con las mediciones terrestres y modelos geológicos en escalas globales (Jour y cols., 2008).

Las investigaciones de Ngo-Duc y cols. (2007), Longuevergne y cols. (2010), Döll y cols. (2014), Brookfield y cols. (2018), y Rateb (2020); han comparado y analizado estimaciones de almacenamiento de agua basadas en datos GRACE y datos piezométricos obtenidos del monitoreo del acuífero *High Plains* (HPA). En su estado agotado, el HPA ha sido identificado en el informe *Satellite Gravity and the Geosphere* del Consejo Nacional de Investigaciones de Estados Unidos como el único acuífero mundial adecuado para estudios y comparaciones con sistemas satelitales como GRACE (Dickey y cols., 1998). Esta afirmación fue confirmada antes del lanzamiento de GRACE por los científicos Chen y cols. (2005).

Las mediciones geospaciales de gran volumen de la misión satelital GRACE han proporcionado información sobre la distribución espacio-temporal del Almacenamiento de Agua Terrestre (TWS, *Total Water Storage*) tanto en la superficie terrestre como en los entornos subsuperficiales (Shamsudduha, 2021). Los datos generados por los satélites de monitoreo climático, como GRACE, están experimentando un crecimiento en diversas escalas. Estas características los hacen susceptibles al análisis mediante algoritmos avanzados de aprendizaje automático y aprendizaje profundo, los cuales pueden caracterizar eficazmente sus tendencias y comportamientos. Esto incluye la explotación de su naturaleza multidimensional y el manejo de sus variadas fuentes y resoluciones espaciales, temporales y espectrales. El empleo de estas técnicas específicas de inteligencia artificial permite abordar la complejidad de los datos y extraer información valiosa que puede ser crucial para la gestión y el análisis hidrológico (Huntingford y cols., 2019).

Los datos de GRACE se han combinado con otras variables climáticas (Ahmed y cols., 2011; Naranjo y cols., 2014; Wenjie y cols., 2020), modelos físicos y redes neuronales (A. Sun y cols., 2019; W. Seyoum y Milewski, 2017; Sahoo y cols., 2017) para monitorear (Long y cols., 2014; Seo y Lee, 2019), medir el agotamiento (Rodell y Famiglietti, 2002), predecir (A. Sun, 2013; M. Yassin y cols., 2024) y mejorar las estimaciones del volumen de agua subterránea.

Mohammadi (2008) junto con otros autores (Coppola y cols., 2003; Parkin y cols., 2007; Nikolos y cols., 2008) demostraron que los modelos de aprendizaje automático podían lograr un rendimiento

equiparable o incluso más preciso que los modelos físicos para predecir la variabilidad del GWL. Mohammadi (2008) argumenta que las Redes Neuronales Artificiales requieren menos variables de entrada y menos tiempo de ejecución en comparación con los modelos convencionales, como MODFLOW.

El Perceptrón Multicapa (MLP, por sus siglas en inglés *MultiLayer Perceptron*) es una de las redes neuronales artificiales más básicas y comúnmente utilizadas para la aproximación de parámetros hidrológicos. Estas variables se caracterizan por su comportamiento como funciones temporales, las cuales suelen carecer de una relación lineal, lo que dificulta su incorporación en los modelos numéricos (Afzaal y cols., 2020). El MLP no tiene la capacidad de retener información pasada, a diferencia de una red neuronal recurrente, que maneja de manera más efectiva el comportamiento no lineal de las series temporales mediante el uso de bloques de memoria que conservan información de pasos temporales anteriores (Taher y cols., 2019). Tanto el MLP como las RNN son métodos ampliamente utilizados y exitosos en problemas relacionados con el modelado del GWL (Coulibaly y cols., 2001). Sin embargo, existe un enfoque más avanzado con una estructura más densa que las mencionadas anteriormente, conocido como redes neuronales convolucionales (CNN, por sus siglas en inglés, Convolutional Neural Network). Las CNN representan un enfoque relativamente nuevo en la exploración sobre el GWL (Afzaal y cols., 2020), y también se han incluido en esta investigación debido a su capacidad para manejar variables climáticas en formato de imagen. A continuación, se detallarán más a fondo las variables y los métodos aplicados en esta investigación.

2.2. Área de estudio

El área seleccionada para probar esta investigación es el acuífero Conejos-Médanos, identificado con la clave 0823 por parte de la Comisión Nacional del Agua (CONAGUA). Está situado en la porción norte del estado de Chihuahua, México, y comparte límites con el acuífero transfronterizo del Bolsón de La Mesilla, en los Estados Unidos de América. Limita al oriente con los acuíferos Valle de Juárez y Samalayuca, al sur con Laguna de Patos y Laguna de Santa María y al occidente con Las Palmas, todos ubicados en el estado de Chihuahua (Figura 2.2.1). Geopolíticamente, el acuífero abarca parcialmente los municipios de Ascensión, Juárez y Ahumada, cubriendo una superficie de 6,138 km². Geográficamente, el área en estudio se sitúa entre los paralelos 30° 49' y 31° 48' de latitud norte y entre los meridianos 106° 27' y 107° 18' de longitud oeste (Figura 2.2.1).



Figura 2.2.1: Delimitación del área de estudio correspondiente al acuífero Conejos-Médanos. Mapa vectorial basado en datos de (CONAGUA, 2023).

Desde 1982, se han realizado diversos estudios físicos y de campo en el acuífero Conejos Médanos, principalmente enfocados en evaluar su capacidad hidrogeológica y su potencial para abastecer de agua potable a Ciudad Juárez. Estos estudios incluyen sondeos eléctricos, análisis químicos del agua subterránea, descripción petrográfica de muestras de roca y perforaciones exploratorias. Se identificaron las formaciones geológicas más favorables para la extracción de agua, como las Formaciones Benigno y Finlay, además de los depósitos aluviales.

Posteriormente, se realizaron estudios complementarios en 1985 y 1989 que identificaron tres unidades geológicas en el subsuelo y se destacó la presencia de agua con concentraciones de sólidos disueltos en diferentes profundidades. En 1999, se realizó un análisis de la calidad del agua, revelando variaciones en la composición química y el flujo subterráneo, mientras que en 2000, se desarrolló un modelo de simulación hidrodinámica que permitió evaluar la capacidad del acuífero para abastecer agua a Ciudad Juárez durante 20 años (CONAGUA, 2023).

Finalmente, el último estudio publicado en el sitio oficial de CONAGUA es en 2007, donde en colaboración con el Servicio Geológico Mexicano llevaron a cabo un censo de aprovechamientos y pruebas de bombeo para establecer una red de monitoreo piezométrico, lo que sentó las bases para la gestión y monitoreo actual del acuífero. Estos trabajos, aunque fundamentales para entender

el comportamiento del acuífero, se centran en estudios físicos y de campo, orientados principalmente a la extracción de agua subterránea (SGM, 2010).

El acuífero Conejos Médanos, situado entre México y Estados Unidos, enfrenta varios desafíos debido a su naturaleza transfronteriza. Uno de los principales problemas es la falta de acuerdos bilaterales formales. Aunque existe el Tratado de Aguas Internacionales de 1944, este acuerdo se centra en las aguas superficiales y no cubre de manera específica la gestión de los acuíferos transfronterizos. Esta carencia dificulta la coordinación efectiva entre ambos países y aumenta el riesgo de conflictos (CILA, 1944).

Otro reto relacionado con su naturaleza transfronteriza es la diferencia en las políticas de uso del agua entre México y Estados Unidos. Cada país tiene normativas diferentes respecto a la gestión del agua subterránea, lo que complica los esfuerzos de conservación y sostenibilidad del recurso compartido (Wilder y cols., 2010; s. Mumme, 2000).

Además, la explotación asimétrica es un problema frecuente en acuíferos transfronterizos. La extracción desigual del agua subterránea entre las dos naciones puede exacerbar las tensiones, especialmente en períodos de estrés hídrico, aumentando la presión sobre el acuífero (Megdal y cols., 2014).

La elección del acuífero Conejos Médanos para la estimación del almacenamiento de agua subterránea (GWS) mediante métodos de Inteligencia Artificial se fundamenta en varios factores críticos. En su última actualización publicada por la CONAGUA, se concluyó que no existe volumen disponible para otorgar nuevas concesiones, ya que el acuífero enfrenta un déficit de aproximadamente 9.4 millones de m^3 . Esta situación refleja un uso insostenible de los recursos hídricos y la urgente necesidad de estrategias más eficientes para su monitoreo y gestión.

Desde la perspectiva de esta investigación, el acuífero Conejos Médanos presenta una alineación clara con los problemas abordados en este estudio. Los datos sobre los niveles piezométricos, disponibles en el Sistema Nacional de Información del Agua (SINA), solo están actualizados hasta 2012. Además, desde el inicio de las mediciones piezométricas en 1996 en 20 pozos, los datos han sido discontinuos y limitados (SINA, 2024). La falta de datos actualizados y estudios recientes profundiza la incertidumbre sobre el estado actual del acuífero, lo que limita la toma de decisiones efectivas.

Además de ser la principal fuente de abastecimiento hídrico para Ciudad Juárez y sus actividades pecuarias, el Servicio Geológico Mexicano (SGM) ya había identificado en estudios previos (2008) la importancia crítica de este acuífero. Dada esta relevancia, y ante la carencia de información continua y precisa, se ha considerado implementar nuevas herramientas tecnológicas, como los métodos de IA, para mejorar la estimación del almacenamiento subterráneo.

Por estas razones, el acuífero Conejos Médanos fue seleccionado para esta investigación, con el objetivo de ofrecer un enfoque alternativo, mediante el uso de IA, que pueda proporcionar datos más actualizados y precisos. Esto no solo contribuirá al conocimiento sobre la situación actual del

acuifero, sino que también podría ser un punto de referencia para evitar desequilibrios futuros en la disponibilidad de agua y promover una gestión más sostenible del recurso.

2.3. Recopilación de datos

Si bien contar con grandes volúmenes de datos, con variaciones que oscilan entre 200,000 y 6 millones de registros por variable, podría parecer una ventaja para abordar problemas complejos, la realidad es que esto también presenta desafíos importantes. Según diversos autores (Provost y Fawcett, 2013; McKinney, 2012; Géron, 2019), una parte sustancial del tiempo en cualquier investigación se dedica a la preparación y adecuación de los datos antes de implementar las Redes Neuronales Artificiales (ANN). Este proceso es crucial para asegurar un funcionamiento óptimo de los modelos de aprendizaje profundo. Por lo tanto, disponer de una gran cantidad de datos no siempre facilita la resolución de problemas; de hecho, puede implicar un esfuerzo considerable en la fase de preprocesamiento. No obstante, una vez que se ha superado este desafío y se ha logrado una manipulación adecuada de la estructura espacio-temporal de los datos, es posible avanzar hacia la implementación de arquitecturas de Inteligencia Artificial para abordar el problema de manera eficaz.

Dado que esta investigación parte del supuesto de la falta de parámetros físicos para la estimación o predicción del almacenamiento de agua subterránea, los retos se centran en la selección adecuada de las variables de entrada que permitan una predicción óptima del GWS. En este contexto, las variables de entrada han sido seleccionadas principalmente en función de la disponibilidad de datos. Entre las variables clave identificadas se incluyen: el almacenamiento de agua subterránea derivado de GRACE, un modelo avanzado que integra observaciones satelitales y terrestres; 10 tipos de evaporación proporcionados por el modelo GLEAM; la precipitación registrada por el modelo CHIRPS; y la temperatura estimada por el modelo ERA.

A continuación, en la Tabla 2.3.1 se listan las variables en orden de captura. La primera columna etiquetada como *Var* identifica la clave de las variables, donde T corresponde a temperatura, E a evaporación, P a precipitación y GWS al almacenamiento de agua subterránea. En la segunda (*Web*) columna se encuentra el nombre de los satélites de donde se obtuvieron los datos, acompañados de un enlace a los respectivos servidores de descarga. En las columnas siguientes se especifica el intervalo de tiempo, la unidad de medida, los períodos orbitales y la resolución espacial de cada variable.

Var	Web	Fecha Ini	Fecha Fin	Unidad	Periodo	Resolución espacial
T	ERA	01-01-1950	31-05-2023	Grados k	Hora	$0.01^\circ = 1.111\text{km}$
E	GLEAM	01-01-1980	31-12-2022	mm	Día	$0.25^\circ = 27.775\text{km}$
P	CHIRPS	01-01-1981	18-05-2023	mm	Día	$0.05^\circ = 5.555\text{km}$
GWS	GRACE	01-02-2003	31-12-2022	mm	Día	$0.25^\circ = 27.775\text{Km}$

Tabla 2.3.1: Detalles de las fuentes de datos para las variables de temperatura (T), evaporación (E), precipitación (P), y almacenamiento de agua subterránea (GWS). La tabla incluye las fuentes web, rangos de fechas de los datos disponibles, unidades de medición, periodos de recolección y resolución espacial.

Todas las imágenes tienen una cobertura global y son archivos NetCDF (Network Common Data Form). NetCDF es el formato estándar de Open Geospatial Consortium, diseñado para la creación, respaldo y acceso a los datos científicos multidimensionales (UCAR, 2023; MetaData, 2023). Este archivo contiene dos secciones que se almacenan como matrices (variables y dimensiones) y otra de texto (atributos o metadatos) (ESRI, 2023). Por sus características, los NetCDF pueden contener la parte espacial n veces por cada t en un intervalo de tiempo. Por ejemplo, la descripción de la imagen ERA5 que se muestra en la Figura 2.3.1, contiene 87,648 matrices de 16×16 con valores de temperatura.

```

► Dimensions:      (longitude: 16, latitude: 16, time: 87648)
▼ Coordinates:
  longitude (longitude) float32 -107.5 -107.4 ... -106.1 -106.0
  latitude  (latitude)  float32  32.0 31.9 31.8 ... 30.7 30.6 30.5
  time      (time)      datetime64[ns] 2002-01-01 ... 2011-12-31T23:00:00
▼ Data variables:
  t2m      (time, latitude, longitude) float32 ...
▼ Indexes:
  longitude PandasIndex
  latitude  PandasIndex
  time      PandasIndex
▼ Attributes:
  Conventions : CF-1.6
  history :     2021-12-09 22:47:18 GMT by grib_to_netcdf-2.23.0: /opt/ecmwf/mars-client/bin/grib_to
                _netcdf -S param -o /cache/data4/adaptor.mars.internal-1639087562.1364026-18423-
                1-fe889a7c-2fb5-4acd-80ee-9d8b5e366ad7.nc /cache/tmp/fe889a7c-2fb5-4acd-80ee-9
                d8b5e366ad7-adaptor.mars.internal-1639071637.3941236-18423-1-tmp.grib

```

Figura 2.3.1: Descripción del archivo NetCDF generado por ERA5, mostrando dimensiones, coordenadas y variables de datos relevantes. Datos leídos y visualizados utilizando la librería xarray en Python.

2.3.1. Datos ERA

ERA5 es el quinto reanálisis del Centro Europeo de Predicción Meteorológica a Medio Plazo (ECMWF por sus siglas en inglés, *European Centre for Medium-Range Weather Forecasts*) que abarca el clima global durante las últimas ocho décadas. Contiene datos en una malla regular de cobertura

global, una resolución espacial de 9 km^2 y temporal horaria. Iniciado a principios de 2016, el proyecto hizo públicos los datos climáticos en enero de 2019 (Hersbach y cols., 2023).

El reanálisis del ECMWF es la base de los boletines climáticos mensuales del Servicio de Cambio Climático Copernicus (C3S). Este reanálisis incluye alrededor de 50 variables, entre las cuales se seleccionó la temperatura del aire en la superficie para este estudio. Este conjunto de datos es catalogado como un reanálisis debido a su capacidad para combinar observaciones obtenidas de diversos sensores, como estaciones terrestres, radares, satélites geoestacionarios y polares, aviones, embarcaciones, boyas y radiosondas, con datos de modelos atmosféricos dinámicos. Estos modelos incorporan principios físicos para recrear las condiciones reales a nivel global (Muñoz Sabater, 2019).

El número de observaciones asimiladas por ERA en 1979 fue de aproximadamente 0.75 millones por día, mientras que para finales de 2018 aumentó a 24 millones diarios. Para el 1 de enero de 2015, alrededor de 40,000 usuarios en todo el mundo habían descargado los datos de ERA-Interim, convirtiéndolo en el repositorio climático más accesible (Hersbach y cols., 2019).

2.3.2. Datos CHIRPS

El conjunto de datos de Precipitación infrarroja con estaciones (CHIRPS, *Climate Hazards group Infrared Precipitation with Stations*) es una base de datos observacional de escala casi global (50°S - 50°N y todas las longitudes), que integra datos de observaciones de estaciones en superficie con datos satelitales de precipitación con resolución de 0.05° . Su resolución espacial se asemeja a la de otros satélites, empleando una malla regular con intervalo diario, y se encuentra disponible desde 1981 hasta la actualidad con un desfase de un mes. CHIRPS hace uso de datos del infrarrojo térmico (TIR) y datos de precipitación de varios satélites, como los de la NOAA, *Rainfall Estimates* (RFE2) y, para la validación, utiliza información de TMPA (*Tropical Rainfall Measuring Mission Multi-satellite Precipitation Analysis*).

Dado que es una base de datos puramente observacional, no puede ser clasificada como reanálisis. Los datos, tanto satelitales como de estaciones en superficie, son capturados, filtrados, homogeneizados y reconstruidos estadísticamente por algoritmos rigurosos para obtener una base de datos confiable y de largo periodo. Los productos finales de CHIRPS han sido evaluados y comparados con otras bases de datos observacionales a nivel global, demostrando resultados favorables en la representación de la climatología y eventos extremos de precipitación (Funk y cols., 2015).

2.3.3. Datos GLEAM

El Modelo Global de Evaporación de la Tierra de Amsterdam (GLEAM) fue desarrollado y proporcionado por Miralles del Instituto Británico de Ciencias Geográficas de la Universidad de Bristol, Reino Unido (Martens y cols., 2017). Es una herramienta que aprovecha los datos satelitales para obtener información diaria sobre el flujo de evaporación en la Tierra, centrándose principalmente en la utilización de sensores que operan en el espectro de microondas. Fue desarrollado por

Miralles y cols. en 2011, y actualmente se encuentra en su versión 3, en la que se han actualizado las estimaciones de diversas variables, aunque se mantienen el algoritmo de pérdida de interceptación y el módulo de evaporación potencial. Desde su creación en 2011, el modelo ha seguido optimizándose y mejorando la representación de los procesos físicos (Martens y cols., 2017).

La evapotranspiración terrestre representa el flujo total de agua desde la superficie terrestre hacia la atmósfera, generalmente expresado en mm. Este proceso engloba tres componentes: (a) la transpiración, que es la evaporación del agua desde el interior de las hojas de las plantas, (b) la evaporación de suelos desnudos y (c) la evaporación de la precipitación interceptada. Además, el autor Miralles, Brutsaert, Dolman, y Gash menciona la sublimación, que se refiere a la contribución de las superficies cubiertas de nieve y hielo, donde el agua sólida se evapora también después de derretirse, debido a condiciones específicas de presión y temperatura (Jambon-Puillet y cols., 2018). La evaporación es un componente clave en el ciclo del agua y la energía en la Tierra (Jung y cols., 2010). Su cambio y flujo de calor latente asociado afecta el flujo de calor sensible al cambiar la temperatura de la superficie terrestre, lo que ocasiona significativas implicaciones en el calentamiento regional y global (Douville y cols., 2013). Representa el segundo proceso más importante en el ciclo hidrológico, después de la precipitación (Taikan y Shinjiro, 2006; Trenberth, Smith, Qian, Dai, y Fasullo, 2007).

GLEAM se divide en cuatro módulos: evaporación potencial, interceptación de lluvia, suelo y estrés. A través de estos módulos se derivan las siguientes variables: evaporación actual (E), evaporación del suelo (Eb), pérdida de interceptación (Ei), evaporación potencial (Ep), sublimación de nieve (Es), transpiración, evaporación de cuerpos de agua abiertos (Ew), estrés evaporativo (S), humedad de suelo de las raíces (SMroot) y humedad del suelo (SMsurf). Todos los conjuntos de datos se encuentran disponibles en una cuadrícula regular de 0.25° de latitud y longitud; con una resolución aproximada de 25×25 kilómetros y una frecuencia diaria (GLEAM, 2011)

2.3.4. Datos GRACE

El Experimento Climático y de Recuperación de la Gravedad (GRACE) es una misión conjunta de la NASA y el Centro Aeroespacial Alemán, lanzada el 17 de marzo de 2002. Este proyecto consta de dos satélites idénticos que orbitan la Tierra a una altitud aproximada de 500 kilómetros, manteniendo una separación de 220 kilómetros entre sí (Figura 2.3.4.1). Estas naves están diseñadas para medir la fuerza de gravedad que nos ancla al planeta, una fuerza que depende de la distribución de masa y la distancia entre los cuerpos involucrados (TELLUS, 2012).



Figura 2.3.4.1: Imagen de la NASA que muestra las dos naves espaciales del proyecto GRACE-FO orbitando sobre la Tierra. Fuente: (GRACE-FO, 2024).

ARSET (*Applied Remote Sensing Training*, (ARSET, 2020)) explica el funcionamiento de GRACE mediante la Figura 2.3.4.2, ilustrando cómo los satélites responden a anomalías gravitacionales. Inicialmente, ambos satélites se desplazan a una velocidad constante, manteniendo una separación estable. Al aproximarse a una región con mayor masa, como una montaña nevada, el satélite líder experimenta un incremento en la atracción gravitacional, lo que acelera su movimiento y altera la distancia entre los dos. Posteriormente, el segundo satélite atraviesa la misma anomalía gravitacional y experimenta variaciones similares. Finalmente, una vez superada la región de mayor masa, ambos satélites recuperan su separación original, restableciendo el equilibrio en su desplazamiento orbital (NASA, 2024).




Figura 2.3.4.2: Representación gráfica de cómo la misión GRACE mide las variaciones en la gravedad terrestre. Fuente: (NASA, 2024).

Los datos brutos de GRACE son solo mediciones constantes de la distancia entre los dos satélites,

registradas mediante dos tecnologías principales: un sistema de medición por microondas basado en el Sistema de Posicionamiento Global (GPS), que detecta las variaciones en la separación con una precisión de hasta un micrómetro, equivalente a una centésima del grosor de un cabello humano. Y acelerómetros sensibles que miden fuerzas no gravitacionales, como la resistencia atmosférica, permitiendo corregir las mediciones y aislar las variaciones debidas únicamente a cambios en el campo gravitacional (TELLUS, 2012).

2.3.4.1. De la gravedad terrestre a la estimación del almacenamiento de agua subterránea

No existen mediciones directas de aguas subterráneas mediante observaciones de teledetección (B. D. Tapley y cols., 2019). Sin embargo, es posible medir el desplazamiento del agua de un lugar a otro, tanto sobre como debajo de la superficie terrestre, en los océanos y en la atmósfera. Esta redistribución de masas origina cambios en la gravedad, que se interpretan como variaciones en el almacenamiento de aguas terrestres (Riebeek, 2012).

El TWS mide la variación de masa en la columna vertical de la Tierra (ver la Figura 2.3.4.1.1) y abarca diferentes componentes: el agua superficial, presente en ríos, lagos, embalses y humedales; la nieve y el hielo, almacenados en glaciares y capas de nieve; la humedad del suelo, contenida en las capas superficiales y profundas; el agua subterránea somera, almacenada en acuíferos por encima del lecho rocoso o capas impermeables; y el agua subterránea profunda, localizada en acuíferos confinados y en las fracturas del lecho rocoso, la cual también contribuye al campo gravitacional detectado por GRACE. Además, incluye otros componentes profundos, como agua atrapada en porosidades residuales del lecho rocoso (agua fósil) o en zonas de alta presión por debajo del nivel freático (ARSET, 2020).




Figura 2.3.4.1.1: Representación de cómo la misión GRACE mide cambios en el almacenamiento de agua terrestre, incluyendo agua superficial, nieve, humedad del suelo y aguas subterráneas. Copyright 2016 California Institute of Technology. Patrocinio gubernamental reconocido. Fuente: (ARSET, 2020).

La técnica gravimétrica empleada por GRACE no tiene un límite de profundidad definido; es capaz de identificar cualquier cambio de masa en la columna terrestre, siempre que sea significativo. Sin embargo, al detectar de manera conjunta todos los componentes de almacenamiento de agua, es necesario aislar específicamente el agua subterránea de las aguas superficiales y atmosféricas. Para este propósito, se utilizan modelos de superficie terrestre, como el *Catchment Land Surface*

Model (CLSM), integrado en el Sistema Global de Asimilación de Datos Terrestres (*Global Land Data Assimilation System*, GLDAS), que permite desagregar y analizar estos distintos componentes (Humphrey y cols., 2023).

Tal como se indica en las ecuaciones 1 y 2 (J. Zhang y cols., 2024; E. NASA, 2018).

$$\Delta TWS = \Delta GWS + \Delta SM + \Delta SWE + \Delta SW \quad (1)$$

$$\Delta GWS = \Delta TWS - (\Delta SM + \Delta SWE + \Delta SW) \quad (2)$$

Donde:

- ΔGWS : Cambio en el almacenamiento de agua subterránea (desconocido)
- ΔTWS : Cambio en el almacenamiento total de agua terrestre (GRACE).
- ΔSM : Cambio en la humedad del suelo (GLDAS).
- ΔSWE : Cambio en el equivalente de agua en nieve (GLDAS).
- ΔSW : Cambio en el agua superficial (GLDAS).

Los datos GWS proporcionan una cobertura global mensual en formato netCDF, proyectados a una cuadrícula de $0.5^\circ \times 0.5^\circ$ con un error estimado de 2 a 3 cm en la resolución de $1^\circ \times 1^\circ$ (NASA Jet Propulsion Laboratory (JPL) Tellus, 2018; Watkins y cols., 2015; Wiese y cols., 2016; Landerer y cols., 2020).

2.3.4.2. Conversión del almacenamiento al volumen de agua subterránea.

Las unidades de los datos procesados de GRACE se expresan en milímetros (mm), lo que significa que cada píxel de $0.25^\circ \times 0.25^\circ$ representa una área en la que, si toda el agua subterránea contenida en ese píxel se distribuyera uniformemente sobre su superficie, el valor en milímetros correspondería a la altura de esa columna de agua.

En los modelos de predicción presentados a continuación, las unidades de los datos permanecen inalteradas a lo largo del proceso. Cabe destacar que los modelos no dependen directamente de las unidades físicas de los datos para generar las predicciones. Sin embargo, durante la revisión de diversas investigaciones relacionadas con el GWS, se observó que los resultados, en algunos casos, son expresados en metros cúbicos (m^3). Esto sugiere la necesidad de detallar una conversión que convierta los valores en dichas unidades, si así se requiere.

A continuación se muestra un ejemplo de conversión de milímetros a metros cúbicos (mm a m^3) en el contexto del GWS. Para ilustrar este proceso, se seleccionó una imagen del día 02 de septiembre de 2019, obtenida del archivo fuente en formato netCDF, de los modelos de Datos GLDAS. En la Figura 2.3.4.2.1, se presentan los valores del almacenamiento de Agua Subterránea por píxel para el área de estudio, así como la delimitación del acuífero de Conejos Médanos. Asimismo,

en la figura se incluye una anotación que indica un valor promedio del GWS de 453.301 mm , el cual representa el almacenamiento promedio del agua subterránea en el área de estudio. Esta información será utilizada como referencia para la conversión a m^3 .

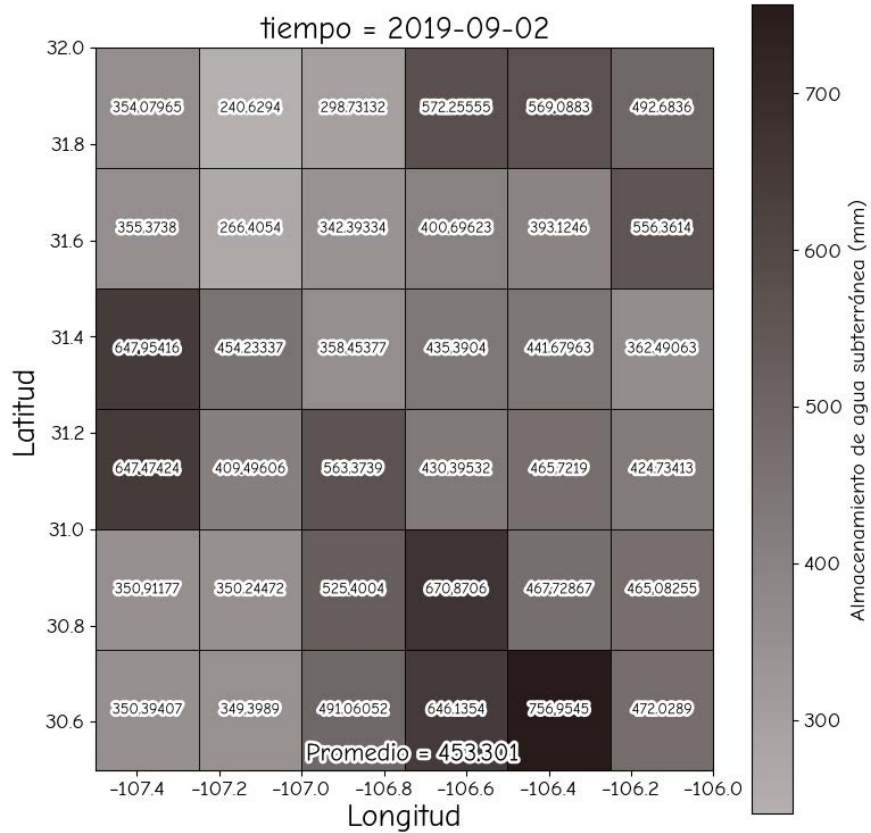


Figura 2.3.4.2.1: Ráster del área de estudio mostrando la distribución espacial del Almacenamiento de Agua Subterránea (GWS) el día 2019-09-02, en una cuadrícula de 6×6 . Cada píxel está etiquetado con los valores de GWS, representados mediante una escala de grises donde los tonos más claros indican menor GWS y los más oscuros, mayor GWS. Las coordenadas en el eje X corresponden a la longitud y en el eje Y a la latitud.

Para calcular el volumen de agua subterránea de un píxel en específico en m^3 , se emplea la metodología sugerida por la NASA. Este procedimiento incluye la conversión de grados a radianes (Ec.3) para calcular el área correspondiente a un píxel en la superficie de la Tierra (Ec.4). Posteriormente, para determinar el volumen de agua subterránea, se multiplica el área del píxel por el espesor del agua subterránea, que se expresa en milímetros (Ec.5).

- Radio promedio de la Tierra

$$R \approx 6,371 \text{ km}$$

- Conversión de grados a radianes

$$\text{radianes} = \text{grados} \times \frac{\pi}{180} \tag{3}$$

Calculando la ecuación 3 para un píxel de $0.25^\circ \times 0.25^\circ$

$$\Delta\theta = \Delta\phi = 0.25^\circ \times \frac{\pi}{180} \approx 0.0043633 \text{ radianes}$$

- Cálculo del área del píxel

$$A = R^2 \cdot \Delta\theta \cdot \Delta\phi \quad (4)$$

Sustituyendo en A :

$$A = (6,371,000 \text{ m})^2 \times 0.0043633 \text{ rad} \times 0.0043633 \text{ rad} \approx 9.675 \times 10^8 \text{ m}^2$$

- Para convertir el grosor de agua 453.301 mm a un volumen en m^3

Grosor (en metros) = Grosor (en mm) \times 0.001

$$V = A \times \text{Grosor} \quad (5)$$

Sustituyendo en V :

$$V_{450} = 9.675 \times 10^8 \text{ m}^2 \times 0.453301 \text{ m} = 4.385 \times 10^8 \text{ m}^3$$

El promedio del volumen de agua subterránea para el día 2 de septiembre de 2019 es de 453.912 mm por píxel de $0.25^\circ \times 0.25^\circ$. Para obtener un cálculo aproximado del volumen total de agua subterránea en el área de estudio, es posible multiplicar este valor promedio por el número total de píxeles en la imagen, que en este caso son 36 píxeles. Alternativamente, se puede calcular el volumen individual para cada píxel y luego realizar la suma total para obtener una estimación más precisa.

A continuación, se presenta un ejemplo detallado del cálculo para convertir este valor en volumen total de agua subterránea, expresado en metros cúbicos (m^3):

1. Área del píxel A

$$A \approx 9.675 \times 10^8 \text{ m}^2$$

2. Grosor convertido a metros

$$\text{GWS} = 453.912 \text{ mm} = 0.453912 \text{ m}$$

3. Volumen de agua en un píxel

$$V = A \times \text{Grosor} = 9.675 \times 10^8 \text{ m}^2 \times 0.453912 \text{ m} \approx 4.392 \times 10^8 \text{ m}^3$$

4. Volumen total para 36 píxeles, (resolución 6×6 de los datos GRACE)

$$V_{\text{total}} = 4.392 \times 10^8 \text{ m}^3 \times 36 \approx 1.581 \times 10^{10} \text{ m}^3$$

es decir, 15.81 mil millones de metros cúbicos.

2.4. Métodos de Inteligencia Artificial (IA)

La Inteligencia Artificial, término introducido por John McCarthy en 1950, se entiende comúnmente como la capacidad de las máquinas para ejecutar cualquier tarea intelectual equivalente a las habilidades humanas (Macpherson y cols., 2021; Ponce y cols., 2014). Sin embargo, es importante abordar este concepto de manera progresiva.

Las máquinas inteligentes pueden ejecutar tareas repetitivas, pero es particularmente notable su capacidad para aprender y adaptar su comportamiento. Por ejemplo, considera una máquina que, al reconocer la imposibilidad de apilar más cajas, decide comenzar una nueva columna. Asimismo, plataformas de streaming como Netflix y Spotify, y el comercio electrónico de Amazon, emplean algoritmos de inteligencia artificial para personalizar recomendaciones basándose en selecciones previas de los usuarios.

El Aprendizaje Automático, también conocido por su acrónimo en inglés *Machine Learning* (ML), constituye la piedra angular de la Inteligencia Artificial. Su enfoque radica en que las máquinas adquieren conocimiento a través de algoritmos que analizan grandes volúmenes de datos, lo que les permite identificar patrones y realizar tareas como clasificación, regresión o agrupamiento. El rendimiento de estos modelos se evalúa mediante la pérdida o métrica, que en regresión significa medir el desajuste de los datos con respecto a los valores esperados. Al final, un modelo de ML concluye la tarea para la que fue entrenado, operando con datos invisibles, es decir, aquellos que no formaron parte de los datos iniciales de entrenamiento (Mitchell, 1997).

El ML se divide en tres categorías: supervisados, no supervisados y por refuerzo (Algren y cols., 2021). Los problemas de aprendizaje supervisado se caracterizan por tareas como la clasificación o el reconocimiento de patrones, donde el resultado deseado ya está definido y el modelo se entrena utilizando una gran cantidad de datos etiquetados (existe una o más variables independientes y una variable dependiente). Por otro lado, en el aprendizaje no supervisado, el objetivo es descubrir relaciones subyacentes en los datos. Aquí, no existen etiquetas predefinidas, ni una correspondencia directa entre la entrada y la salida, lo que lo hace de naturaleza independiente. Los algoritmos de aprendizaje automático por refuerzo producen planes o cursos de acción, tomando decisiones a fin de lograr los mejores resultados, imitando el proceso de aprendizaje por ensayo y error; optimizados dado un conjunto de restricciones o un sistema de recompensas (Murphy, 2021).

Una subárea del ML es DL, nombre que se le da a las técnicas de ML que emplean redes neuronales artificiales profundas a gran escala para no solo aprender conceptos, sino también entender entornos complejos de datos no estructurados como el reconocimiento de imágenes y voz, el procesamiento del lenguaje natural y los sistemas autónomos (Jeon y cols., 2021).

El aprendizaje profundo, también conocido como *Deep Learning* (DL), fue pensado en el funciona-

miento y estructura del cerebro humano, donde los nodos interconectados simbolizan las neuronas y los niveles de aprendizaje se corresponden con las capas (Taye, 2023). A medida que aumenta el número de capas, el aprendizaje se vuelve más profundo. Esto permite que una Red Neuronal Artificial (RNA) descubra estructuras intrincadas en grandes conjuntos de datos. El algoritmo de retropropagación de las RNA guía a la máquina sobre cómo ajustar sus parámetros internos, los cuales se utilizan para calcular la representación en cada capa basada en la representación de la capa anterior. El DL ha demostrado su eficacia en el procesamiento de imágenes, video, voz y audio, con las redes neuronales convolucionales, mientras que las redes neuronales recurrentes han mostrado su eficacia en el análisis de datos secuenciales, como texto y voz (Lecun y cols., 2015).

De acuerdo con la literatura, el método más aplicado en la estimación de agua subterránea es el Perceptrón Multicapa ((Nearing y cols., 2021; Sahoo y cols., 2017) seguido por las CNN y las redes de memoria a corto plazo (LSTM por su acrónimo en inglés *Long short-term memory*) (Afzaal y cols., 2020; Shen, 2018; Kratzert y cols., 2019). Algunos estudios también combinaron la teledetección de GRACE con el algoritmo de bosques aleatorios conocido por su acrónimo en inglés *Random Forest* (RF) de ML (L. Chen y cols., 2019).

Esta investigación elige probar los modelos más utilizados, siguiendo las recomendaciones de estudios previos que indican la posibilidad de hallar soluciones efectivas incluso en arquitecturas más sencillas. Aunque en este caso no se optó por las opciones más simples, el proceso de programación y ejecución reveló resultados interesantes. Los modelos empleados se describen a continuación, en el orden siguiente: 1) Perceptrón Multicapa, la arquitectura más sencilla utilizada para programar los primeros modelos base, explorar las variables disponibles y obtener las primeras estimaciones. 2) Bosques Aleatorios, empleados para identificar las variables más predictivas y reducir la complejidad en los modelos subsecuentes. 3) Red Neuronal Convolucional, que integra la dimensión espacial de las imágenes. 4) Red Neuronal Recurrente, específicamente Long Short-Term Memory (LSTM), usada para manejar la temporalidad de los datos y evaluar su potencial predictivo para el GWS, específicamente para determinar si este se puede predecir sin la intervención de otras variables climáticas. 5) Red Neuronal Convolucional Recurrente (CRNN), una arquitectura que combina ambas dimensiones, temporal y espacial, de los datos para mejorar la precisión de las predicciones.

2.4.1. Multilayer Perceptron (MLP)

El perceptrón, desarrollado por Rosenblatt en 1958, es uno de los primeros modelos de redes neuronales artificiales que constituye una parte fundamental en el desarrollo del aprendizaje automático. Inspirado en el funcionamiento de las neuronas biológicas del cerebro humano, este modelo ha evolucionado y adaptado su estructura para abordar problemas específicos, como la estimación o predicción del almacenamiento de agua subterránea. Su representación (Figura 2.4.1.1) incluye los siguientes parámetros:

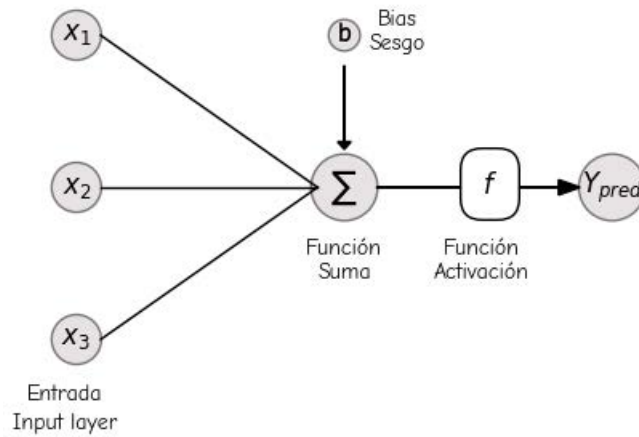


Figura 2.4.1.1: Diagrama de un perceptrón, el núcleo de construcción fundamental de las redes neuronales. Los inputs X_1, X_2, X_3 son sumados ponderadamente junto con un sesgo b en la función de suma. El resultado es luego pasado a través de una función de activación f , produciendo la salida Y_{pred} .

- a) Entradas: Son los valores, características o atributos que se introducen en la red. En este caso, las entradas son X_1, X_2, X_3 , correspondientes a la temperatura máxima, la temperatura media y la temperatura mínima, respectivamente.
- b) Pesos: Representan los coeficientes asignados a cada entrada o característica, que determinan su influencia en la neurona.
- c) Sesgo: Es un valor adicional que permite a la función de activación desplazarse en una dirección específica, ajustando el resultado final.
- d) Función de suma: Calcula la suma ponderada de todas las entradas y sus respectivos pesos.
- e) Función de activación: Es crucial para introducir la no linealidad en el modelo, permitiendo que la red neuronal aprenda y represente relaciones complejas entre las variables.
- f) Salida: El valor predicho Y_{pred} que en este contexto representa el almacenamiento de agua subterránea, calculado a partir de los valores de temperatura de entrada X_i

La Ecuación 6 formaliza el cálculo mostrado en el diagrama anterior, donde la función de una neurona $g(x)$ es igual a la sumatoria ponderada de los valores de entrada x multiplicados por sus respectivos pesos, sumando el término del sesgo. Donde w_i son los pesos, x_i los valores de entrada, y b el término de sesgo.

$$g(x) = \sum_{i=1}^n w_i x_i + b \quad (6)$$

Un Perceptrón Multicapa (MLP) es una red neuronal artificial que pertenece a las redes *feedforward* (también conocidas como redes de propagación hacia adelante). En estas redes, la información fluye exclusivamente en una dirección: desde la capa de entrada, a través de las capas ocultas (si las hay) y, finalmente, hacia la capa de salida. Cada neurona en una capa está conectada a todas las neuronas de la capa siguiente, transmitiendo sus resultados de manera unidireccional, sin ciclos ni conexiones de retroalimentación (Goodfellow y cols., 2016).

La Figura 2.4.1.2 ilustra un MLP completamente conectado. Este modelo consta de una capa de entrada con 3 neuronas, correspondientes a las variables del vector de entrada $\vec{x} = \{x_1, \dots, x_n\}$. Los valores ingresan a una capa oculta l_i con 100 neuronas (h_1, \dots, h_{100}), donde se procesan mediante funciones de activación f . La red termina en una capa de salida o con una sola neurona, cuyo valor es la predicción final del modelo. A continuación, se describe el flujo de información a través de esta estructura.

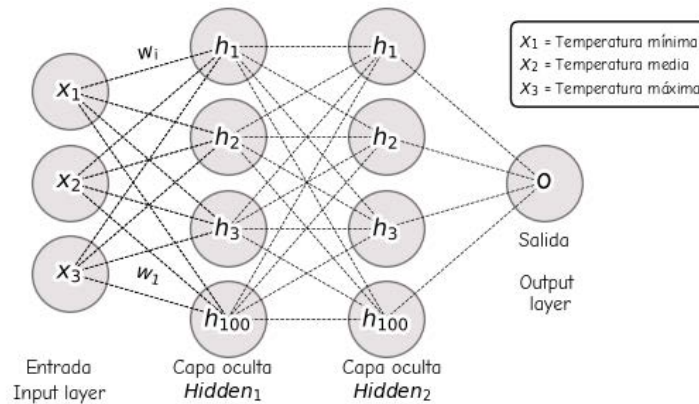


Figura 2.4.1.2: Estructura de una red neuronal artificial multicapa utilizada para predecir la temperatura basada en tres variables de entrada: temperatura mínima (X_1), temperatura media (X_2), y temperatura máxima (X_3). La red contiene dos capas ocultas (H_1 y H_2), cada una con 100 neuronas, indicando el proceso de transformación de datos a través de conexiones ponderadas (w_i) antes de llegar a la capa de salida.

1. **Propagación hacia adelante.** Cada perceptrón en la capa l_i está conectado a cada perceptrón en la capa l_{i-1} . Las capas están totalmente conectadas, lo que implica que las salidas dependen de todos los perceptrones de la capa anterior. Como se ilustra en la Figura 2.4.1.3 en cada capa se calcula la suma ponderada (Ec. 6) y se aplica la función de activación (Ec. 7). En lo concerniente a nuestros datos, esta arquitectura emplea la función de activación de tangente hiperbólica (Tanh) en las capas intermedias u ocultas, mientras que para la salida se aplica la función ReLU (8 Unidad Lineal Rectificada)

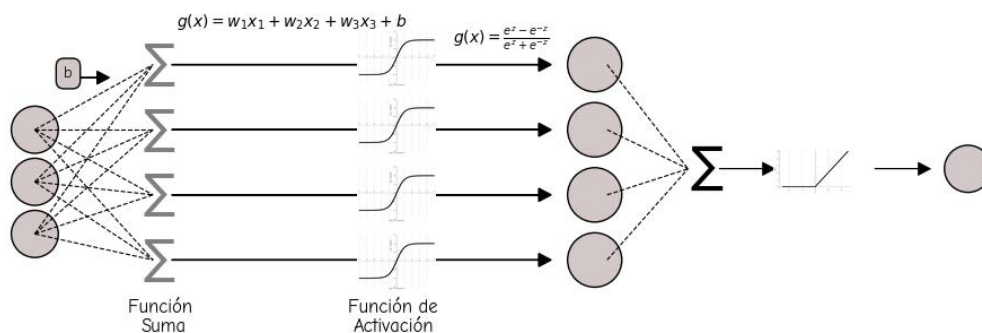


Figura 2.4.1.3: Diagrama de una red neuronal artificial que ilustra el proceso de transformación de la señal a través de la red. Las entradas X_1, X_2, X_3 son combinadas en una función suma ponderada por sus respectivos pesos W_1, W_2, W_3 y un sesgo b , cuyo resultado se pasa a través de una función de activación sigmoide, $g(x) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$, para cada neurona en la capa oculta. Los resultados activados son luego sumados en la capa de salida para producir la señal final. Este modelo visualiza el flujo de datos y la transformación a lo largo de la red, destacando las operaciones clave en cada paso.

2. La **Función de activación** es una expresión matemática que determina si una neurona se activa o no se activa en la red neuronal. Estas funciones son indispensables para introducir no linealidad a la red; sin ellas, la red neuronal se reduciría a un modelo de regresión lineal (Szandala, 2021).

- La Tangente Hiperbólica (tanh) es una función de activación no lineal, definida como el cociente entre el seno hiperbólico y el coseno hiperbólico de un número real x . Esto se expresa matemáticamente en la Ecuación 7, donde su dominio abarca $(-\infty, \infty)$. Dado que la función está centrada en cero y su rango oscila entre -1 y 1, sin incluir esos extremos (ver Figura 2.4.1.4), se utiliza principalmente en las capas ocultas de una red neuronal. Su media cercana a 0 ayuda a centrar los datos y facilitar el aprendizaje en la capa subsiguiente (Jindal y cols., 2022).

$$\text{Tanh } g(x) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad g(x) = (-1, 1) \quad (7)$$




Figura 2.4.1.4: Función tangente hiperbólica, esta función transforma los valores de entrada en un rango entre -1 y 1, lo que ayuda a modelar decisiones no lineales en las neuronas artificiales.

- La función de activación Unidad Lineal Rectificada (ReLU) establece cualquier entrada negativa en 0 y mantiene las entradas positivas sin cambios. Es una función lineal (Figura 2.4.1.5) que activa un nodo si su entrada es positiva; de lo contrario, emite un valor nulo, como se indica en la Ecuación 8. Esta simplicidad contribuye a la reducción de la carga computacional y mitiga el problema de la desaparición de gradientes. Sin embargo, puede llevar a la inactividad de algunas neuronas.

$$\text{Relu } g(x) = \max(0, x) \quad g(x) = \begin{cases} 0, & \text{si } x < 0 \\ x, & \text{si } x \geq 0 \end{cases} \quad (8)$$




Figura 2.4.1.5: Función de activación comúnmente usada en redes neuronales profundas. La ReLU activa una neurona solo cuando la entrada es positiva, lo que la hace eficiente para aumentar la no linealidad de los modelos sin afectar los valores de activación positivos.

3. **Cálculo del error.** Normalmente, el proceso de aprendizaje en la red implica evaluar globalmente el porcentaje de error, para evaluar el desempeño de un modelo. El **error** se define como la diferencia entre los valores observados (o_i) y los valores predichos (y_i) por el modelo. Su magnitud indica qué tan lejos están las predicciones de los valores reales, y su análisis permite identificar si el modelo está aprendiendo correctamente o si necesita ajustes adicionales (Bull, 2014).

Existen diversas métricas para cuantificar el error dependiendo del objetivo del análisis y la naturaleza de los datos. Las métricas ocupadas en los modelos que se describen más adelante son:

- **Error Absoluto Medio (MAE)** Ecuación 9: Toma el valor absoluto de las diferencias entre los valores previstos y reales, asegurando que tanto las sobreestimaciones como las subestimaciones respecto al valor objetivo contribuyan de igual manera al error (Belyadi y Haghighat, 2021). Al tratar todos los errores por igual, el MAE minimiza el impacto de los valores atípicos en la función de pérdida (Willmott y Matsuura, 2005).

$$MAE(X) = \frac{1}{N} \sum_{i=1}^N |o_i - y_i| = \frac{1}{N} \sum_{i=1}^N |g(\vec{w} \cdot \vec{x} + b) - y_i| \quad (9)$$

- **Error Cuadrático Medio (MSE)** Ecuación 10: El MSE mide el promedio de las diferencias al cuadrado entre los valores previstos y reales (Bull, 2014). Su cálculo es análogo a la medida estadística de la varianza (σ^2), permitiendo evaluar la incertidumbre alrededor del pronóstico más probable (\hat{y}^i). Al elevar las diferencias al cuadrado, penaliza de manera más significativa los errores grandes, lo que lo hace especialmente útil cuando se busca priorizar una alta precisión en la mayoría de los casos.

$$MSE(X) = \frac{1}{N} \sum_{i=1}^N (o_i - y_i)^2 = \frac{1}{N} \sum_{i=1}^N (g(\vec{w} \cdot \vec{x} + b) - y_i)^2 \quad (10)$$

El objetivo principal al calcular estas métricas es minimizar el error, lo cual indica que el modelo está aprendiendo correctamente las relaciones subyacentes en los datos. Cada métrica tiene fortalezas y debilidades, por lo que su selección depende del con-

texto del problema y de las características específicas de los datos. A continuación se describen sus términos:

N : Número total de muestras en el conjunto de datos.

o_i : Valor predicho por el modelo para la muestra i .

y_i : Valor real correspondiente a la muestra i .

$g(\vec{w} \cdot \vec{x} + b)$: Es la salida del modelo, donde: \vec{w} es el vector de pesos, \vec{x} es el vector de entrada y b es el sesgo o término independiente.

$|o_i - y_i|$: Diferencia absoluta entre el valor predicho y el valor real para el cálculo del *MAE*.

$(o_i - y_i)^2$: Diferencia al cuadrado entre el valor predicho y el valor real para el cálculo del *MSE*.

4. Retropropagación. El error se retropropaga desde la capa de salida hacia las capas ocultas y hasta la capa de entrada. Para maximizar la precisión de la red, es necesario minimizar su error ajustando los valores de \vec{w} y b . Esto se logra mediante el descenso del gradiente, un proceso iterativo que reduce el valor de la función de error hasta converger en un mínimo local. El descenso de gradiente, descrito en las Ecuaciones 11, es aplicable a cualquier función de error, no solo al error cuadrático medio. En el caso de un perceptrón simple, los valores de \vec{w} y b se actualizan en cada iteración i con base en la tasa de aprendizaje α . En el caso del *perceptrón multicapa*, las actualizaciones se vuelven más complejas, ya que las redes multicapa tienen más conexiones y capas. Por lo tanto, el índice i representa la neurona en la capa anterior, j la neurona en la capa siguiente, y el subíndice k indica a qué capa pertenece el peso o sesgo. Así, el peso w_{ij}^k representa la conexión entre la neurona i de la capa $k - 1$ con la neurona j de la capa k , y su actualización sigue la regla del descenso de gradiente, como se detalla en la Ecuación 11.

Este sistema de indexación es crucial en redes profundas, ya que cada capa puede tener múltiples neuronas conectadas con muchas otras neuronas en las capas adyacentes, requiriendo una actualización detallada de los pesos y sesgos en cada conexión.

$$\Delta w_{ij}^k = -\alpha \frac{\partial E(X)}{\partial w_{ij}^k} \quad ; \quad \Delta b_{ij}^k = -\alpha \frac{\partial E(X)}{\partial b_i^k} \quad (11)$$

Donde:

- $\Delta w_{ij}^{(k)}$ y $\Delta b_i^{(k)}$ son los ajustes aplicados al peso $w_{ij}^{(k)}$ y al sesgo $b_i^{(k)}$ en la capa k .
- α es la tasa de aprendizaje (*learning rate*), un hiperparámetro que controla el tamaño del paso de ajuste.
- $E(X)$ es la función de error calculada para el conjunto de datos X .
- $\frac{\partial E(X)}{\partial w_{ij}^{(k)}}$ y $\frac{\partial E(X)}{\partial b_i^{(k)}}$ son las derivadas parciales de la función de error con respecto al peso y

al sesgo, respectivamente.

Una vez que estos gradientes son calculados, se emplean para ajustar los valores de los pesos (w) y los sesgos (b) dentro de la red. Este ajuste se realiza mediante un algoritmo de optimización, generalmente el descenso por gradiente o alguna de sus variantes avanzadas. La actualización de los parámetros se guía por la siguiente fórmula general:

$$w_{ij}^{(k)} \leftarrow w_{ij}^{(k)} + \Delta w_{ij}^{(k)} \quad (12)$$

$$b_i^{(k)} \leftarrow b_i^{(k)} + \Delta b_i^{(k)} \quad (13)$$

Donde $\Delta w_{ij}^{(k)}$ y $\Delta b_i^{(k)}$ son los ajustes calculados usando el gradiente del error.

Una vez actualizados los parámetros, el proceso se reinicia con el siguiente lote de datos o la siguiente época, según corresponda. Este ciclo se repite a lo largo de múltiples épocas hasta que el error converge a un valor mínimo o se alcanza un criterio de parada predefinido. Cabe destacar que completar un pase por todos los datos del conjunto de entrenamiento se denomina una época.

5. **Evaluación del modelo.** Finalmente, se requiere evidencia que permita cuantificar y evaluar la asociación entre los resultados pronosticados por las redes neuronales y los datos reales. Este proceso implica el uso de métricas específicas que permitan medir la probabilidad de obtener resultados similares o más extremos que los observados, con el propósito de determinar si se acepta o rechaza la hipótesis nula. Las métricas empleadas dependen del tipo de problema abordado: en problemas de clasificación, se suelen utilizar métricas como la exactitud (*accuracy*); mientras que en problemas de regresión, se emplean métricas como el *MAE* o el coeficiente de correlación de *Pearson*, entre otras.

- El *accuracy* o exactitud en un problema de clasificación, es una métrica que mide el porcentaje de predicciones correctas sobre el total de predicciones (Ecuación 14). Es decir, qué tan a frecuente el modelo predice correctamente la clase de prueba. En este contexto, TP corresponde a los verdaderos positivos, TN son los verdaderos negativos, FP a los falsos positivos y FN a los falsos negativos.

$$\text{Accuracy} = \frac{\text{Número de predicciones correctas}}{\text{Número total de predicciones}} = \frac{TP + TN}{TP + TN + FP + FN} \quad (14)$$

- El coeficiente de correlación de *Karl Pearson*, es un parámetro estadístico ampliamente empleado (Palmer y cols., 2001) donde su calculo es independiente de cualquier unidad que se utiliza para medir las variables. Cuanto más cercano sea el valor del coeficiente a (+1), mayor será la asociación positiva entre las variables, indicando que el aumento de una variable está relacionado con el aumento de la otra. También pue-

de existir una relación lineal negativa total (-1), donde el aumento de una variable se asocia con la disminución de la otra. Por lo tanto, este coeficiente toma valores reales dentro de estos límites. La forma más común de calcular este coeficiente es mediante la Ecuación 15, donde x_i son los valores de entrada, y_i los valores pronosticados por la red y \bar{x}, \bar{y} son, respectivamente, los valores medios de las variables.

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (15)$$

El *P-value* es una medida estadística utilizada para evaluar la el nivel de confianza en las predicciones de modelos de aprendizaje automático (Lu y Ishwaran, 2017), determinando la significancia de los resultados observados en comparación con una hipótesis nula. Indica la probabilidad de obtener resultados tan extremos como los observados, asumiendo que la hipótesis nula (H_0) es verdadera. La Ecuación 16 describe el cálculo del puntaje Z , que estandariza la diferencia entre la media muestral (\bar{x}) y la media poblacional (μ), utilizando el error estándar de la media.

$$Z = \frac{\bar{x} - \mu}{\frac{\sigma}{\sqrt{n}}} \quad (16)$$

En esta ecuación:

\bar{x} : Representa la media de la muestra.

μ : Es la media poblacional o el valor esperado bajo H_0 .

σ : Es la desviación estándar poblacional, que mide la dispersión de los datos.

n : Es el tamaño de la muestra.

El puntaje Z permite calcular el valor P , que cuantifica la probabilidad de observar un puntaje igual o más extremo que Z . Si el valor P es menor que un nivel de significancia predefinido (α , comúnmente 0.05 o 5 %), se considera que la diferencia es estadísticamente significativa, lo que lleva al rechazo de la hipótesis nula (H_0). Por el contrario, si $P > \alpha$, no se rechaza H_0 , indicando que los resultados observados podrían ser consistentes con la hipótesis nula.

Al llegar a la etapa final, donde se comparan los valores reales con los predichos, puede surgir el fenómeno de sobreajuste (*overfitting*). El sobreajuste ocurre cuando un modelo de aprendizaje automático se ajusta excesivamente a los datos de entrenamiento, logrando un desempeño excelente en ellos, pero presentando un bajo rendimiento en los datos de validación o prueba, es decir, aquellos que no se han ocupado durante el entrenamiento. Este problema se identifica al graficar las funciones de pérdida durante el entrenamiento: si las curvas de entrenamiento y validación se superponen, indica que no hay sobreajuste. Sin embargo, si estas curvas se distancian considerablemente, existe una alta probabilidad de que se esté produciendo un sobreajuste o, en su defecto, un subajuste (Ying, 2019).

2.4.2. Random Forest (RF)

El bosque aleatorio se distingue por su estructura que incorpora múltiples árboles de decisión (ver Figura 2.4.2.1). Es decir, muchos árboles construidos de manera “aleatoria” y con la misma tendencia conforman un bosque aleatorio. Este es uno de los algoritmos más populares en el aprendizaje automático, utilizado tanto en tareas de clasificación como de regresión, y fue desarrollado por Breiman, Friedman, Stone, y Olshen en 1984. En los árboles estándar, cada nodo se divide utilizando la mejor división entre todas las variables. En un bosque aleatorio, cada nodo se divide utilizando el mejor valor de entre un subconjunto de predictores elegidos aleatoriamente en esos nodos. Esta estrategia ha demostrado ser más efectiva y robusta contra el sobreajuste en comparación con otros clasificadores, incluidos el análisis de máquinas de soporte vectorial y las redes neuronales (Breiman, 2001b).

En una Regresión de Bosques Aleatorios, el proceso comienza con un nodo raíz que incluye todas las observaciones y características continuas del conjunto de entrenamiento. Cada árbol se genera recursivamente a partir de un subconjunto de características seleccionadas aleatoriamente, y se extrae un subconjunto de datos al azar para dividirse nuevamente. Cada árbol realiza su propia predicción individual, y estas predicciones se promedian para producir un resultado único. El promedio de las predicciones hace que una RFR sea superior a un único árbol de decisión, mejorando así su precisión y reduciendo el sobreajuste. El algoritmo finaliza cuando se cumple una condición predeterminada, como cuando todas las muestras de un nodo pertenecen a una misma clase o cuando no quedan atributos disponibles para realizar más divisiones (Kuhn y Johnson, 2013).

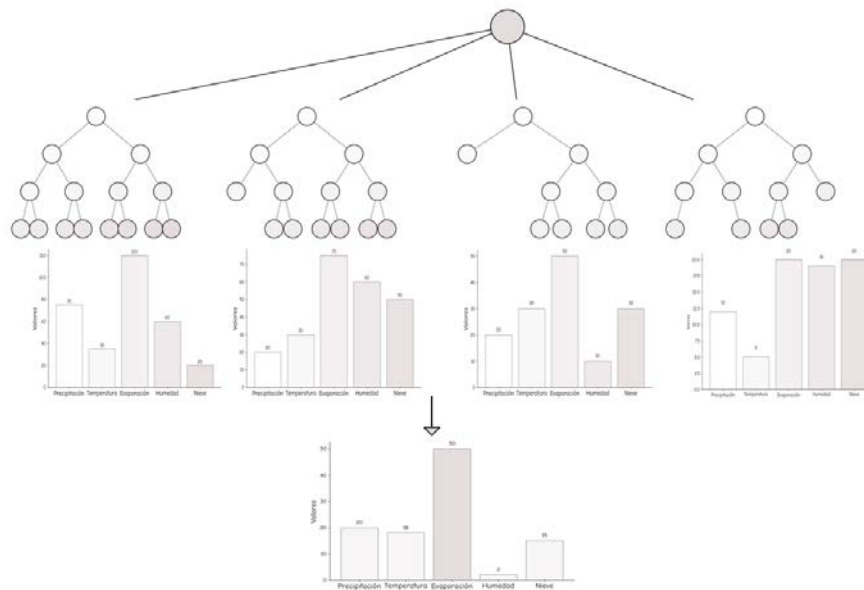


Figura 2.4.2.1: Estructura de un Bosque Aleatorio aplicado a la predicción del clima, donde cada árbol se caracteriza por nodos que siempre se bifurcan en dos ramas. Esta representación muestra la importancia relativa de diferentes variables como precipitación, temperatura, evaporación, humedad y nieve. Las barras indican la influencia de cada variable, con valores más altos señalando una mayor contribución a la precisión del modelo.

En los problemas de regresión, RF utiliza un conjunto de árboles de decisión para combinar sus respuestas y generar una estimación de la variable dependiente. Dado un vector de entrada X , RF construye K árboles de regresión $h_k(X)$. La predicción final del modelo se obtiene promediando las predicciones de todos los árboles en el bosque. La Ecuación 17 describe matemáticamente este proceso,

$$RFR_{prediction} = \frac{1}{K} \sum_{k=1}^k h_k(X), \quad (17)$$

donde K es el número total de árboles y $h_k(X)$ es la predicción de cada árbol.

Los árboles de decisión en RF se construyen mediante una técnica de agregación conocida como el método de Bootstrap Aggregating o Bagging. En el proceso de Bagging, se toma una muestra aleatoria de datos del conjunto de entrenamiento con reemplazo en cada nodo dentro de cada árbol. El *reemplazo* implica que un mismo punto de datos puede ser seleccionado varias veces en el conjunto de datos remuestreado.

Las muestras que no son seleccionadas para entrenar el árbol k_i en el proceso de Bagging se incluyen en otro subconjunto denominado *datos fuera de la bolsa* (OOB, por sus siglas en inglés). Estos datos OOB se utilizan para evaluar el rendimiento de la regresión en RF. Dado que aproximadamente un tercio de los datos se selecciona en promedio, se evalúa el rendimiento mediante el error cuadrático medio, el cual puede converger a medida que se aumenta el número de árboles en el conjunto. (Breiman, 2001b).

2.4.3. Convolutional Neural Networks (CNN)

Las Redes Neuronales Convolucionales (CNN o ConvNet) representan un enfoque predominante en el aprendizaje profundo, especialmente en aplicaciones de visión por computadora. A diferencia del aprendizaje automático (ML), donde las características frecuentemente dependen en gran medida de la experiencia de un experto, las CNN permiten que el algoritmo seleccione automáticamente estas características sin la necesidad de conocimiento previo sobre cuáles podrían ser las más útiles para lograr un objetivo específico (Lecun y cols., 1998). Por esta razón, las CNN son potentes clasificadores de imágenes, superando por primera vez a un humano en un desafío de reconocimiento de objetos en 2015 (He y cols., 2015).

De manera general, las CNN utilizan un sistema jerárquico; las primeras capas (aquellas justo después de la capa de entrada) detectan características simples o de bajo nivel (bordes y manchas en las imágenes) y las capas posteriores se combinan para formar características de alto nivel que pueden resultar en formas más complejas, como los contornos de un objeto (edificios, perros, gatos, muebles, personas, etc.) (Fieres y cols., 2006).

El modelo CNN consta de seis componentes principales (ver Figura 2.4.3.1): 1) Capas Convolucionales, donde se aplican filtros para extraer características espaciales de la imagen; 2) Capas de

Agrupación o *Pooling*, que reducen la dimensionalidad; 3) Función de Activación como ReLU para introducir no linealidad; 4) Capa de *Flatten*, que convierte la salida en un vector; 5) Capa Completamente Conectada, y 6) Capa de Salida, que realiza la predicción final (Indolia y cols., 2018). A continuación, se describen estos componentes en mayor detalle.

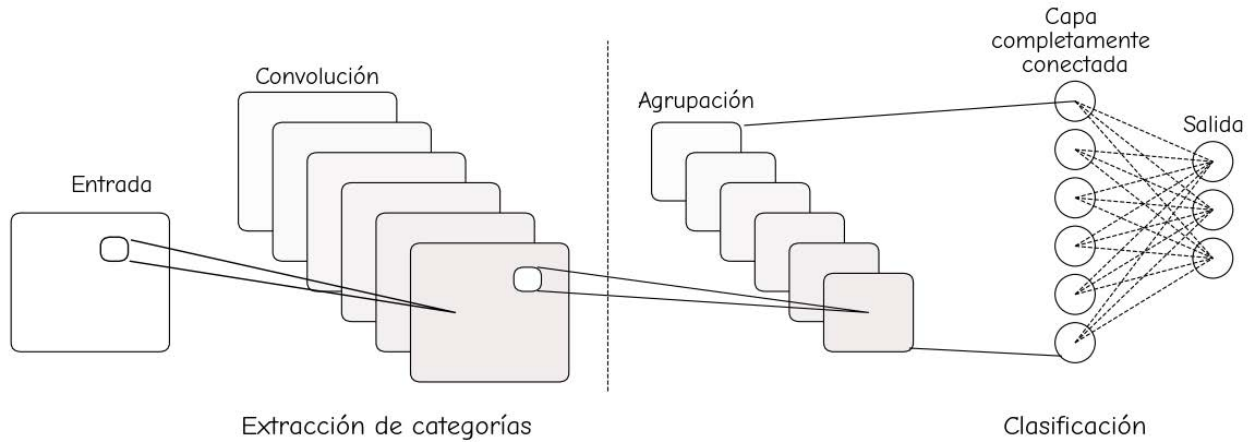


Figura 2.4.3.1: Diagrama de la estructura básica de una Red Neuronal Convolutiva (CNN). Comienza con la capa de entrada que procesa las imágenes. Sigue con múltiples capas de convulsión que detectan características visuales, seguidas de capas de agrupación (pooling) que reducen la dimensionalidad de los datos. La red concluye con capas completamente conectadas que facilitan la clasificación final en la capa de salida. Este flujo muestra cómo las imágenes son transformadas y categorizadas en una CNN.

Capa convulsional (*Convolution layer*). Esta capa genera etiquetas a partir de la extracción de características mediante un campo receptivo local (J. Fang y cols., 2016). El proceso clave que utiliza esta capa es la **convulsión**, que consiste en aplicar un filtro o kernel sobre una imagen de entrada (o mapa de características) y calcular una nueva representación basada en la multiplicación punto a punto entre los valores del filtro y los valores de la imagen, seguido de la suma de esos productos. Este proceso permite a la red detectar patrones locales como bordes, texturas o esquinas en una imagen, generando un *mapa de características* que destaca las características importantes.

La convulsión se puede describir matemáticamente como:

$$(f * g)(t) = \sum_a f(a) \cdot g(t - a) \quad (18)$$

En el contexto de una red neuronal convulsional, la Ecuación 18 toma la forma discreta para una imagen I y un filtro K , donde la convulsión es (Ec. 19):

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i - m, j - n) K(m, n) \quad (19)$$

Donde I es la imagen de entrada, K es el kernel (filtro), y $S(i, j)$ es el valor en la posición (i, j) del mapa de características resultante. El filtro se desplaza a lo largo de la imagen, y en cada posición

se realiza esta operación de multiplicación y suma, generando así el nuevo mapa de características.

Cada vez que el campo receptor se desplaza por la imagen de entrada, se conecta a una nueva posición en la capa convolucional y crea un vector de pesos. Todas las neuronas en la capa oculta comparten el mismo conjunto de pesos y sesgo. Esto permite detectar características similares en diversas ubicaciones de la imagen. Cuando el campo receptor ha barrido toda la imagen, las neuronas en la capa oculta proporcionan un mosaico completo de la imagen de entrada. A esta salida se le conoce como mapa de características, y a los pesos compartidos se les denomina filtro o kernel (Palsson y cols., 2017).

Al hacer una analogía con las imágenes de GRACE, cuya resolución es de 6×6 , se puede visualizar cada imagen como una matriz de valores numéricos que representan los datos asociados a cada píxel.

$$\begin{pmatrix} a_{11} & a_{12} & a_{13} & a_{14} & a_{15} & a_{16} \\ a_{21} & a_{22} & a_{23} & a_{24} & a_{25} & a_{26} \\ a_{31} & a_{32} & a_{33} & a_{34} & a_{35} & a_{36} \\ a_{41} & a_{42} & a_{43} & a_{44} & a_{45} & a_{46} \\ a_{51} & a_{52} & a_{53} & a_{54} & a_{55} & a_{56} \\ a_{61} & a_{62} & a_{63} & a_{64} & a_{65} & a_{66} \end{pmatrix}$$

El filtro es una pequeña matriz 3×3 que se desliza sobre la matriz de entrada.

$$\text{Filtro} = \begin{pmatrix} f_{11} & f_{12} & f_{13} \\ f_{21} & f_{22} & f_{23} \\ f_{31} & f_{32} & f_{33} \end{pmatrix}$$

La convolución se realiza posicionando el filtro sobre una submatriz de la matriz de entrada, calculando el producto punto (multiplicando y sumando los elementos correspondientes), y desplazando el filtro a la siguiente posición hasta cubrir toda la matriz de entrada. El tamaño de la salida dependerá del tamaño de la entrada, el filtro y si se utiliza *padding* o no.

Por ejemplo, si el filtro de 3×3 se coloca en la esquina superior izquierda de la matriz de entrada de 6×6 , el cálculo en la posición $(1, 1)$ se realizaría de la siguiente manera (Ec. 20).

$$\begin{aligned} \text{Salida}_{1,1} = & (a_{11} \cdot f_{11}) + (a_{12} \cdot f_{12}) + (a_{13} \cdot f_{13}) + \\ & (a_{21} \cdot f_{21}) + (a_{22} \cdot f_{22}) + (a_{23} \cdot f_{23}) + \\ & (a_{31} \cdot f_{31}) + (a_{32} \cdot f_{32}) + (a_{33} \cdot f_{33}) \end{aligned} \quad (20)$$

Este proceso se repite para todas las posiciones posibles del filtro sobre la matriz de entrada. Al

finalizar, se obtiene una matriz de salida más pequeña que la original. Si no se aplica *padding* (es decir, no se añaden bordes adicionales a la matriz de entrada), la salida de la convolución será de tamaño 4×4 , dado que se pierden filas y columnas en cada borde conforme el filtro se desplaza.

$$\begin{pmatrix} s_{11} & s_{12} & s_{13} & s_{14} \\ s_{21} & s_{22} & s_{23} & s_{24} \\ s_{31} & s_{32} & s_{33} & s_{34} \\ s_{41} & s_{42} & s_{43} & s_{44} \end{pmatrix}$$

El *padding* consiste en agregar filas y columnas de ceros alrededor de la matriz de entrada para mantener su tamaño después de aplicar la convolución (Ec. 21). Si se aplica un *padding* adecuado (generalmente de 1 en cada borde para un filtro de 3×3), el tamaño de la matriz de entrada puede conservarse tras la convolución.

$$\text{Salida} = \frac{\text{Tamaño de la entrada} + \text{Tamaño de la salida} + 2 \cdot \text{Padding}}{\text{Stride}} \quad (21)$$

Si volvemos a nuestra imagen de 6×6 y aplicamos un *padding* de 1 (agregar una capa de ceros alrededor de la matriz de entrada), la nueva matriz de entrada sería de tamaño 8×8 . Esto permite que la convolución se aplique sin perder filas o columnas en los bordes, y el tamaño de la salida se mantendrá igual al de la entrada original.

$$\begin{pmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & a_{11} & a_{12} & a_{13} & a_{14} & a_{15} & a_{16} & 0 \\ 0 & a_{21} & a_{22} & a_{23} & a_{24} & a_{25} & a_{26} & 0 \\ 0 & a_{31} & a_{32} & a_{33} & a_{34} & a_{35} & a_{36} & 0 \\ 0 & a_{41} & a_{42} & a_{43} & a_{44} & a_{45} & a_{46} & 0 \\ 0 & a_{51} & a_{52} & a_{53} & a_{54} & a_{55} & a_{56} & 0 \\ 0 & a_{61} & a_{62} & a_{63} & a_{64} & a_{65} & a_{66} & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{pmatrix}$$

Luego, al aplicar el filtro de 3×3 , la matriz de salida tendría el mismo tamaño que la matriz de entrada original, es decir, 6×6 , gracias al *padding* aplicado. Este proceso se puede observar claramente en la Figura 2.4.3.2, donde se muestra cómo la operación de convolución mantiene las dimensiones de la matriz de entrada tras el *padding*.




Figura 2.4.3.2: Aplicación de *padding* de 1 a una matriz de entrada de tamaño 6×6 . Tras el *padding*, la matriz se expande a 8×8 , permitiendo que la aplicación del filtro de 3×3 genere una matriz de salida con las mismas dimensiones que la matriz original (6×6).

Función de activación. Después de aplicar los filtros en las capas convolucionales, los mapas de características resultantes se pasan a las funciones de activación para adaptarse a las características no lineales de las imágenes de entrada (Tharsanee y cols., 2021). Una de las funciones más comunes en redes neuronales es ReLU (*Rectified Linear Unit*), que filtra las características menos relevantes al convertir los valores negativos en cero y mantener los positivos. Esto es crucial para procesar datos complejos como las imágenes GRACE de 6×6 , permitiendo que la red se enfoque en patrones importantes. Algunas de las funciones de activación más utilizadas se muestran a continuación en la Tabla 2.4.3.1 (Sanchez y cols., 2020).

Función de activación	Rango	Características	Inconvenientes
Sigmoid	[0,1]	Puede emplearse en la capa de salida para la clasificación binaria.	Problema de gradiente que desaparece.
Tanh	[-1,1]	Se puede aplicar a las capas ocultas de la red	Se produce un problema de gradiente que desaparece y se necesita más tiempo para lograr una predicción precisa
ReLU	[0,∞]	La función de activación de la unidad lineal rectificadora implica cálculos matemáticos comprensibles. Activa las neuronas basándose en la salida; en otras palabras, si la salida es menor que cero, las neuronas se inactivan en la red.	Existe la posibilidad de que el modelo no cuente con la capacidad de aprender a partir de los datos de entrada y que la red sea incapaz de realizar retropropagación
Softmax	[0,1]	La conjunción de sigmoideos produce la probabilidad de que los mapas de características o los puntos de datos estén asociados con una clase específica, y es especialmente útil en tareas de clasificación multiclase.	La operación de Softmax se lleva a cabo con notable facilidad en comparación con otras funciones de activación y carece de las limitaciones principales previamente mencionadas.

Tabla 2.4.3.1: Características de algunas de las funciones de activación más utilizadas

Capa de Agrupación (*Pooling Layer*). Las capas de agrupación suelen colocarse entre las capas convolucionales y su objetivo es reducir la dimensionalidad de los mapas de características, disminuyendo así la cantidad de parámetros en la red. Este submuestreo se realiza mediante una ventana que aplica una función para seleccionar el valor representativo dentro de esa área. Por ejemplo, la *max-pooling* selecciona el valor máximo de cada ventana, como se muestra en la Figura 2.4.3.3 (Indolia y cols., 2018).




Figura 2.4.3.3: Representación gráfica del proceso de pooling en el tratamiento de imágenes, utilizando una ventana de 2x2 para la selección de características. Las flechas indican cómo los valores máximos de cada subregión son seleccionados para formar una nueva matriz reducida, optimizando la red para procesos posteriores de clasificación o reconocimiento.

Aplanar (Flattening). Convierte la salida de las capas convolucionales o de *pooling* (que normalmente tienen múltiples dimensiones) en un vector unidimensional. Esto es esencial para que la información sea procesada correctamente por las capas densas o completamente conectadas que suelen seguir. Al realizar esta operación, se preserva la información espacial, pero se elimina la estructura multidimensional, facilitando la aplicación de funciones de clasificación o regresión en la capa final (ej. Figura 2.4.3.4) (Goodfellow y cols., 2016).




Figura 2.4.3.4: Representación del proceso de *flattening*, este paso transforma la matriz de datos bidimensional resultante del *pooling* en un vector unidimensional, preparando los datos para la entrada en la capa completamente conectada.

Capa completamente conectada (Fully-Connected Layer). Esta capa neuronal densa establece conexiones entre cada neurona con todas las neuronas de las capas adyacentes, utilizando pesos ajustables (ver Figura 2.4.3.5). El vector de entrada se somete a una transformación lineal y, posteriormente, pasa por una función de activación que genera un nuevo vector de salida, el cual será usado en la siguiente capa (Indolia y cols., 2018).

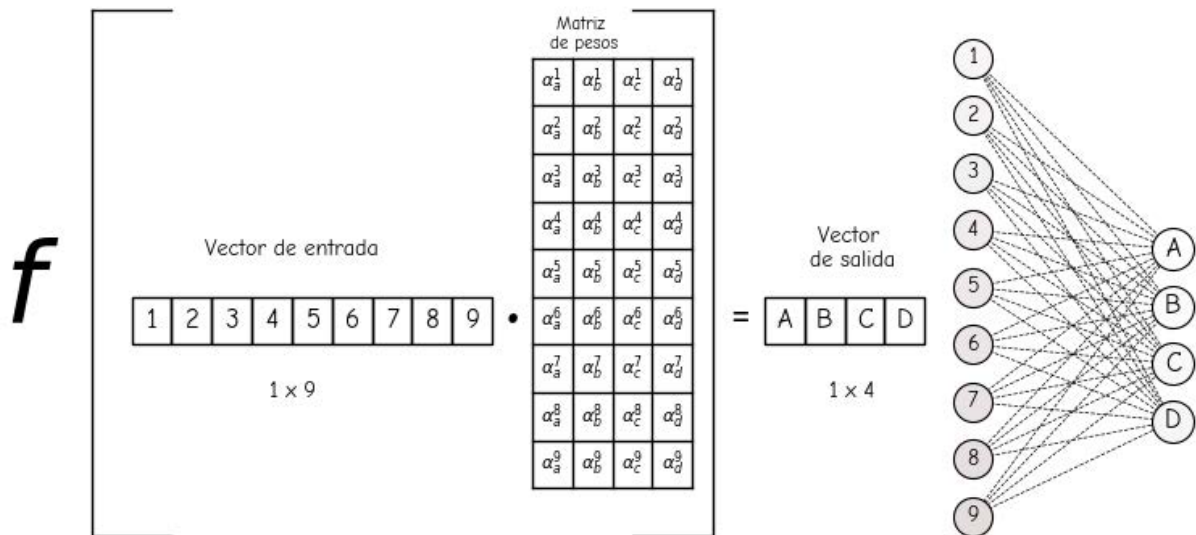


Figura 2.4.3.5: Ejemplo de una capa completamente conectada en una red neuronal. El vector de entrada de dimensiones 1×9 es transformado a través de una matriz de pesos en un vector de salida de 1×4 . Cada elemento del vector de salida es una combinación lineal de los elementos del vector de entrada, ponderada por los pesos correspondientes de la matriz, demostrando cómo las capas completamente conectadas integran información a lo largo de la red.

2.4.4. Long Short-Term Memory (LSTM)

Las Redes de Memoria Larga a Corto Plazo (LSTM) son un tipo especial de red neuronal recurrente (RNN) diseñadas para procesar datos secuenciales (Schmidhuber y cols., 2017). Las RNN son modelos que aplican los mismos parámetros a cada elemento de una secuencia, lo que permite capturar dependencias temporales entre datos. Todas las redes neuronales recurrentes tienen la forma de una cadena, con una estructura similar a la de la Figura 2.4.4.1, donde X_i contiene la información presente que pasa por una función de activación \tanh para obtener una h_i que abarca toda la información pasada.




Figura 2.4.4.1: Representación de una Red Neuronal Recurrente (RNN) estándar con una sola capa. Este diagrama muestra cómo la información fluye a través del tiempo: cada estado h_t recibe tanto la entrada actual x_t como el estado anterior h_{t-1} . La función de activación \tanh se aplica en cada paso para combinar estas entradas antes de pasar al siguiente estado h_{t+1} . Este mecanismo permite que la RNN capture dependencias temporales en secuencias de datos.

La retropropagación recurrente consume mucho tiempo en aprender a almacenar información durante intervalos de tiempo prolongados. Y el problema surge cuando el estado anterior que influye en la predicción actual no es del pasado reciente; esto hace que el modelo RNN no pueda predecir con precisión el estado actual (S. Hochreiter, 1991). Para abordar este problema de la desaparición del gradiente, es decir, la pérdida de información que se encuentra más en el pasado, se desarrollaron las LSTM.

Las LSTM ajustan dinámicamente qué datos conservar y cuáles olvidar durante el entrenamiento, lo que les permite recordar información importante durante más tiempo. De acuerdo con la Figura 2.4.4.2, cada unidad de LSTM está compuesta por las siguientes neuronas (Y. Sun y cols., 2020):

1. La **célula de memoria** (C_t) en una LSTM es la encargada de almacenar información relevante a lo largo del tiempo. El valor actual de la célula de memoria C_t se actualiza utilizando una combinación del estado de la célula anterior C_{t-1} y de la nueva información \tilde{C}_t , modulada por la puerta de olvido f_t y la puerta de entrada i_t . Esto se expresa con la siguiente fórmula (Ec. 22):

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (22)$$

2. La **puerta de actualización** en una LSTM recibe la información nueva proveniente de la capa anterior y decide qué porciones se almacenarán en la célula de memoria. Este proceso se controla mediante la función sigmoide (σ) y la tangente hiperbólica (\tanh). La puerta de

entrada i_t decide cuánto de la nueva información, representada como \tilde{C}_t , debe añadirse a la célula de memoria. El producto Hadamard (\odot) se aplica entre el valor de la puerta de entrada y la nueva información candidata, determinando qué proporción de la información se actualizará en la célula de memoria, tal como se describe en la Ecuación 23.

$$U_t = i_t \odot \tanh(\tilde{C}_t) \quad (23)$$

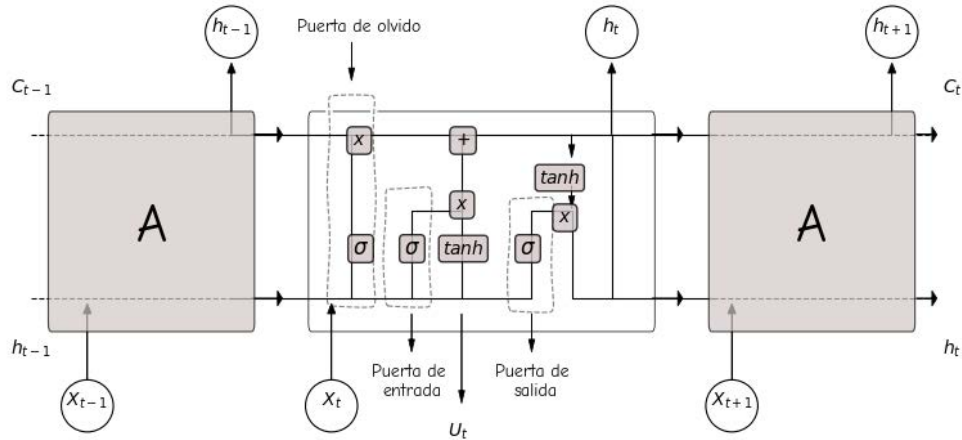


Figura 2.4.4.2: Diagrama de una celda LSTM en una Red Neuronal Recurrente, ilustrando su estructura interna y mecanismos de control de flujo de información. Esta celda incluye puertas de olvido, entrada y salida, representadas respectivamente, que regulan el flujo de información permitiendo que la red recuerde y olvide información de manera selectiva. Cada puerta utiliza funciones de activación como la sigmoidea (σ) y la tangente hiperbólica (\tanh) para procesar los datos de entrada (x_t) y los estados anteriores (h_{t-1} , C_{t-1}), generando un nuevo estado (h_t) y actualizando el estado de la celda (C_t).

3. La **puerta de olvido** (f_t) en una red LSTM utiliza una función sigmoidea (σ) para determinar qué parte de la información del estado oculto previo (h_{t-1}) y de la entrada actual (x_t) debe conservarse o desecharse en el instante t . La fórmula de la puerta de olvido es la Ecuación 24, donde f_t es la salida, \mathbf{W}_f representa los pesos asociados a la puerta, y \mathbf{b}_f es el sesgo. La función sigmoidea asegura que el resultado de f_t se encuentre entre 0 y 1, indicando cuánto de la información anterior se debe olvidar o retener.

$$f_t = \sigma(\mathbf{W}_f \cdot [h_{t-1}, x_t] + \mathbf{b}_f) \quad (24)$$

4. La **puerta de entrada** i_t es crucial en una celda LSTM, ya que controla cuánta información nueva debe añadirse al estado de la célula. Este proceso tiene dos componentes principales:
 - Capa sigmoidea. Esta función sigmoide (Ecuación 25) toma como entradas el estado oculto anterior h_{t-1} y la entrada actual x_t . La función sigmoidea, representada por σ , comprime los valores entre 0 y 1, determinando qué información debe conservarse para la actualización del estado de la célula.

$$i_t = \sigma(\mathbf{W}_i \cdot [h_{t-1}, x_t] + \mathbf{b}_i) \quad (25)$$

Donde:

- i_t es la activación de la puerta de entrada.
 - \mathbf{W}_i son los pesos asociados a la puerta de entrada.
 - h_{t-1} es el estado oculto en el tiempo $t - 1$.
 - x_t es la entrada en el tiempo t .
 - \mathbf{b}_i es el sesgo de la puerta de entrada.
 - σ es la función sigmoidea, que produce valores entre 0 y 1.
- Capa *tanh*: La función tangente hiperbólica (*tanh*) (Ecuación 26) genera un conjunto de nuevos valores candidatos \hat{C}_t , que representan la nueva información que potencialmente se añadirá al estado de la celda. La *tanh* comprime los valores entre -1 y 1.

$$\hat{C}_t = \tanh(\mathbf{W}_C \cdot [h_{t-1}, x_t] + \mathbf{b}_C) \quad (26)$$

Donde:

- \hat{C}_t es el nuevo valor candidato para el estado de la celda.
- \mathbf{W}_C son los pesos para la actualización de la celda.
- \mathbf{b}_C es el sesgo de la celda.
- \tanh es la función tangente hiperbólica, que genera los valores candidatos entre -1 y 1.

Finalmente, la nueva información candidata y la información de la puerta de entrada se combinan para actualizar el estado de la celda C_t . La actualización del estado de la celda se lleva a cabo de la siguiente manera (Ec. 27):

$$C_t = f_t \odot C_{t-1} + i_t \odot \hat{C}_t \quad (27)$$

Donde:

- C_t es el nuevo estado de la celda en el tiempo t .
- f_t es la salida de la puerta de olvido, que decide qué información del estado anterior C_{t-1} debe mantenerse.
- C_{t-1} es el estado anterior de la celda.
- i_t es la activación de la puerta de entrada.
- \hat{C}_t es la nueva información candidata.
- \odot representa el producto elemento a elemento (Hadamard).

En la fórmula final ya no aparece explícitamente la función sigmoidea σ porque ya ha sido aplicada en las puertas anteriores, como la puerta de entrada i_t y la puerta de olvido f_t . En esas etapas, la función sigmoidea ha transformado los valores de las entradas para determinar cuánto de la información nueva se debe agregar (i_t) y cuánto de la información pasada se debe olvidar (f_t).

La Ecuación 27 representa cómo la memoria C_t de la celda LSTM se actualiza combinando la información pasada (filtrada por f_t) y la nueva información candidata \hat{C}_t (modificada por i_t), utilizando el producto punto a punto (\odot).

5. La **Puerta de salida** (o_t) actúa como un filtro que decide qué partes del estado oculto se van a generar como salida. Primero, una función sigmoidea (σ) determina qué partes del estado de la celda se utilizarán para generar la salida (Ec. 28). Luego, el estado de la celda (C_t) pasa por una función tanh (Ec. 29) que limita sus valores entre -1 y 1. Finalmente, se multiplica la salida de la función sigmoidea por este estado transformado, generando así el estado oculto h_t en el tiempo t .

$$o_t = \sigma(\mathbf{W}_o \cdot [h_{t-1}, x_t] + \mathbf{b}_o) \quad (28)$$

$$h_t = o_t \odot \tanh(C_t) \quad (29)$$

Donde:

- o_t es la activación de la puerta de salida.
- \mathbf{W}_o son los pesos asociados a la puerta de salida.
- h_{t-1} es el estado oculto en el tiempo $t - 1$.
- x_t es la entrada en el tiempo t .
- \mathbf{b}_o es el sesgo de la puerta de salida.
- C_t es el nuevo estado de la celda.
- tanh es la función tangente hiperbólica, que transforma el estado de la celda entre -1 y 1.
- \odot representa el producto entrada a entrada (Hadamard).

La Memoria a Largo Plazo es una variante de red neuronal recurrente que destaca por su capacidad de aprender y predecir patrones secuenciales complejos. A diferencia de las redes de propagación hacia adelante, las LSTM pueden mantener información a lo largo de pasos de tiempo, lo que les permite capturar dependencias temporales y mejorar la precisión en la predicción de series temporales (K. y cols., 2020).

Una de las características clave de las LSTM es su estructura tridimensional, que comprende tres parámetros fundamentales: el tamaño de lote (batch size), los pasos de tiempo y las caracterís-

ticas (features). Esta organización permite procesar múltiples secuencias simultáneamente y es fundamental para explotar dependencias temporales.

Los pasos de tiempo son un parámetro crucial que no se considera en las redes neuronales tradicionales. Cada paso representa una única instancia temporal en la secuencia de datos. Por ejemplo, en la Figura 2.4.4.3, se ilustra un proceso de aprendizaje en ciclos de 3 pasos. En el primer paso, se genera una salida O_1 , que se retroalimenta a la celda LSTM. Posteriormente, se ejecuta el segundo paso, produciendo O_2 , y así sucesivamente hasta completar los pasos establecidos. Esto permite que las LSTM retengan información relevante de estados anteriores, lo que mejora significativamente la capacidad de predicción (Hochreiter y cols., 1997).




Figura 2.4.4.3: Diagrama de una Red Neuronal Recurrente LSTM mostrando la reutilización de una misma celda A a lo largo de tres pasos de tiempo consecutivos. Cada celda procesa una entrada distinta (x_t, x_0, x_1, x_2) y actualiza su estado oculto (h_t, h_0, h_1, h_2) en cada paso, con cada estado alimentando al siguiente. Las salidas (O_1, O_2, O_3) son generadas en cada paso. Este proceso ilustra cómo la información es propagada y transformada en una secuencia, destacando la capacidad de la LSTM para manejar dependencias temporales en datos secuenciales.

Todos los datos de series temporales se pueden descomponer en cuatro componentes fundamentales: el valor promedio o nivel, una tendencia creciente o decreciente, una estacionalidad o patrón repetitivo de corto plazo, y una variación aleatoria o ruido residual (Siegel, 2012).

El componente estacional es particularmente relevante en los datos meteorológicos, ya que refleja patrones repetitivos que dependen de la época del año. La frecuencia de estos ciclos puede variar por diversas razones, como los períodos diarios, mensuales (fases lunares), trimestrales (estaciones del año) y anuales (Date, 2023). Estos patrones actúan como ventanas de aprendizaje que capturan la naturaleza cíclica de los datos. Por ejemplo, la rotación de la Tierra genera variaciones diarias en la temperatura, mientras que la inclinación del eje terrestre provoca estacionalidades anuales (primavera, verano, otoño e invierno). En la Figura 2.4.4.4 se puede observar claramente un ciclo estacional de aproximadamente 12 meses.

En el contexto de las redes LSTM, este tipo de patrones es esencial, ya que el modelo puede aprender dependencias temporales complejas, como los ciclos anuales de temperatura, en bloques de 365 pasos de tiempo. Este enfoque mejora la precisión en la predicción, ya que permite capturar los ciclos repetitivos inherentes a los datos meteorológicos y adaptarse a las variaciones que se presentan.




Figura 2.4.4.4: Visualización del componente estacional en la serie temporal de temperatura. Esta gráfica muestra cómo los patrones de temperatura en grados *Kelvin*, fluctúan de manera regular, observando ciclos anuales consistentes a lo largo del intervalo de tiempo.

2.4.5. Convolutional Recurrent Neural Network (CRNN)

El Modelo de Red Neuronal Convolutiva Recurrente (CRNN) es una herramienta utilizada principalmente para procesar y clasificar datos secuenciales de longitud variable. Estas redes integran en su arquitectura una red neuronal convolutiva seguida de una red neuronal recurrente. Tanto la convolución como la agrupación se realizan localmente en regiones de la imagen, sin considerar dependencias contextuales entre diferentes regiones, lo cual es útil para capturar la estructura espacial. En contraste, las redes neuronales recurrentes (RNN) emplean conexiones recurrentes (retroalimentación) para aprender dependencias contextuales entre datos secuenciales (Zuo y cols., 2015).

Las CRNN son particularmente eficaces para procesar datos bidimensionales en diversas tareas. En el caso de las imágenes, primero se extraen las características integradas y su correlación espacial utilizando la red convolutiva. Luego, se procesa su correlación temporal con la red recurrente para capturar dependencias espaciales a largo plazo y realizar predicciones precisas (Shi, Bai, y Yao, 2017; Zihlmann, Perekrestenko, y Tschannen, 2017; Pinheiro y Collobert, 2014). Para datos de audio, la CNN extrae características locales, mientras que la RNN proporciona un resumen temporal del audio basado en las características extraídas (Kukanov y cols., 2018). En el procesamiento de texto, sucede algo similar: primero, la CNN reconoce caracteres individuales, y posteriormente, la RNN extrae las dependencias del texto según el contexto (Yu y cols., 2023).

Las arquitecturas que componen las CRNN, previamente descritas de manera independiente, conectan la salida del modelo convolutivo con la red recurrente mediante una capa intermedia. En esta etapa, el vector resultante de la imagen procesada por la CNN se aplana a un formato bidimensional para ser la entrada adecuada en la RNN, lo que permite capturar las características espaciales y temporales en conjunto (Liang y cols., 2015).

2.5. Trabajos relacionados

En las últimas décadas, la combinación de datos de teledetección y arquitecturas de inteligencia artificial ha cobrado un papel crucial en la investigación relacionada con la gestión de recursos hídricos, particularmente en el almacenamiento de agua subterránea.

Aunque durante esta investigación se han revisado numerosos estudios, solo se seleccionaron 11 de ellos, destacando por su relevancia y alineación con el uso de datos satelitales y modelos de inteligencia artificial. El objetivo principal de estas investigaciones es la predicción y el monitoreo del almacenamiento de agua subterránea, la mejora de la resolución de los datos y la evaluación de la dinámica hidrológica a niveles local y regional. Otras buscan generar parámetros que mejoren la comprensión de los procesos hidrológicos subterráneos, ofreciendo soluciones útiles para la gestión eficaz de este recurso.

Si bien estos estudios han logrado sus objetivos en términos de estimaciones del agua subterránea, se observa una notable falta de documentación sobre el tratamiento adecuado de los datos espaciales antes de su integración en redes neuronales artificiales. En este contexto, el primer estudio analizado ha resultado ser de especial utilidad, ya que detalla el manejo de series temporales y, en particular, la configuración de los pasos de tiempo, un aspecto crucial para poder hacer una predicción.

La Tabla 2.5.1 presenta una descripción detallada de cada estudio, cubriendo varios aspectos clave: el número de la investigación, que está relacionado con el título y una breve descripción del estudio; el objetivo principal, que resume la finalidad de la investigación; la arquitectura de IA empleada, que detalla el tipo de modelos de aprendizaje automático utilizados; las variables que se incluyeron en el análisis, como precipitaciones, evapotranspiración, humedad del suelo, entre otras; las métricas de correlación, como el coeficiente de Pearson o la eficiencia de Nash-Sutcliffe, que cuantifican la precisión de los modelos; el período de estudio que abarca el rango temporal de los datos utilizados, y finalmente, la región geográfica analizada, que especifica la zona donde se realizaron las predicciones y el monitoreo de las aguas subterráneas.

1. *Temperature Forecasting via Convolutional Recurrent Neural Networks Based on Time-Series Data*: Este artículo propone una red neuronal convolucional recurrente para pronosticar la temperatura a 4 días futuros, utilizando series temporales de datos de temperatura pasada. El modelo es capaz de captar la correlación temporal y espacial de los cambios de temperatura, empleando datos históricos de la región continental de China (Z. Zhang y Dong, 2020).
2. *Predicting Groundwater Level Changes Using GRACE Data*: El objetivo de este trabajo es investigar la viabilidad de reducir la escala de los datos satelitales del Experimento sobre Clima y Recuperación de Gravedad (GRACE) para predecir los cambios en el nivel de las aguas subterráneas y, de esta manera, mejorar la capacidad actual para la gestión sostenible de los recursos hídricos (A. Sun, 2013).
3. *Improved Methods for Estimating Local Terrestrial Water Dynamics from GRACE in the Northern High Plains*: Este proyecto busca mejorar la resolución y la aplicabilidad de los datos de anomalía de almacenamiento terrestre de agua (TWSA) obtenidos del satélite GRACE, para estudiar la dinámica del ciclo hidrológico terrestre en la región de las Grandes Llanuras del Norte, permitiendo su aplicación en cuencas hidrográficas de entre 5,000 y 20,000 km^2 . El modelo ANN predijo con precisión las anomalías mensuales de almacenamiento de agua dentro

de un margen de incertidumbre de 34 mm en la mayoría de las cuencas (W. M. Seyoum y Milewski, 2017).

4. *Combining Physically Based Modeling and Deep Learning for Fusing GRACE Satellite Data: Can We Learn From Mismatch?*: Esta investigación busca incorporar los datos GRACE a modelos hidrológicos globales para mejorar su desempeño predictivo. En este estudio, se desarrollaron modelos de redes neuronales convolucionales (CNN) para aprender los patrones espacio-temporales de discrepancias entre las anomalías de TWS derivadas de GRACE y las simuladas por NOAA. Este estudio demuestra la similitud que tiene GRACE con la medida piezométrica, con una correlación de aproximadamente el 94 % (A. Sun y cols., 2019).
5. *Downscaling of GRACE-Derived Groundwater Storage Based on the Random Forest Model*: Esta investigación aborda el desafío de mejorar la resolución espacial del almacenamiento de agua subterránea utilizando datos del satélite GRACE. Esta investigación demostró que, desde la perspectiva de series de tiempo largas, los resultados de predicción del modelo RF son ideales en toda el área de investigación y en el área de pozos de observación. Desde la perspectiva espacial, los cambios detallados del almacenamiento de agua podrían capturarse con mayor detalle después de la reducción de escala. (L. Chen y cols., 2019).
6. *Forecasting GRACE Data over the African Watersheds Using Artificial Neural Networks*: Este estudio utilizó los datos derivados del satélite GRACE sobre el almacenamiento total de agua terrestre (TWSGRACE) para predecir eventos de sequía en 10 importantes cuencas hidrográficas de África. El modelo fue capaz de predecir la terminación de una sequía en la cuenca del Zambeze entre marzo y octubre del año 2015 y el inicio de una sequía en la cuenca del Lago Chad en enero-marzo del año 2016 (Ahmed y cols., 2019).
7. *Improving the Resolution of GRACE Data for Spatio-Temporal Groundwater Storage Assessment*: Utilizando modelos de aprendizaje automático, este estudio mejora la resolución espacial de los datos de GRACE, centrándose en la cuenca de irrigación del Indo. El modelo de bosques aleatorios (RFM) logró su objetivo principal de superar la limitada resolución espacial de GRACE, que es de 1° , y aumentarla a 0.25° para permitir un análisis a nivel regional (Ali y cols., 2021).
8. *Predicting Changes in Spatiotemporal Groundwater Storage Through the Integration of Multi-Satellite Data and Deep Learning Models*: Investigación centrada en el monitoreo continuo y la predicción precisa de los cambios en el almacenamiento de agua subterránea utilizando modelos de aprendizaje profundo. Las conclusiones de esta investigación destacan el uso exitoso de modelos de aprendizaje profundo, específicamente LSTM y CNN-LSTM, para predecir cambios en el almacenamiento de agua subterránea (GWSC) en Corea del Sur. (Seo y Lee, 2021).
9. *Advancing SDGs: Predicting Future Shifts in Saudi Arabia's Terrestrial Water Storage Using Multi-Step-Ahead Machine Learning Based on GRACE Data*: El estudio utilizó una combinación de modelos de aprendizaje automático para predecir las anomalías de los niveles de agua subterránea en Arabia Saudí (M. A. Yassin y cols., 2024).

10. *Groundwater Level Prediction Using Machine Learning and Geostatistical Interpolation Models*: En Arizona, se combinan modelos de aprendizaje automático con técnicas de interpolación espacial para predecir las anomalías en los niveles de agua subterránea (Zowam y Milewski, 2024).
11. *Machine Learning Downscaling of GRACE/GRACE-FO Data to Capture Spatial-Temporal Drought Effects on Groundwater Storage at a Local Scale Under Data-Scarcity*: Este estudio propone un novedoso método de downscaling (reducción de escala) basado en el aprendizaje automático para mejorar la resolución espacial de los datos de anomalía en el almacenamiento de agua subterránea derivados de los satélites GRACE y GRACE-FO (Shilengwe y cols., 2024).

Inv	Objetivo	Modelo	Variables	Correlación	Periodo	Área
(Z. Zhang y Dong, 2020)	Predecir Temperatura	CRNN	T	45	1952 al 2018	China
(A. Sun y cols., 2019)	Mejorar Resolución	MLP	T, P, Piezometría, GWS	45	03-2003 al 08-2012	High Plains Aquifer, Pecos Valley, Aquifer Sand
(W. M. Seyoum y Milewski, 2017)	Mejorar Resolución	ANN	P, T, NDVI, Humedad de suelo (NOAH), Descarga	0.85	04-2002 al 11-2014	Grandes Llanuras del Norte
(A. Sun y cols., 2019)	Combinar con modelos físicos	CNN	Piezometría (3896 pozos)	0.94	01-2005 al 11-2014	India
(L. Chen y cols., 2019)	Mejorar Resolución	RF, SVM, MLR	P, E, Escorrentía, H, Agua equivalente de nieve	0.78 a 0.94	01-2003 al 06-2016	Noreste de China Continental
(Ahmed y cols., 2019)	Predecir sequías	NARX	P, T, E, NDVI	0.79 a 0.97	04-2002 al 09-2015	Africa
(Ali y cols., 2021)	Mejorar Resolución	RF/ANN	MDE, Pendiente, H, E, P, T, Escorrentía, Agua en embalses	0.67 a 0.77	2003-2016	Cuenca de irrigación del Indo
(Seo y Lee, 2021)	Monitoreo, predicción	CNN-LSTM	P, T, NDVI, NDWI	0.7	2003 al 2019	Corea del Sur
(M. A. Yassin y cols., 2024)	Predicción	ENN, SVR, BPNN	P,T, H, NDVI, MNDWI	0.72 a 0.99	2007-2017	Cuenca Árabe, Arabia Saudita
(Zowam y Milewski, 2024)	Predicción y monitoreo	EBK, SVR, SVM, RF	P, SM, ET, LST, VI, CN	0.72 a 0.76	2010-2019	Arizona
(Shilengwe y cols., 2024)	Generar datos hídricos	RF, XG-Boost, piezometría	E, P, H	0.86	2009-2020	Cuenca del río Barotse, Zambia

Tabla 2.5.1: Investigaciones sobre datos de GRACE y arquitecturas de IA

3 Metodología

Esta sección tiene como objetivo presentar la metodología, utilizando las distintas arquitecturas de Deep Learning, así como modelos basados en machine learning, ambos descritos en el Marco Teórico, particularmente en la Sección 2.4. La metodología adoptada se resume en la Figura 3.1. El proceso comienza con la exploración de los datos disponibles, seguida de la selección y preprocesamiento de las variables relevantes. Posteriormente, se implementan los modelos de IA, que son entrenados y validados con los datos de estudio.

Los datos utilizados corresponden a imágenes con cobertura global, y sus frecuencias de adquisición varían, desde capturas diarias hasta horarias. Por ello, previo a seleccionar el modelo IA más adecuado, es esencial determinar la forma más eficiente de extraer el área geográfica de interés, definir el período de estudio y analizar qué opciones nos ofrecen las frecuencias de muestreo de los satélites. Una vez definidos estos aspectos, el siguiente paso es trabajar en la estructura de los datos. Esto implica unificar todas las variables en un formato vectorial, crear un arreglo bidimensional con el fin de visualizarlas e identificar y eliminar valores atípicos para facilitar su manipulación, de manera que puedan utilizarse de forma coherente en las arquitecturas propuestas de ML y DL (Endel y Piringer, 2015; Stobierski, 2023).

Una vez concluido el preprocesamiento de los datos, se prueban las primeras arquitecturas, utilizando todas las variables disponibles en los modelos de Perceptrón Multicapa y Bosques Aleatorios. El MLP se emplea inicialmente, ya que es una de las redes neuronales más simples y frecuentemente recomendadas en la literatura para investigaciones preliminares en IA. Posteriormente, se utiliza el algoritmo de Bosques Aleatorios, cuyo propósito ha sido identificar las variables más predictivas, reduciendo así la carga computacional y mejorando la eficiencia del entrenamiento de las arquitecturas más complejas.

En el cuarto paso, se implementa una Red Neuronal Convolutiva (CNN), reconocida por su idoneidad para procesar imágenes y detectar patrones complejos a medida que la información pasa por múltiples capas sucesivas. Como siguiente paso, se integra la arquitectura de Memoria a Corto y Largo Plazo (LSTM), especialmente diseñada para aprovechar las dependencias temporales en series de datos.

Finalmente, como se describió en el capítulo anterior, se implementa un modelo de Red Neuronal Convolutiva Recurrente (CRNN) para combinar las propiedades de las CNN y las LSTM, es decir, para integrar tanto las características espaciales como las temporales. Esta arquitectura tiene como objetivo predecir el almacenamiento de agua subterránea de manera más cuantitativa en áreas de sistemas acuíferos.

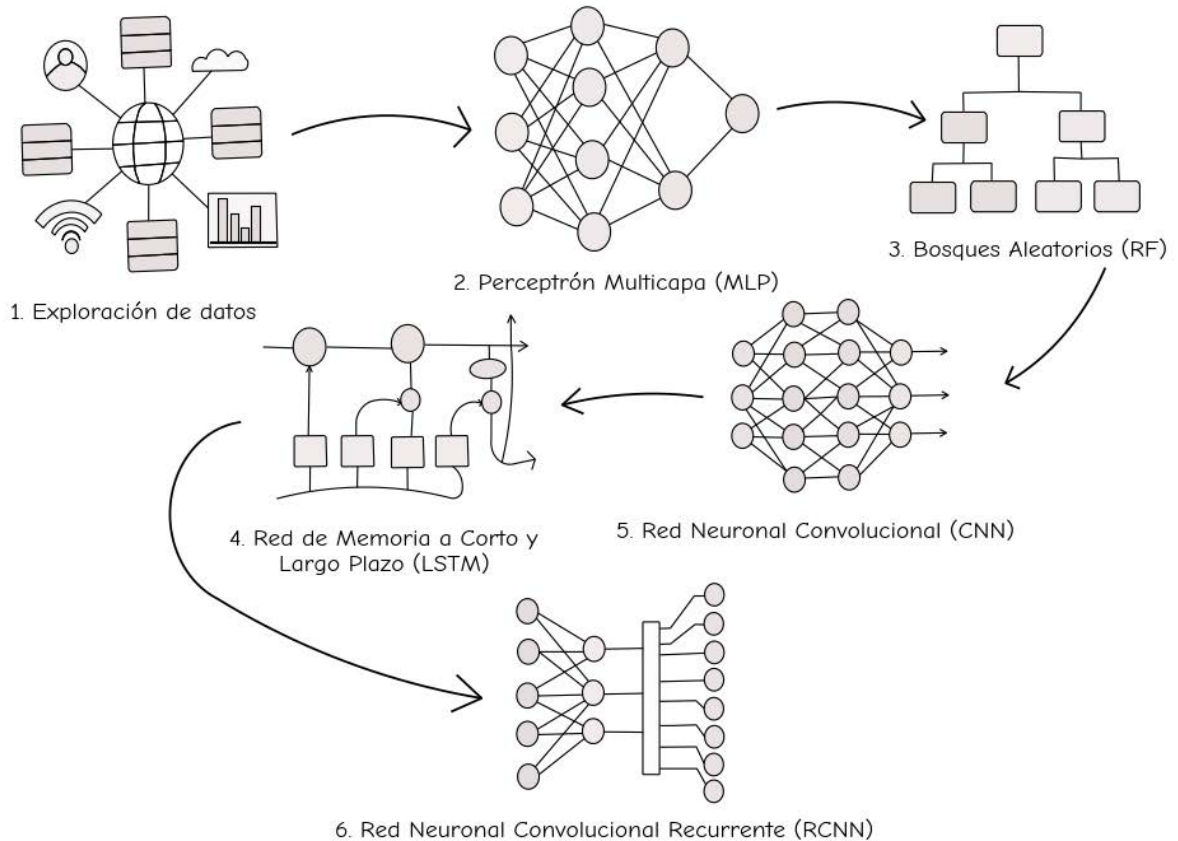


Figura 3.1: Esquema de las metodologías evaluadas en la tesis para la predicción del GWS. Este diagrama ilustra la secuencia desde la exploración de datos hasta la aplicación de diversas arquitecturas de aprendizaje automático: 1) Perceptrón Multicapa (MPL), 2) Bosques Aleatorios (RF), 3) Red Neuronal Convolutiva (CNN), 4) Red de Memoria a Corto y Largo Plazo (LSTM), y 5) Red Neuronal Convolutiva Recurrente (RCNN). Cada técnica se evaluó para determinar cuál resultaba más efectiva en el procesamiento y análisis de los datos específicos relacionados con el GWS.

3.1. Exploración de datos

3.1.1. Selección espacial y temporal

Espacialmente, esta investigación ha delimitado el área de estudio a las coordenadas geográficas: Noroeste [-107.5° N, 30.5° W] y Sureste [-106° N, 32° W]. El objetivo de esta adaptación es cubrir el área de interés, sin importar las diferentes resoluciones de las imágenes empleadas.

En la Figura 3.1.1.1, se muestran las dimensiones de las imágenes, ordenadas de mayor a menor, con la descripción de latitud y longitud correspondiente para cada una de las variables. Las cuatro imágenes superponen dos vectores sobre el raster: el límite del acuífero y una cuadrícula. Cada cuadro en la rejilla es un píxel, que a su vez es un dato individual y que en conjunto, estos píxeles determinan el tamaño de la matriz de valores en el área de estudio.

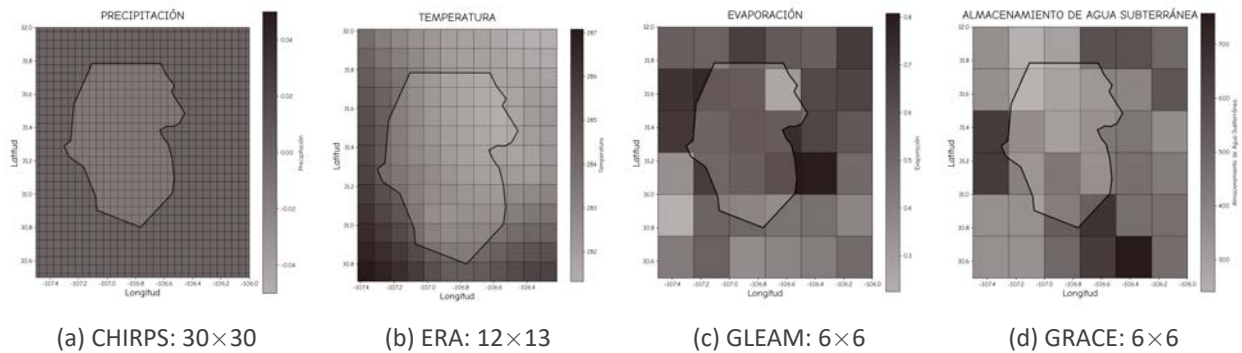


Figura 3.1.1.1: Resoluciones espaciales de imágenes ajustadas a la misma área de estudio: (a) Temperatura medida en una resolución de 30×30 km con datos de CHIRPS, (b) Precipitación en una resolución de 12×13 km con datos de ERA, (c) Evaporación en una resolución de 6×6 km con datos de GLEAM, y (d) Almacenamiento de Agua Subterránea en una resolución de 6×6 km con datos de GRACE. Cada celda que integra el grid representa un dato individual, la densidad de los datos está en función directamente de su resolución.

La selección del intervalo temporal también está condicionada por la disponibilidad de los datos. Como se muestra en la Figura 3.1.1.2, la línea horizontal más gruesa representa los datos comprometidos en esta investigación, que abarcan 7274 días desde el **01-02-2003** hasta el **31-12-2022**. Este período coincide con la disponibilidad del Almacenamiento de Agua Subterránea (GWS) proporcionado por el satélite GRACE.

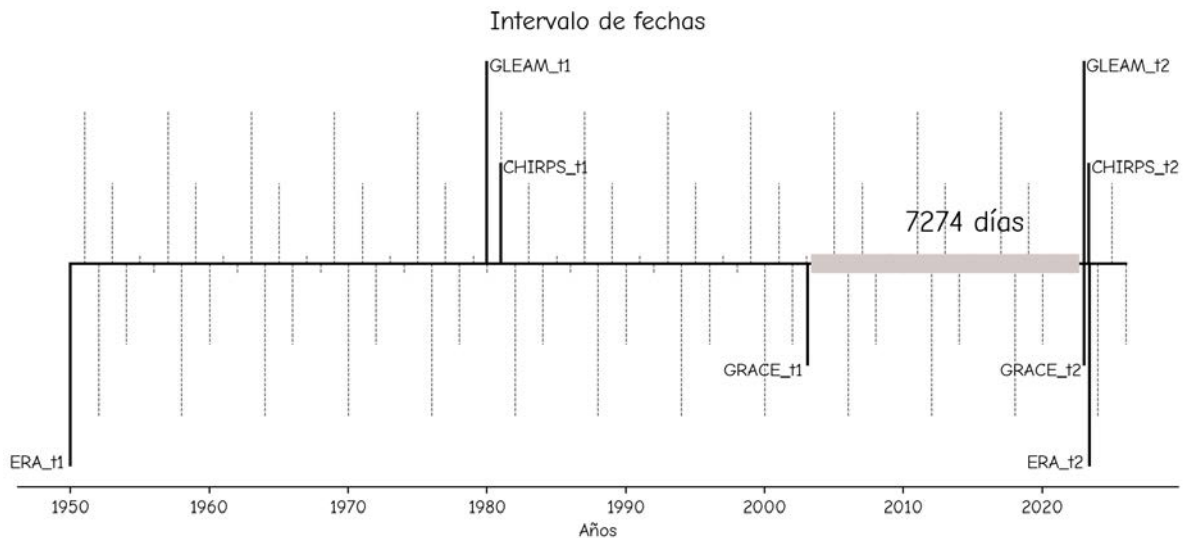


Figura 3.1.1.2: Visualización de los intervalos de tiempo de la disponibilidad temporal de los conjuntos de datos utilizados en la investigación. Las líneas verticales indican los rangos de años activos para los conjuntos de datos de CHIRPS, GLEAM, GRACE y ERA. La línea más gruesa resalta el periodo de 7274 días seleccionado para el análisis detallado, abarcando las coincidencias temporales máximas entre las diferentes fuentes.

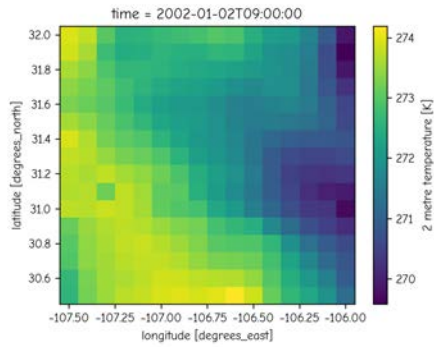
A continuación, en la Tabla 3.1.1.1, se describen las claves de las variables utilizadas en los siguientes apartados. La variable de precipitación se presenta como un arreglo que abarca el área de interés con 900 datos, representando la mayor resolución entre las variables de entrada. En el caso de los datos de ERA, la matriz se compone de 156 valores por cada medida máxima, media y mínima diaria.

Para los archivos GLEAM y GRACE, la resolución que cubre el área de interés es la misma, es decir, 36 valores para cada uno de los 10 subtipos en el caso de la evaporación y un número equivalente para la representación del almacenamiento de agua subterránea.


Satélite	Clave de Variables	Descripción	Dimensión filas x columnas
CHIRPS	P	Precipitación	900 px
ERA	T_min	Temperatura mínima	156 px
	T_med	Temperatura media	
	T_max	Temperatura máxima	
GLEAM	E	Evaporación real (Actual Evaporation)	36 px
	Eb	Evaporación del suelo (Soil Evaporation)	
	Ei	Pérdida de intercepción (Interception Loss)	
	Ep	Evaporación potencial (Potential Evaporation)	
	Es	Sublimación de nieve (Snow Sublimation)	
	Et	Transpiración (Transpiration)	
	Ew	Evaporación en aguas abiertas (Open-Water Evaporation)	
	S	Estrés evaporativo (Evaporative Stress)	
	SMroot	Humedad del suelo en la zona de raíces (Root-Zone Soil Moisture)	
	SMsurf	Humedad del suelo superficial (Surface Soil Moisture)	
GRACE	GWS	Almacenamiento de Agua Subterránea (Ground Water Storage)	36 px

Tabla 3.1.1.1: Descripciones de las claves de variables y el número de puntos de observación para cada uno de los conjuntos de datos satelitales de CHIRPS, ERA, GLEAM y GRACE, utilizados en el área de estudio.


A continuación, en la Figura 3.1.1.3, se presenta del lado izquierdo un recorte de uno de los días de las imágenes obtenidas de los datos de CHIRPS, ERA, GLEAM y GRACE, respectivamente. Los encabezados de las imágenes aparecen en su idioma original, inglés, tal como se extraen del metadato. En la segunda columna, se muestra su equivalente vectorial, donde cada variable $a_{i,j}$ representa el valor del centroide de cada uno de los píxeles en la imagen.



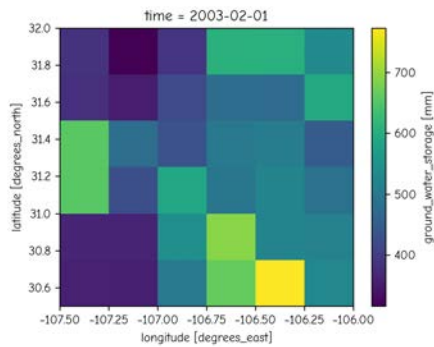
$$\begin{pmatrix} a_{1,1} & a_{1,2} & \cdots & a_{1,30} \\ a_{2,1} & a_{2,2} & \cdots & a_{2,30} \\ \vdots & \vdots & \cdots & \vdots \\ a_{30,1} & a_{30,2} & \cdots & a_{30,30} \end{pmatrix} \Rightarrow \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_{900} \end{bmatrix}$$



$$\begin{pmatrix} a_{1,1} & a_{1,2} & \cdots & a_{1,13} \\ a_{2,1} & a_{2,2} & \cdots & a_{2,13} \\ \vdots & \vdots & \cdots & \vdots \\ a_{12,1} & a_{12,2} & \cdots & a_{12,13} \end{pmatrix} \Rightarrow \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_{156} \end{bmatrix}$$



$$\begin{pmatrix} a_{1,1} & a_{1,2} & \cdots & a_{1,6} \\ a_{2,1} & a_{2,2} & \cdots & a_{2,6} \\ \vdots & \vdots & \cdots & \vdots \\ a_{6,1} & a_{6,2} & \cdots & a_{6,6} \end{pmatrix} \Rightarrow \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_{36} \end{bmatrix}$$



$$\begin{pmatrix} a_{1,1} & a_{1,2} & \cdots & a_{1,6} \\ a_{2,1} & a_{2,2} & \cdots & a_{2,6} \\ \vdots & \vdots & \cdots & \vdots \\ a_{6,1} & a_{6,2} & \cdots & a_{6,6} \end{pmatrix} \Rightarrow \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_{36} \end{bmatrix}$$

Figura 3.1.1.3: Proceso de vectorización de raster, el cual ilustra cómo se convierten las posiciones de los valores en cada píxel de la imagen en vectores unidimensionales, conservando el orden espacial para un análisis detallado posterior. De arriba a abajo: (1) Temperatura superficial el 19 de octubre de 2002, transformada de una matriz de 30×30 a un vector de 900 elementos; (2) Precipitación el 29 de julio de 2013, de 12×13 a 156 elementos; (3) Evaporación el 1 de febrero de 2003, de 6×6 a 36 elementos; y (4) Almacenamiento de agua subterránea el 1 de enero de 2003, también de 6×6 a 36 elementos. Las imágenes se muestran con leyendas en inglés, tal como aparecen en los archivos fuente, sin alteraciones.

Los vectores de las imágenes se organizan en un arreglo bidimensional, donde las filas son secu-

ciales en cada columna, de arriba a abajo, y las columnas son ordinales de izquierda a derecha, como se ilustra en la Figura 3.1.1.4. Las flechas en la figura indican el orden de captura de los datos, así como de las imágenes.

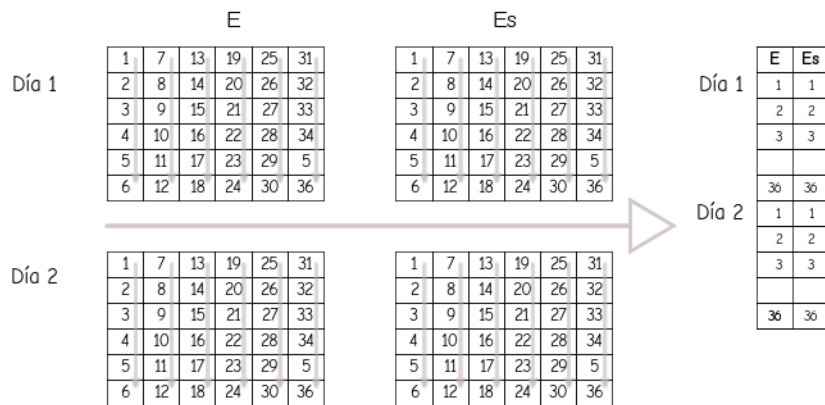


Figura 3.1.1.4: Ejemplo del proceso de captura secuencial de los valores de píxeles en imágenes para dos días consecutivos, mostrando cómo los datos son organizados en matrices (E) y (Es), luego resumidos en vectores simplificados. Cada matriz representa un día de captura, con los números dentro de las celdas indicando el orden de captura.

Una vez obtenida la Tabla (como se ilustra en la Figura 3.1.1.5), indexada por la longitud, latitud y tiempo, se facilita la manipulación y adaptación de los vectores de entrada para los modelos subsecuentes.

	time	longitude	latitude	precip
0	2003-02-01	-107.475006	30.524994	0.000000
1	2003-02-01	-107.475006	30.574997	0.000000
2	2003-02-01	-107.475006	30.625000	0.000000
3	2003-02-01	-107.475006	30.674995	0.000000
4	2003-02-01	-107.475006	30.724998	0.000000
...
6218100 rows × 4 columns				

Figura 3.1.1.5: Datos de precipitación del satélite CHIRPS organizados en una tabla indexada por tiempo, longitud y latitud. Este conjunto contiene registros diarios que suman un total de 6,218,100 filas, representando 900 mediciones diarias distribuidas geográficamente, registradas el 1 de febrero de 2003. Los valores de precipitación en cero indican ausencia de lluvia.

Este formato tabular proporciona un primer acercamiento del comportamiento de los datos. En las Figuras 3.1.1.6, 3.1.1.7, 3.1.1.8 y 3.1.1.9 se pueden observar las gráficas de las variables: en el eje X se muestran los valores diarios a lo largo de 7274 días, mientras que el eje Y indica el rango en el que oscilan los valores de acuerdo con sus respectivas unidades.




Figura 3.1.1.6: Serie temporal de los datos de precipitación diaria desde 2001 hasta 2022. En el eje X se muestran los años, y en el eje Y se presenta la precipitación en milímetros. La gráfica ilustra los valores promedio diarios consolidados a lo largo de 7274 días, mostrando variaciones y picos de precipitación a lo largo del tiempo.




Figura 3.1.1.7: Las gráficas representan, de arriba hacia abajo, la evolución de las temperaturas mínimas, medias y máximas registradas diariamente desde el 2004 hasta el año 2022 en unidades de grados *kelvin*. Cada panel muestra cómo los valores oscilan dentro de un rango específico, ilustrando las variaciones climáticas anuales y subrayando períodos de extremos térmicos.

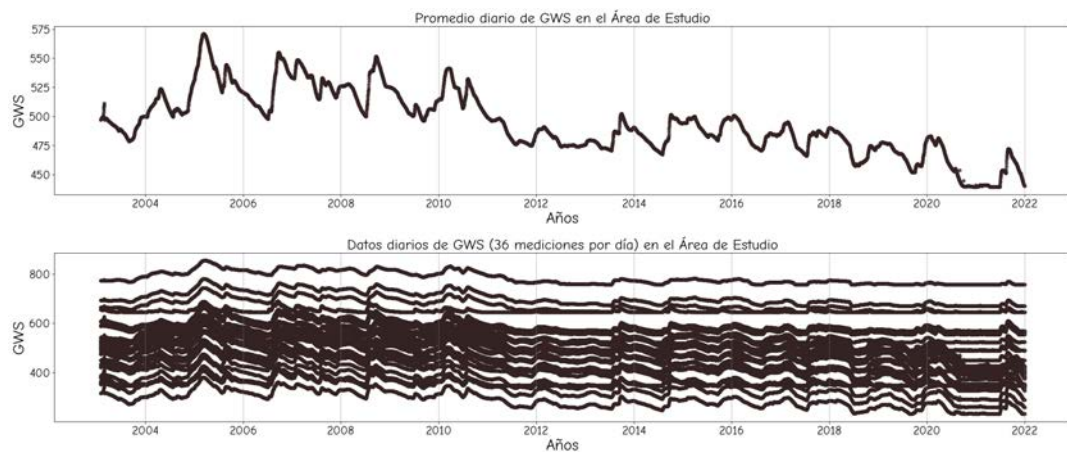


Figura 3.1.1.8: Comparación diaria del almacenamiento de agua subterránea, desde 2004 hasta 2022. En la primera gráfica se muestra el promedio diario de GWS, mientras que en la segunda gráfica, cada día está representado por 36 puntos de medición individuales, mostrando la variabilidad intradiaria y la respuesta del acuífero a condiciones específicas.




Figura 3.1.1.9: Series temporales de las variables de evaporación medidas a lo largo de los años 2004 a 2022. Cada panel, etiquetado desde E hasta SMurf, representa diferentes valores, mostrando variaciones estacionales y tendencias anuales. Los picos en los gráficos reflejan períodos de alta evaporación, que generalmente coinciden con los meses más cálidos, mientras que las partes más bajas indican menores tasas de evaporación durante los meses más fríos.

3.1.2. División del conjunto de datos para entrenamiento, validación y prueba del modelo

La partición de datos es la forma de evaluación del rendimiento de modelos de regresión o clasificación. Todas las arquitecturas que a continuación se exponen subdividen el 100 % de los datos en tres lotes (Figura 3.1.2.1). Una división comúnmente utilizada es asignar el 80 % de los datos para el entrenamiento y el 20 % restante para la prueba. Luego, del 80 % asignado al entrenamiento, se toma un 20 % adicional para validación, resultando en tres conjuntos (Isabelle, 1997). El conjunto de entrenamiento se utiliza para ajustar el modelo; este implica seleccionar variables y estimar parámetros. En esta etapa, el modelo aprende y realiza predicciones sobre los datos, aproximándose a su objetivo. Posteriormente, el modelo ajustado se utiliza para predecir las respuestas de las observaciones en un segundo conjunto de datos, denominado conjunto de validación. La validación proporciona una métrica de error que puede ser utilizada para detener el entrenamiento a medida que aumenta.

Por último, los datos del conjunto de prueba son utilizados para la evaluación de los modelos.

En esta etapa, se obtienen las métricas de rendimiento, como precisión, pérdida, coeficiente de correlación, error absoluto medio, *P-value*, entre otras.




Figura 3.1.2.1: Esquema de división aleatoria de datos para procesos de aprendizaje automático, mostrando la asignación de conjuntos para entrenamiento (60.4%), validación (10.6%) y prueba (20%). La segmentación de los datos garantiza que el entrenamiento, la validación y las pruebas se realicen en muestras únicas y no superpuestas.

En la Tabla 3.1.2.1 se presenta un ejemplo de la estructura del conjunto de un par ordenado $[X, Y]$. En la primera fila, el arreglo indica la configuración de una tabla bidimensional, conformada por 261,864 registros y 5 variables de evaporación para GLEAM y 1 para GRACE. La resolución de ambos mapas es de 6×6 píxeles; por esta razón, los conjuntos de entrenamiento, validación y prueba tienen una configuración de 4 dimensiones. La primera dimensión corresponde al número de días, seguida por la altura, el ancho y, finalmente, el número de bandas, que puede referirse al valor de las variables de *Evaporación* o, en el caso de *Y*, al *Almacenamiento de Agua Subterránea*.

Conjunto	X = GLEAM	Y = GRACE
100 % de datos	[261864,5]	[261864,1]
Entrenamiento	[4655, 6, 6,5]	[4655, 6, 6,1]
Validación	[1164, 6, 6,5]	[1164, 6, 6,1]
Prueba	[1455, 6, 6,5]	[1455, 6, 6,1]

Tabla 3.1.2.1: Distribución de los conjuntos de datos GLEAM y GRACE para entrenamiento, validación y prueba. $X = GLEAM$ y $Y = GRACE$ indican las variables independientes y dependientes respectivamente, con el conjunto completo consistiendo en 261864 muestras, y las divisiones de los tres subconjuntos estructurados para optimizar el aprendizaje y la validación del modelo.

3.1.3. Normalización de los conjuntos de datos

Para optimizar el rendimiento de la red neuronal, es crucial que los tres grupos de datos (entrenamiento, validación y prueba) sean normalizados (Shanker y cols., 1996), ya que esto afecta significativamente la efectividad de la predicción de la red (Bhanja y Das, 2018; Laurent y cols., 2016; the Stanford, 2024). Geométricamente, cuando los valores están normalizados, los datos se concentran en torno al origen, como se ilustra en la Figura 3.1.3.2. Esta imagen sugiere que, cuando las variables presentan diferentes distribuciones (parábolas de la izquierda), el tiempo requerido para que el método de descenso de gradiente alcance el mínimo es mayor, en comparación con el caso en el que las variables están escaladas. Esto mejora la eficiencia en la reducción iterativa de los errores (Blondel y Roulet, 2024).




Figura 3.1.3.2: Comparación de las trayectorias de descenso del gradiente con y sin normalización de datos. A la izquierda, los datos normalizados muestran una ruta de descenso más directa y eficiente hacia el mínimo global dentro de un rango de valores más restringido de θ . A la derecha, sin normalizar, la ruta de descenso es más errática y extendida, demostrando cómo la falta de normalización puede afectar la eficiencia y el comportamiento del algoritmo en la búsqueda del mínimo.

La normalización convierte todos los valores en un intervalo entre 0 y 1, lo que minimiza el efecto de las diferencias en las escalas de las variables de entrada (sklearn developers, 2024). Este proceso es crucial, ya que evita que la red neuronal asigne pesos desiguales a las muestras, lo que podría hacer que ciertas variables dominen el proceso de aprendizaje. La normalización equilibra la optimización, reduce el impacto de los valores atípicos y contribuye a prevenir problemas como la desaparición o explosión de gradientes (Ahmed Ouameur y cols., 2020).

En esta investigación, cada conjunto de entrenamiento, validación y prueba fue escalado mediante la sustracción de la media, como se muestra en la Ecuación 30, de modo que todos los valores quedaran dentro del rango de 0 a 1. En la fórmula, X denota la variable de interés, mientras que max y min representan los valores máximos y mínimos de la variable, respectivamente.

$$X_{norm} = \frac{(X - X_{min})}{(X_{max} - X_{min})} \quad (30)$$

3.2. MLP para estimar el GWS

Como se mencionó anteriormente, los perceptrones multicapa (MLP) constituyen la base de las arquitecturas de aprendizaje profundo. Por esta razón, este estudio comienza con pruebas más simples, utilizando redes neuronales que constan de una a tres capas ocultas. Las variables de entrada y salida son datos promedio diarios de los valores del área de estudio. Al utilizar los promedios de los valores de las imágenes, se omiten las dimensiones de longitud y latitud; sin embargo, los atributos geográficos continúan caracterizando el área de interés.

A continuación, se describen los modelos MLP desarrollados para cada una de las variables de entrada. Cada variable, como fuerte indicador de la zona de interés, busca obtener a la salida, con una sola neurona Y , la estimación y/o pronóstico del promedio del Almacenamiento de Agua Subterránea en la zona de estudio.

3.2.1. MLP para estimar el GWS con Temperatura

La resolución espacial de los mapas de Temperatura es de 16x16 píxeles. La reducción de las dimensiones está indicada en la segunda columna de la Tabla 3.2.1.1. Aquí se puede observar que se elimina una dimensión con el promedio de los 256 puntos de la imagen tanto para una variable como para el caso de las tres temperaturas.

Var	Reducción	Entradas
T_med	[7274, 12, 13, 1]	[7274, prom[156], 1]
T_max,T_min,T_med	[7274, 12, 13, 3]	[7274, prom[156], 3]

Tabla 3.2.1.1: Dimensión de las variables de temperatura antes y después de la reducción de datos. *Var* indica las variables consideradas; *Reducción* muestra las dimensiones de los datos tras aplicar un proceso de promedio (promedio de todos los puntos en el área de estudio), mientras que *Entradas* representa las dimensiones finales, adecuadas para su uso en arquitecturas de MLP.

A continuación, la Figura 3.2.1.1 expone la estructura de los modelos de entrenamiento de Perceptrón Multicapa. En cada caso, la capa final aloja una neurona en la capa de salida que resulta en el pronóstico medio del almacenamiento de agua subterránea. En relación al entrenamiento *mlp_1*, la capa de entrada está compuesta por una neurona, correspondiente al valor medio de la temperatura, seguida por una capa intermedia que integra 30 neuronas. En el entrenamiento *mlp_2*, tres neuronas ingresan con los valores de temperatura máxima, media y mínima; y el proceso continúa con tres capas ocultas que aglomeran 100 neuronas cada una.

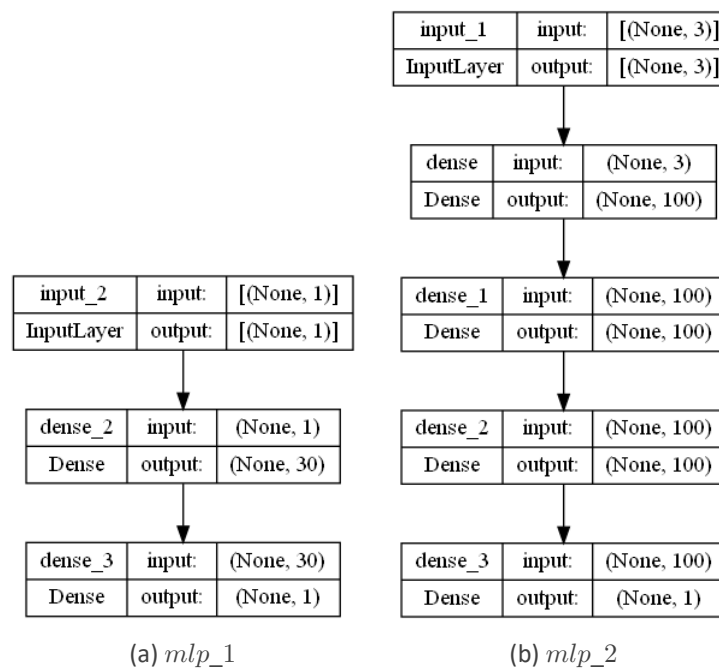


Figura 3.2.1.1: Comparación de dos arquitecturas del Perceptrón Multicapa (MLP) para la predicción del promedio del Volumen de Agua Subterránea. A la izquierda, el modelo utiliza una única variable de entrada, T_{med} , y consta de una única capa intermedia de 100 unidades antes de la capa de salida. A la derecha, el modelo incorpora tres variables de temperatura (T_{med} , T_{max} , T_{min}) y presenta tres capas intermedias, cada una con 100 unidades, antes de llegar a la capa de salida.

3.2.2. MLP para estimar el GWS con Precipitación

La resolución de los mapas del satélite CHIRPS para el área de estudio es de 30×30 píxeles. La representación matricial de estas imágenes se detalla en la Tabla 3.2.2.1. En la primera columna, se enumeran las claves correspondientes a las variables precipitación (P) y GWS. Para ambas variables, la matriz bidimensional está estructurada de la siguiente manera: la primera dimensión representa el número total de días (7274), mientras que la segunda posición corresponde al número total de píxeles por imagen, obtenido de multiplicar las dimensiones de resolución.

Var	Matriz	Reducción	Entradas
P	[7274, 30, 30,1]	[7274, $30 \times 30 \times 1$]	[7274, 900]
GWS	[7274, 6, 6, 1]	[7274, $6 \times 6 \times 1$]	[7274, prom[36], 1]

Tabla 3.2.2.1: Transformación de los datos de las variables de precipitación (P) y almacenamiento de agua subterránea (GWS). La columna *Matriz* indica las dimensiones originales de los datos, *Reducción* muestra cómo se multiplican estas dimensiones para eliminar tres. Finalmente la columna *Entradas* describe las dimensiones finales de los datos que alimentan al modelo.

Los entrenamientos *mlp_3* y *mlp_4*, mostrados en la Figura 3.2.2.1 varían en el número de capas ocultas y en la cantidad de épocas para ambas arquitecturas. La capa de entrada consta de 900 neuronas, correspondientes a los valores de cada píxel en la imagen. En cuanto al almacenamiento de agua subterránea, la capa de salida se mantuvo igual que en modelos anteriores, considerando el valor promedio diario correspondiente.

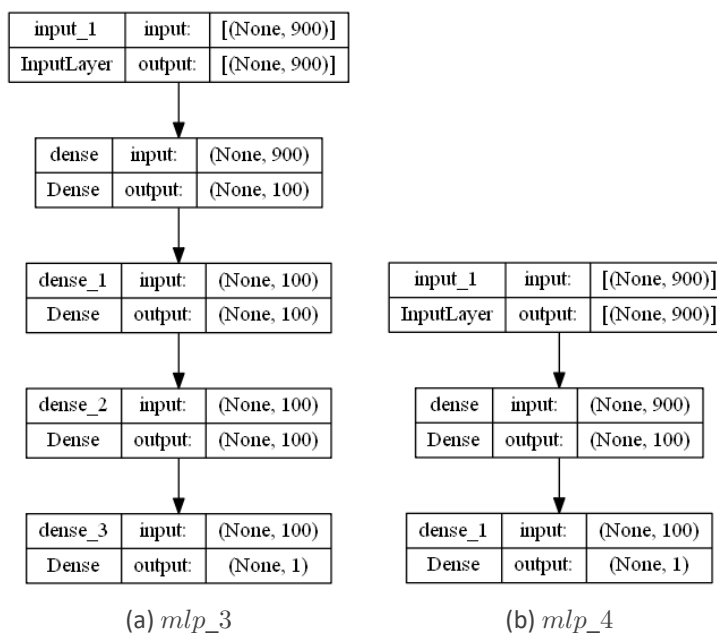


Figura 3.2.2.1: Dos arquitecturas de MLP para predecir el promedio de GWS utilizando 900 valores de Precipitación en la entrada. A la izquierda, el modelo (a) *mlp_3* se desarrolla a través de cuatro capas densas. A la derecha, el modelo (b) *mlp_4* presenta una configuración más simplificada con solo tres capas densas. Ambos modelos exploran cómo la cantidad y estructura de las capas afectan el rendimiento en la tarea de predicción del GWS.

3.2.3. MLP para estimar el GWS con Evaporación

La resolución de los datos de Evaporación del satélite GLEAM coincide con la resolución del Almacenamiento de Agua Subterránea de GRACE en el área de estudio. Ambos satélites utilizan una resolución de 6 píxeles de ancho por 6 píxeles de alto, lo que equivale a un total de 36 puntos de valores por cada uno de los 7274 días. A diferencia de las variables anteriores, un mapa de evaporación consta de 10 bandas, que se organizan en la matriz de entrada de la siguiente manera:

1. Actual Evaporation (E)
2. Soil Evaporation (Eb)
3. Interception Loss (Ei)
4. Potential Evaporation (Ep)
5. Snow Sublimation (Es)
6. Transpiration (Et)
7. Open-Water Evaporation (Ew)
8. Evaporative Stress (S)
9. Root-Zone Soil Moisture (SMroot)
10. Surface Soil Moisture (SMsurf)

A continuación, en la Tabla 3.2.3.1, se presentan dos formas de los valores de evaporación en relación con el GWS. El primer vector concentra únicamente los valores de una variable de evaporación (E), mientras que la segunda forma conserva las diez variables diarias en un arreglo con 360 valores.

Var	Matriz	Reducción	Entradas
1 banda de E	[7274, 6, 6,1]	[7274, $6 \times 6 \times 1$]	[7274, 36]
10 bandas de E	[7274, 6, 6,10]	[7274, $6 \times 6 \times 10$]	[7274, 360]

Tabla 3.2.3.1: La tabla muestra dos configuraciones: una con una sola banda de datos de evaporación y la segunda con diez. La columna *Matriz*, indica las dimensiones originales de los datos. El campo *Reducción* detalla como al multiplicarse las dimensiones estas se reducen a los valores de *Entradas*, 36 para cuando solo es una variable de evaporación y 360 valores cuando son 10 bandas de evaporación.

Estas dos variantes de arreglos se emplean en las arquitecturas representadas en la Figura 3.2.3.1. Los cuatro primeros entrenamientos utilizan 36 neuronas en la primera capa de entrada a la red, mientras que los entrenamientos mlp_{11} y mlp_{12} emplean 360 neuronas en la capa de entrada. Además, se consideró un tercer modelo con dos capas intermedias y otros dos entrenamientos que ocupan tres capas ocultas con entre 100 y 300 neuronas. Se realizaron más pruebas intentando incluir más capas ocultas y variando el número de neuronas, pero los resultados no fueron óptimos, por lo que se conservaron los modelos más representativos. Los primeros dos modelos, aunque su estructura parece similar con una capa oculta y 50 neuronas, se diferencian por el número de épocas empleadas para su entrenamiento. Esta diferencia se entenderá mejor con la descripción

de las estadísticas más adelante en la Tabla 4.3.1.

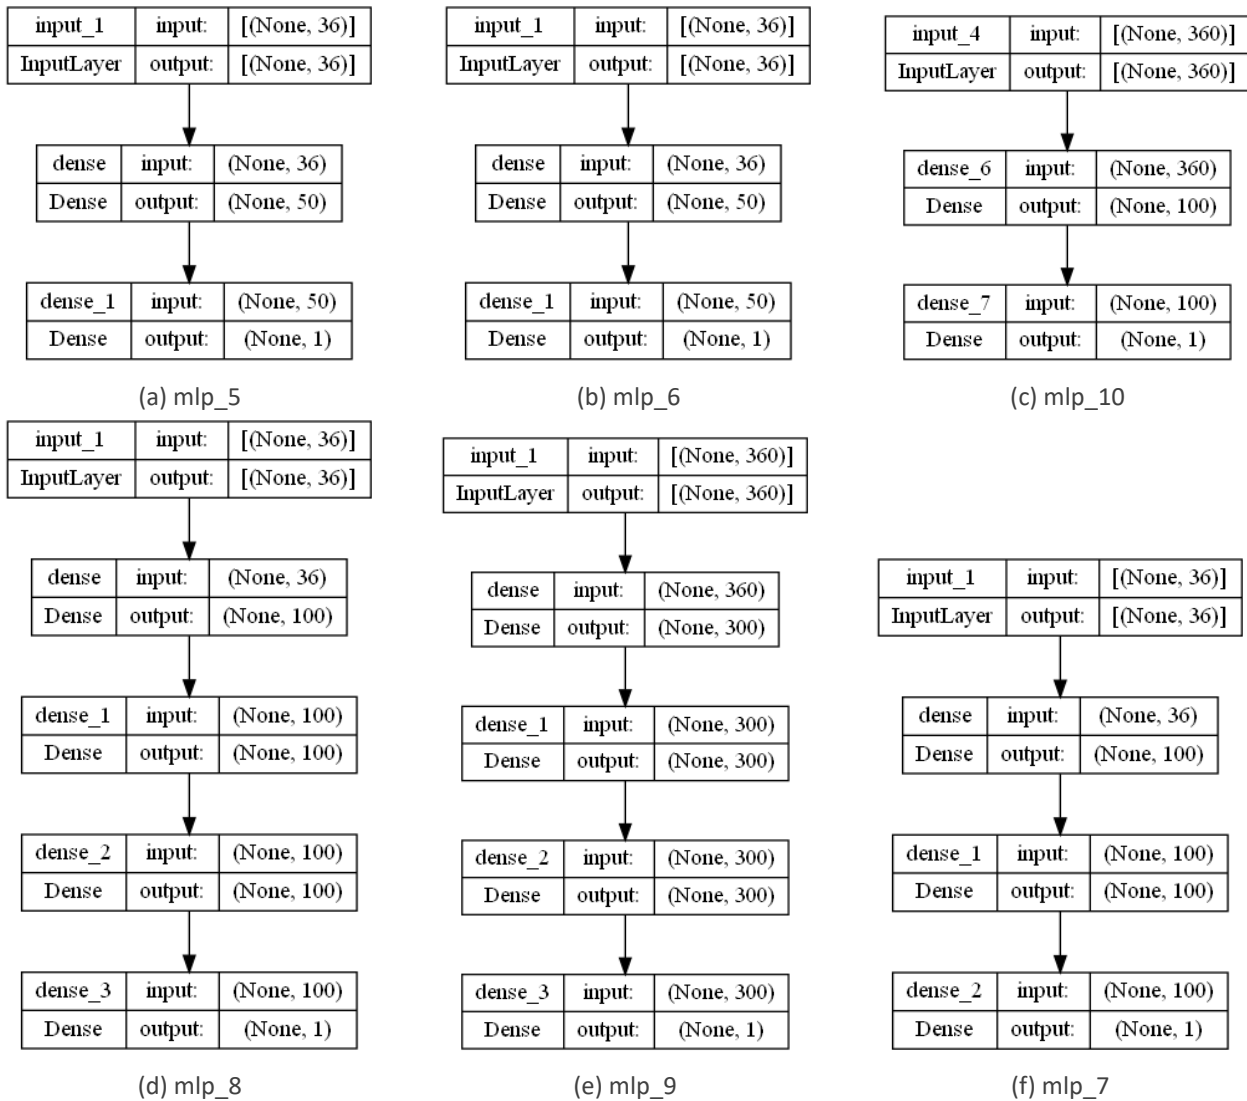


Figura 3.2.3.1: Diversas configuraciones de Perceptrón Multicapa (MLP) evaluadas para la predicción del Volumen de Agua Subterránea usando variables de Evaporación. Los modelos difieren en la cantidad de datos de entrada, procesando de 36 o 360 valores respectivamente, lo que refleja las dimensiones detalladas en la tabla inmediata anterior. Cada modelo varía en profundidad y complejidad, desde arquitecturas más simples con una o dos capas densas hasta configuraciones más complejas con hasta cuatro capas densas, diseñadas para probar el impacto de la estructura del modelo en la precisión de las predicciones.

3.3. RFR para estimar GWS

El propósito de aplicar el método de Regresión de Bosques Aleatorios (RFR, *Random forests for regression*) a nuestros datos es estimar cuáles variables podrían tener una mayor influencia en la predicción del cambio en el almacenamiento de agua subterránea. Sin embargo, es importante destacar que este modelo no puede considerarse como el óptimo, dado que, al igual que en el modelo anterior, no se están considerando las componentes espaciales ni las temporales de los datos.

Para iniciar el proceso de entrenamiento del modelo, resulta fundamental consolidar todas las variables en una tabla única y abordar la disparidad de las resoluciones de las imágenes. Para resolver este problema, se calculó el promedio de los valores correspondientes al área de estudio, generando así un único valor diario por cada variable. De esta manera, aunque se pierde la información espacial de cada observación, se logra la unificación de todas las variables en un formato tabular, requisito esencial para aplicar este método. La tabla resultante consta de 7,274 registros, que corresponden al número de días que abarca el período de estudio, y 15 columnas, representando las variables que se utilizan en el modelo para su evaluación (Figura 3.3.1).

	t_mean	t_max	t_min	precip	E	Eb	Ei	Ep	Es	Et	Ew	S	SMroot	SMSurf	GWS_tavg
0	285.056349	294.857504	275.992938	0.000000	0.189762	0.146036	0.000000e+00	1.097699	0.0	0.042853	0.000873	0.178272	0.116905	0.101454	496.988047
1	287.893719	296.612315	280.401154	0.000000	0.228232	0.175650	0.000000e+00	1.321804	0.0	0.051589	0.000993	0.176532	0.116205	0.100794	497.360773
2	285.707505	294.959061	277.931909	0.000000	0.200015	0.151653	0.000000e+00	1.196959	0.0	0.047413	0.000950	0.173073	0.115575	0.097957	497.650001
3	281.386400	291.094430	274.322185	0.035853	0.145274	0.109635	0.000000e+00	0.949822	0.0	0.034893	0.000745	0.158983	0.114415	0.096813	497.870924
4	284.172292	290.801509	280.622225	2.604074	0.101550	0.075874	0.000000e+00	0.623601	0.0	0.025215	0.000461	0.159638	0.114677	0.098649	498.035609
..

Figura 3.3.1: Tabla de datos utilizada para el análisis de importancia de variables en un modelo de Bosques Aleatorios. Las columnas representan las diferentes variables, como temperaturas media, máxima y mínima (t_mean, t_max, t_min), precipitación (precip), y diferentes componentes de la evaporación (E, Eb, Ei, Ep, Es, Et, Ew), junto con las variables de humedad del suelo (S, SMroot, SMSurf) y el promedio de Almacenamiento de Agua Subterránea (GWS_tavg). Esta tabla facilita la evaluación de qué variables contribuyen más significativamente a la predicción del GWS, permitiendo seleccionar las más predictivas para optimizar el modelo.

Con la integración de todos los datos en un formato tabular, es posible separar la variable dependiente, y , que representa el almacenamiento de agua subterránea, de las variables independientes, X , que comprenden el resto de las columnas.

Los modelos fueron generados utilizando el módulo de sklearn, específicamente el objeto de RandomForestRegressor (sklearnF, 2023). El árbol representado en la Figura 3.3.2 se obtuvo mediante un proceso de entrenamiento que involucró 1000 estimadores y una profundidad (número de niveles en el árbol) de 3. La Figura 3.3.2 muestra la estructura del árbol; esta es representada mediante rectángulos, donde cada uno corresponde a un nodo que contiene cinco valores: la clave de la variable, el error cuadrático medio (MSE), el número de muestras (*samples*) y el valor de la predicción, que en nuestro caso se refiere al almacenamiento de agua subterránea en *mm*.

Para ejemplificar el funcionamiento del árbol, este comienza con un nodo raíz que plantea la pregunta: ¿El valor de la variable *Es* es menor o igual a 0.1? Si esta condición es verdadera, continúa descendiendo por la rama izquierda, considerando la variable *SMSurf*. Si la condición es falsa, sigue por la rama derecha, evaluando la siguiente variable *Es*. Como se puede observar, las condiciones verdaderas conducen a la izquierda, mientras que las condiciones falsas llevan a la derecha en cada nodo. El árbol concluye en el tercer nivel, proporcionando las últimas estimaciones del almacenamiento de agua subterránea. Según este árbol en particular, solo cuatro variables (*Es*, *SMSurf*, *E* y *Et*) son realmente relevantes para realizar la predicción, mientras que las demás características carecen de importancia en este contexto.

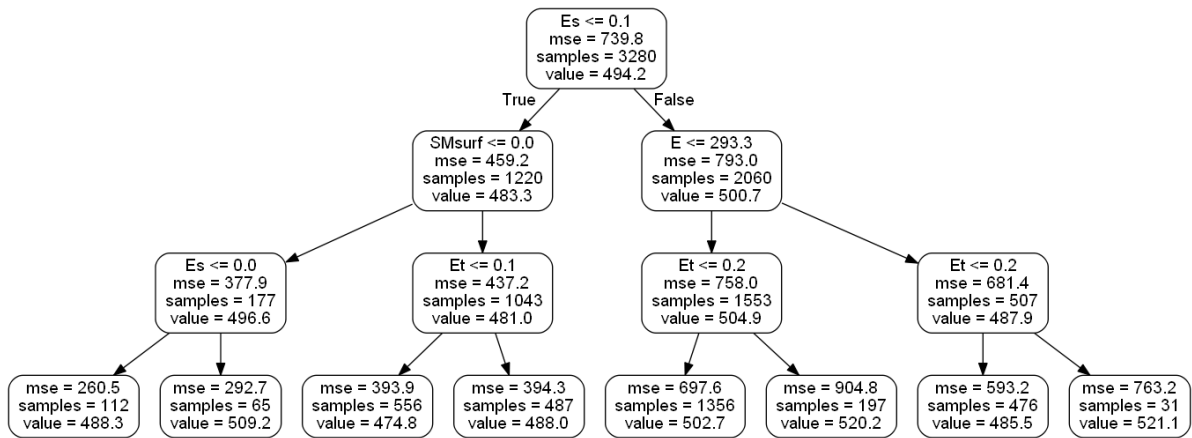


Figura 3.3.2: Árbol de decisión con 3 niveles de profundidad y 1000 estimadores, utilizado para predecir el Almacenamiento de Agua Subterránea. Cada nodo del árbol muestra el valor de corte para una variable (Es, Smsurf, Et), el error cuadrático medio (MSE), el número de muestras en el nodo y el valor promedio de GWS en ese nodo. Este modelo facilita la identificación de las variables más importantes y cómo influyen en las predicciones del GWS.

Se llevaron a cabo varios entrenamientos RFR, sin restricciones en la profundidad, variando el número de estimadores desde 100 hasta 1000. Los resultados se mantuvieron consistentes con las seis primeras variables mencionadas y para verificar la importancia de estas variables, se repitió el entrenamiento del MLP *mlp_9*, usando la misma arquitectura, pero esta vez tomando como entrada solo las primeras cinco variables propuestas que refiere la Tabla 4.4.1.

El modelo, como se presenta en la Figura 3.3.3, comienza con 180 neuronas en la capa de entrada, resultantes de multiplicar la latitud por la longitud y las 5 bandas seleccionadas de evaporación ($[6 \times 6 \times 5]$). A continuación, se implementan tres capas intermedias con 300 neuronas cada una, y la capa de salida consta de una sola neurona que estima el promedio del GWS.

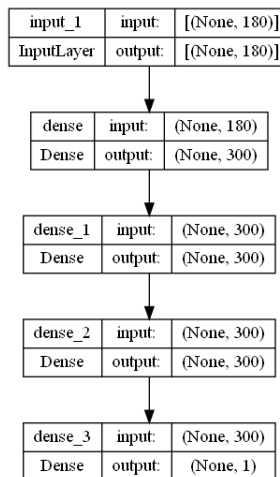


Figura 3.3.3: Estructura del modelo de Perceptrón Multicapa *mlp_11*, configurado para utilizar las cinco variables identificadas como las más importantes por el modelo RFR. El modelo consta de una capa de entrada que recibe 180 datos (correspondientes a las cinco variables seleccionadas a lo largo de varios tiempos), seguido por tres capas densas con 300 neuronas cada una, y una capa de salida con una única neurona para predecir el Volumen de Agua Subterránea.

3.4. CNN para estimar el GWS

En los modelos anteriores, las variables de entrada, es decir, las imágenes, presentan transformaciones que implican aplanar su dimensionalidad para convertirlas en vectores unidimensionales, lo que conlleva la pérdida de su espacialidad. Una de las ventajas de utilizar una red neuronal convolucional (CNN) es que las imágenes conservan sus dimensiones originales, como ancho, alto, tiempo y canales o bandas de información.

En esta arquitectura, las entradas consisten en tres imágenes que representan las variables de Evaporación, Temperatura y Precipitación (E, T, P). La configuración de los datos de entrada se ilustra en la Tabla 3.4.1. La primera matriz corresponde a la Evaporación, señalada como X_1 , con dimensiones $[6 \times 6 \times 5]$, es decir, 6 píxeles de alto por 6 píxeles de ancho y 5 bandas de información (SM_{root} , Et , Eb , SM_{surf} , Ew). La segunda matriz corresponde a los datos de Temperatura del satélite ERA, identificada como X_2 , con dimensiones $[16 \times 16 \times 3]$, donde las 3 bandas representan los valores de Temperatura máxima, media y mínima. Por último, la variable X_3 corresponde a la Precipitación, la cual contiene una única banda con información proveniente del satélite CHIRPS.

	X1 GLEAM	X2 ERA	X3 CHIRPS
train	(4655, 6, 6, 5)	(4655, 16, 16, 3)	(4655, 30, 30, 3)

Tabla 3.4.1: Dimensiones de los datos de entrada para el conjunto de entrenamiento de un modelo CNN, utilizando variables de los tres satélites. X_1 GLEAM representa datos con dimensiones $[4655, 6, 6, 5]$, X_2 ERA con $[4655, 16, 16, 3]$, y X_3 CHIRPS con $[4655, 30, 30, 3]$. Cada conjunto de datos corresponde al número de muestras, altura, ancho y canales de características respectivamente, preparados específicamente para ser procesados por la primera capa convolucional del modelo.

La Figura 3.4.1 del entrenamiento *cnn_1*, generada utilizando la librería *model_to_dot* de Keras (TF, 2023), muestra una estructura similar a la de un diagrama de árbol. En este diagrama, cada nodo está representado por un rectángulo dividido en tres columnas y dos filas. La primera columna indica el nombre de la variable, la segunda señala si corresponde a una entrada o salida, y la tercera muestra las dimensiones del arreglo. Es importante notar que en todos los arreglos del modelo, la primera posición siempre comienza con la palabra *None*. Este valor está reservado para el tamaño del lote (*batch_size*), que corresponde al número de imágenes (tiempo) utilizadas en el segmento de entrenamiento. A continuación, se detalla la resolución de la imagen, y la última posición del arreglo representa el número de filtros, los cuales van cambiando a medida que la red se hace más profunda.

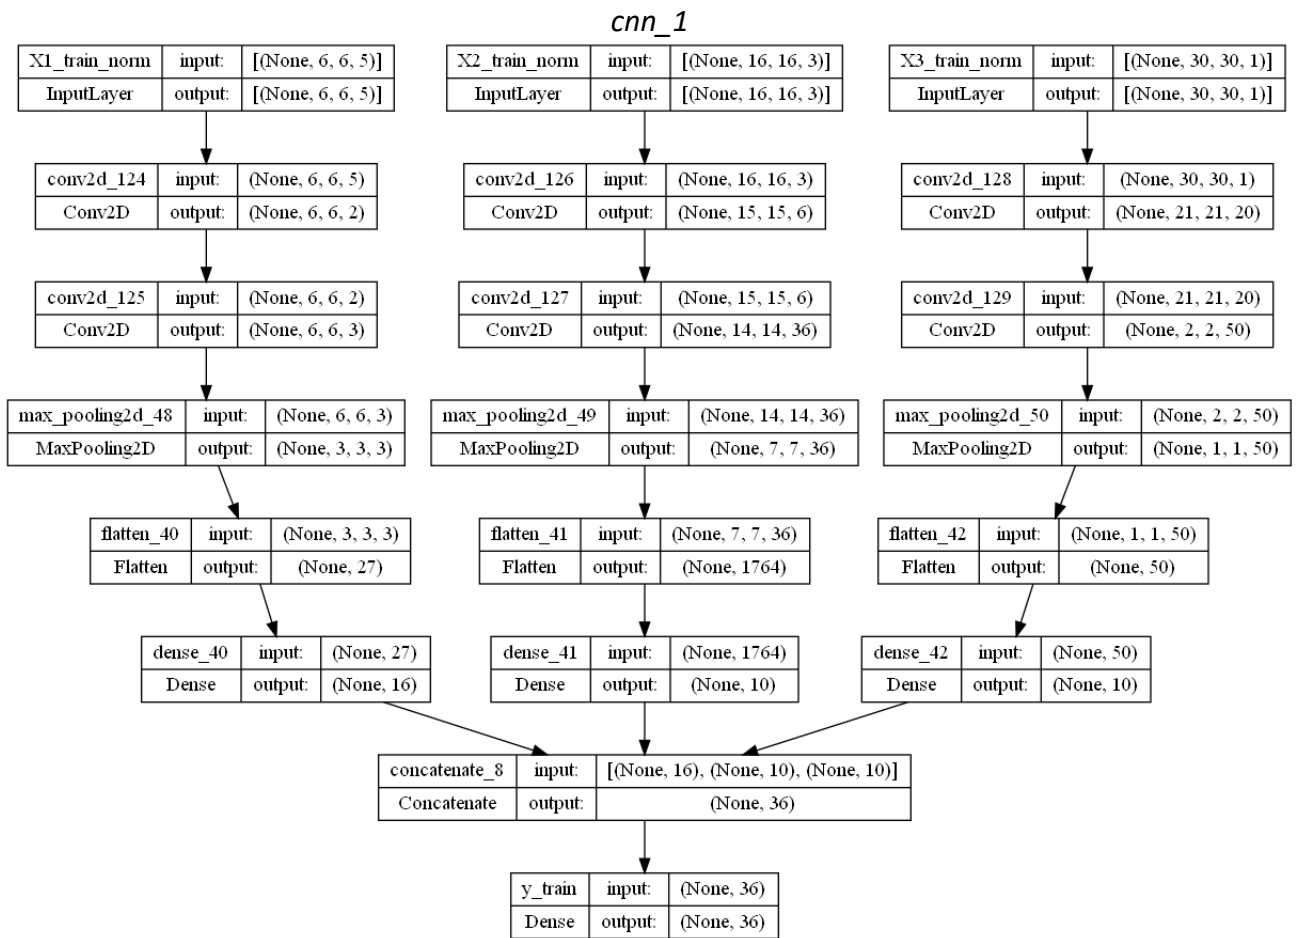


Figura 3.4.1: Modelo CNN para la estimación del Almacenamiento de agua subterránea. Este modelo integra tres flujos de entrada diferentes, cada uno correspondiente a una variable ambiental distinta (GLEAM, ERA, CHIRPS), procesadas a través de capas convolucionales y de agrupamiento, seguidas por capas densas. La fusión de las características extraídas se realiza antes de la capa de salida, que estima el almacenamiento de agua subterránea. Este enfoque permite capturar y combinar patrones espaciales y temporales críticos de cada conjunto de datos para mejorar la precisión de la estimación.

El modelo *cnn_1* comprende un total de 8 niveles y 16 capas. El diseño inicia con tres flujos paralelos de procesamiento, cada uno de los cuales sigue una arquitectura similar, pero con diferentes dimensiones de entrada y profundidad de variables. El primer nivel del modelo consiste en tres variables de entrada con diferentes matrices o resoluciones. En cada flujo, después de la capa de entrada, se aplican dos capas convolucionales con activación *Tanh*. Las capas convolucionales tienen distintas profundidades de filtros, los cuales aumentan a medida que avanza el flujo. Este incremento permite que el modelo capture tanto características de bajo como de alto nivel. Por ejemplo, en las entradas X_1 y X_2 , se comienza con pocos canales (5 y 3, respectivamente), los cuales se incrementan progresivamente hasta alcanzar 36 y 50 canales en las capas finales.

Tras cada bloque de capas convolucionales, se aplica una capa de agrupación máxima (*MaxPooling2D*), que reduce las dimensiones espaciales de los mapas de características, conservando solo las más relevantes. Posteriormente, cada flujo pasa por una capa de aplanamiento (*Flatten*), que convierte el tensor tridimensional en un vector unidimensional. Las dimensiones de los vectores

aplanados varían dependiendo del tamaño inicial de la entrada y del número de operaciones de convolución y *pooling* aplicadas. Así, los tamaños de los vectores resultantes son 27, 1764 y 50 en los tres flujos, respectivamente.

Cada flujo de características aplanadas es luego procesado por una capa densa (*Dense*) con activación *Tanh*, lo que reduce aún más el tamaño de los vectores. En esta fase, las capas densas ajustan los vectores a dimensiones más manejables: 16 neuronas para el flujo X_1 y 10 neuronas para los flujos X_2 y X_3 .

Las salidas de las tres secciones se concatenan en una sola capa, formando un vector final de 36 dimensiones. Esta concatenación combina las características aprendidas en los tres flujos de datos para generar una representación conjunta.

Después de la concatenación, el modelo conecta el vector combinado a una capa densa (*Dense*) con activación *ReLU*. La activación *ReLU* se utiliza en este punto para mantener los valores positivos y mitigar problemas de saturación en la red, lo que favorece un entrenamiento más eficiente.

Finalmente, esta capa produce la salida del modelo con 36 neuronas, que representan la predicción final o las características aprendidas por el modelo. Estos 36 valores están asociados a los valores continuos del almacenamiento de agua subterránea.

3.5. LSTM para estimar el GWS

Como se mencionó en el marco teórico de esta investigación, los modelos LSTM integran una dimensión de pasos en su arquitectura. Estos *pasos de tiempo* constituyen un hiperparámetro definido en las LSTM para indicar el número de pasos con los que el modelo aprende para luego predecir un número equivalente de pasos futuros. Estos pasos pueden coincidir con la estacionalidad de las series de datos temporales meteorológicos, ya que estas observaciones se registran como una secuencia ordenada en el tiempo con intervalos regulares, como cada hora, día, semana, mes, trimestre o año (Hyndman y Athanasopoulos, 2018).

En la Figura 3.5.1 se muestra un ejemplo básico para la segmentación de datos en tres pasos. Este proceso involucra dos variables de entrada, $[X_1, X_2]$, y una variable de salida, Y , donde cada variable cubre tres días, desde $t = 1$ hasta $t = 3$.

Es importante señalar que la arquitectura LSTM no trabaja directamente con la referencia espacial, por lo que los valores de los píxeles de las imágenes correspondientes a cada día se promedian, eliminando así la latitud y la longitud. Esto permite obtener un único valor diario por cada imagen. Luego, para organizar la tabla según los pasos temporales, los valores de X_1 y X_2 del día 1 se emparejan con el valor de Y del día 3, como se ilustra en los recuadros de color naranja. Del mismo modo, el día 2 de X_1 y X_2 se empareja con el día 4 de Y , y así sucesivamente.

Este proceso permite a la red LSTM aprender las relaciones temporales entre los datos históricos y los valores futuros.




Figura 3.5.1: Esquema de la segmentación temporal de datos para un modelo LSTM, mostrando cómo se organizan los conjuntos de entrada X_1 y X_2 y los objetivos Y en ventanas de tiempo de tres pasos. Este método permite al modelo LSTM aprender dependencias a través del tiempo al correlacionar secuencias de entrada consecutivas con salidas futuras, crucial para la predicción precisa en series temporales.

Se realizaron múltiples pruebas con modelos LSTM siguiendo las recomendaciones de la literatura. En estas pruebas se intentó predecir el almacenamiento de agua subterránea (*GWS*) con diferentes horizontes de predicción, abarcando desde un paso diario hasta anticipaciones mensuales, estacionales y anuales. Además, se evaluaron tanto enfoques univariados como multivariados. El enfoque univariado consistió en predecir el *GWS* utilizando exclusivamente los valores pasados de esta misma variable, mientras que el enfoque multivariado, ya empleado en arquitecturas anteriores, incorporó diversas variables adicionales, como la temperatura, la precipitación y la evaporación, para mejorar la precisión en la predicción del *GWS*.

A continuación, en la Tabla 3.5.1, se presentan las formas de los vectores de entrada para tres modelos, diferenciados por los pasos y el número de variables utilizadas para realizar la predicción. El primer modelo, denominado *lstm_1*, intenta predecir el promedio del almacenamiento de agua subterránea a un mes, utilizando como entrada el promedio de cada una de las cinco variables de evaporación. Los modelos segundo y tercero, *lstm_2* y *lstm_3*, respectivamente, buscan predecir el *GWS*, es decir, los 36 valores del área de interés un día después. El modelo *lstm_2* emplea el mismo *GWS* como entrada, mientras que el modelo *lstm_3* utiliza únicamente una variable de evaporación (*SMroot*) como entrada.

Modelo	Pasos	Matriz con Pasos	Salida de Y
<i>lstm_1</i>	31 pasos = 1 mes	[7274, 31, 5]	GWS_{med}
<i>lstm_2</i>	1 paso = 1 día	[7274,1,36]	36 valores de <i>GWS</i>
<i>lstm_3</i>	1 paso = 1 día	[7274,1,36]	36 valores de <i>GWS</i>

Tabla 3.5.1: Configuración de las entradas para tres modelos LSTM distintos diseñados para predecir el almacenamiento de agua subterránea. Cada modelo tiene una estrategia diferente: *lstm_1* utiliza 31 pasos representando un mes con 5 variables de evaporación, *lstm_2* y *lstm_3* utilizan un paso por día con 36 valores diarios de *GWS* y *Smroot*, respectivamente.

Una vez que los datos han sido organizados conforme a los pasos temporales definidos, se procede

con la segmentación en conjuntos de entrenamiento, validación y prueba. Dado que la arquitectura LSTM está diseñada para aprender a lo largo de un período de tiempo, es esencial preservar el orden temporal de los datos durante esta división. A diferencia de otras arquitecturas donde los datos pueden seleccionarse de manera aleatoria, en las LSTM es fundamental que los datos de prueba sean posteriores a los de entrenamiento, garantizando un orden y un aprendizaje basado en la secuencia temporal, tal como se ilustra en la Figura 3.5.2.

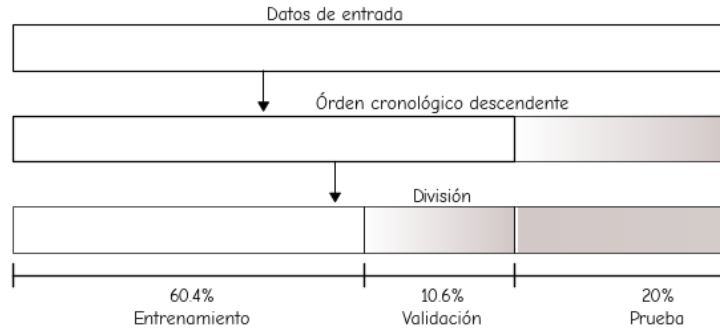


Figura 3.5.2: Proceso de segmentación de series de tiempo para entrenamiento, validación y prueba en un modelo LSTM. Los datos se ordenan en secuencia cronológica descendente antes de dividirlos, asegurando que la temporalidad de los eventos se mantiene consistente a lo largo de las fases de entrenamiento (60.4%), validación (10.6%) y prueba (20%).

La configuración de los tres entrenamientos se presenta en la Figura 3.5.3. Los dos primeros modelos (*lstm_1* y *lstm_2*) tienen una capa oculta de 100 neuronas, mientras que el tercero (*lstm_3*) cuenta con dos capas ocultas, cada una con 100 neuronas. En el primer modelo, la salida es el promedio del GWS. En el segundo y tercer modelos, la salida corresponde a una imagen de GWS de dimensiones $[6 \times 6]$.

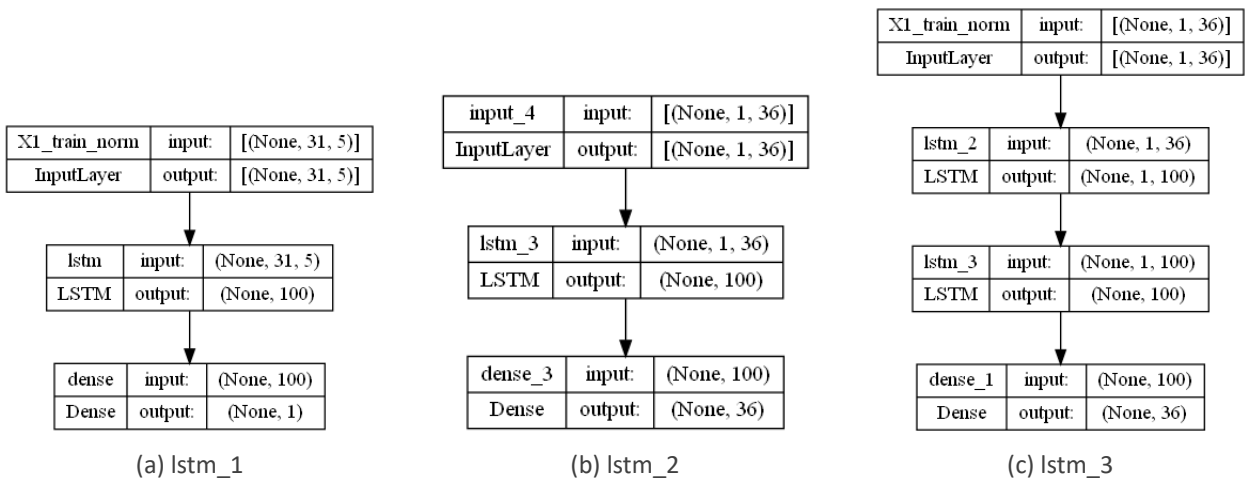


Figura 3.5.3: Tres arquitecturas de modelos LSTM, cada uno configurado para diferentes entradas y salidas: (a) *lstm_1* con 31 pasos diarios, procesando 5 variables de evaporación, (b) *lstm_2* y (c) *lstm_3* ambos con 1 paso diario pero *lstm_2* usando 36 valores de GWS y *lstm_3* 36 valores de Smroot. Cada modelo apunta a predecir el GWS basados en sus configuraciones específicas.

3.6. CRNN para estimar el GWS

Las CRNN combinan redes neuronales convolucionales y redes recurrentes, permitiendo la extracción de características espaciales a través de las capas convolucionales antes de procesar las dependencias temporales con las capas recurrentes. Esto es especialmente útil en tareas donde la estructura espacial está presente (Shi y cols., 2016).

La arquitectura CRNN requiere que las muestras tengan un formato 3D $[lat, lon, val]$ para la parte de la CNN y cumplan con la forma [muestras, intervalos de tiempo, características] para la LSTM. Dada esta premisa, inicialmente se dispone de una tabla bidimensional compuesta por el par (\vec{X}_i, \vec{y}_i) , donde \vec{X}_i corresponde a las variables de evaporación del satélite de GLEAM ($SMroot, Et, Eb, SMsurf, Ew$) sugeridas por el modelo Bosques Aleatorios, y la variable \vec{y}_i , que en todos los casos ha sido el Almacenamiento de Agua Subterránea.

Una vez seleccionadas las variables involucradas en el módulo CNN en su forma 3D, se procede con la configuración de la siguiente dimensión que ocuparán las LSTM: los pasos. En este caso, se configuraron los datos para incluir dos tipos de arquitecturas:

- *Many-to-Many* con tiempo sincronizado: Como se muestra en la Figura 3.6.1 en el lado izquierdo, esta arquitectura se caracteriza por procesar múltiples entradas y mapearlas a múltiples salidas, conservando una longitud igual entre ambas. Este tipo de modelo es útil cuando cada entrada tiene una salida correspondiente en la misma secuencia temporal, asegurando una relación directa entre las entradas y las salidas a lo largo de cada paso de tiempo.
- *Many-to-Many* con tiempo no sincronizado: Esta arquitectura, representada en el lado derecho de la Figura 3.6.1, procesa múltiples entradas y genera múltiples salidas, pero, a diferencia del enfoque con tiempo sincronizado, la longitud de las entradas y las salidas no tiene que coincidir. Esto significa que las salidas pueden generarse después de un retraso respecto a las entradas, o bien puede haber más o menos salidas que entradas. Es útil en situaciones donde la salida depende de varios pasos de entrada, pero no necesita estar directamente alineada con cada uno.




Figura 3.6.1: La arquitecturas LSTM de tipo *many-to-many* mostrando dos enfoques: sincronizado, donde las salidas son generadas simultáneamente con las entradas, y asíncrono, donde las salidas dependen de todas las entradas previas sin sincronización inmediata con estas.

Estas arquitecturas se analizarán con mayor detalle en los modelos que se describen a continua-

ción. Basándose en las pruebas previas con las arquitecturas CNN y LSTM, la selección de los hiperparámetros clave, tales como el número de pasos, épocas y capas ocultas, resultó más precisa. Aunque se realizaron múltiples experimentos variando diferentes configuraciones de estos hiperparámetros, esta investigación expone los resultados más representativos. En la Tabla 3.6.1, se presentan dos configuraciones distintas del enfoque *Many-to-Many*: una para un modelo sincronizado y otra para un modelo asíncrono.

En la primera fila, el vector de entrada contiene una dimensión de 30 pasos, mientras que en el segundo modelo el vector de entrada contiene 31 pasos. En ambos casos, el vector de salida contiene 36 valores en la dimensión de muestra.

Es importante recordar que estos vectores de entrada han pasado previamente por un riguroso protocolo de preprocesamiento. Inicialmente, los datos fueron ordenados temporalmente y de acuerdo con las coordenadas [longitud, latitud]. Posteriormente, se dividieron en segmentos de 30 y 31 pasos. Luego, los datos fueron segregados en tres conjuntos: entrenamiento, validación y prueba, sin aplicar mezclado aleatorio (*shuffle*). Finalmente, los datos en cada uno de estos tres conjuntos fueron normalizados.

Modelo	Pasos	Matriz con Pasos	Salida de GWS
asíncrono	30 pasos	[None, 30, 6, 6, 5]	[None, 30, 36]
síncrono	31 pasos	[None, 31, 6, 6, 5]	[None, 31, 36]

Tabla 3.6.1: Configuraciones de entrada para modelos CRNN sincronizados y asincrónicos. Se detalla el número de pasos y la estructura de las matrices de entrada [None que representa cualquier número de muestras, 6 latitud, 6 longitud, 5 variables de evaporación]. Se describe también la dimensión de salida para la predicción del GWS.

La arquitectura utilizada para ejecutar ambos modelos (síncrono y asíncrono) es la misma; la diferencia radica en cómo se acomodaron los datos. Un ejemplo de este acomodo se ilustra en la Figura 3.6.2. En el formato síncrono, existe una correspondencia entre 31 días x como entrada y la salida y . En analogía con nuestros datos, esto implica que las cinco variables de evaporación aprenden a estimar el almacenamiento de agua subterránea en el mismo período temporal de la evaporación. En cuanto al formato asíncrono, las cinco variables de evaporación de entrada aprenden a predecir el almacenamiento de agua subterránea (*GWS*) 30 días después.




Figura 3.6.2: Comparación de dos arquitecturas LSTM, mostrando un modelo sincronizado con 31 pasos y un modelo asincrónico con 30 pasos. Cada paso representa un intervalo de tiempo en el procesamiento de la serie temporal, donde la sincronización refleja una alineación con intervalos regulares mientras que la asincrónica ajusta los pasos de acuerdo a criterios o pruebas específicas del modelo.

A continuación, en la Figura 3.6.3, se muestra la configuración de la arquitectura del modelo asíncrono. La capa de entrada tiene una forma de $(None, 30, 6, 6, 5)$. Aquí, *None* indica un tamaño de lote variable. El valor *30* representa el número de pasos de tiempo, *6* y *6* son las dimensiones espaciales, y *5* es el número de características (evaporación) en cada paso de tiempo.

Layer (type)	Output Shape	Param #
input_layer (InputLayer)	$(None, 30, 6, 6, 5)$	0
time_distributed (TimeDistributed)	$(None, 30, 6, 6, 2)$	12
time_distributed_1 (TimeDistributed)	$(None, 30, 6, 6, 3)$	9
time_distributed_2 (TimeDistributed)	$(None, 30, 3, 3, 3)$	0
time_distributed_3 (TimeDistributed)	$(None, 30, 3, 3, 4)$	16
time_distributed_4 (TimeDistributed)	$(None, 30, 36)$	0
lstm (LSTM)	$(None, 30, 36)$	10,512
dense (Dense)	$(None, 30, 36)$	1,332

Figura 3.6.3: Detalle de la arquitectura CRNN utilizada para el entrenamiento de predicción a 30 pasos en modo asíncrono. La estructura incluye capas distribuidas en tiempo para manejar entradas multidimensionales específicas de series temporales, seguido de una capa LSTM para capturar dependencias a largo plazo y una capa densa para la predicción de salida.

El modelo continúa con una capa convolucional con forma $(None, 30, 6, 6, 2)$. Esta capa aplica una operación convolucional a cada uno de los pasos de tiempo de forma independiente, transformando la forma a $(None, 30, 6, 6, 2)$, donde 2 es el número de filtros aplicados. Seguidamente, otra capa convolucional aplicada a cada paso de tiempo modifica la forma a $(None, 30, 6, 6, 3)$, con 3 filtros.

A continuación, se realiza una operación de convolución seguida de una reducción de la dimensionalidad (*pooling*), resultando en una forma de $(None, 30, 3, 3, 3)$. Posteriormente, una nueva capa convolucional transforma la forma a $(None, 30, 3, 3, 4)$, con 4 filtros. Luego, una capa de aplanado (*flattening*) convierte las dimensiones espaciales a una dimensión unidimensional para cada paso de tiempo, resultando en una forma de $(None, 30, 36)$, donde 36 es el producto de las dimensiones anteriores ($3 \times 3 \times 4$).

Para casi finalizar, se agrega una capa LSTM para procesar la secuencia temporal de longitud 30, generando una salida de la misma longitud temporal con 36 características para cada paso de tiempo.

El modelo concluye con una capa densa (*fully connected*) que mantiene la misma forma de salida que la capa LSTM, $(None, 30, 36)$, proporcionando una transformación final de los datos.

Este modelo CRNN utiliza una serie de capas convolucionales (envueltas en capas *TimeDistributed* para tratar cada paso de tiempo de manera independiente) seguidas de una capa LSTM para capturar dependencias temporales. Finalmente, una capa densa procesa la salida de la LSTM.

Las formas de las capas intermedias ilustran cómo se transforman y procesan los datos a través de las distintas etapas del modelo.

A continuación, se presenta la configuración de la arquitectura del modelo CRNN síncrono diseñado para la estimación del almacenamiento de agua subterránea, modificando solo la dimensión temporal a 31 días. Como se observa en la Figura 3.6.4, el vector de salida consta de 36 datos que, al ser transformados, resultan en una matriz de dimensiones $[6 \times 6]$. Esta matriz corresponde a la resolución espacial proporcionada por el satélite *GRACE*.

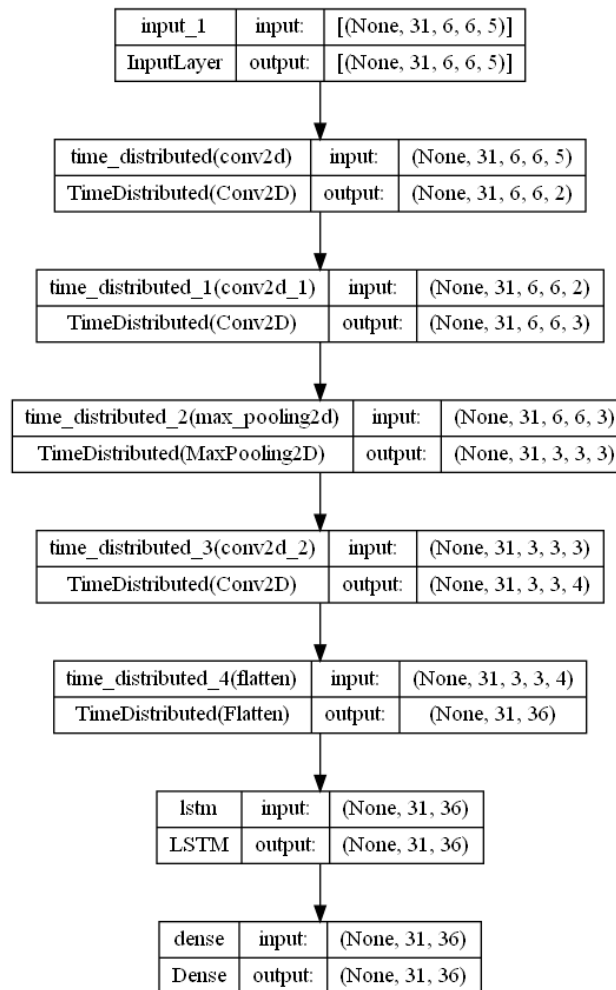


Figura 3.6.4: Arquitectura CRNN para entrenamiento con 31 pasos en modo sincronizado. Esta configuración incorpora capas de convolución y pooling distribuidas en el tiempo para procesar secuencias de entradas temporales, seguido de una capa LSTM para capturar dependencias temporales y una capa densa para la predicción final del almacenamiento de agua subterránea.

4 Resultados y análisis

En este capítulo se presentan los resultados obtenidos a lo largo de la investigación. Para ello, se incluyen tablas, gráficos y las métricas más relevantes que permiten evaluar el desempeño de las arquitecturas MLP, CNN, LSTM y CRNN, siguiendo el enfoque metodológico planteado en los capítulos anteriores. Además, se ha dedicado una sección específica a la comparación de los resultados más destacados con el fin de analizar de manera detallada el rendimiento de las diferentes arquitecturas.

Se incluye también una subsección sobre la conversión de unidades de mm a m^3 , en caso de ser necesario para la interpretación de los resultados en términos de volúmenes de agua. Por último, se presenta una compilación de trabajos relacionados que utilizan datos de teledetección del satélite GRACE y técnicas de IA, enfocándose en la estimación del volumen de agua subterránea para contextualizar los hallazgos de este estudio en un marco de investigaciones similares.

Antes de proceder con la presentación de los resultados, es fundamental que el lector comprenda los tres tipos de gráficos que se emplearán para ilustrar los hallazgos (ver Figura 4.1): (a) gráfica de función de pérdida, (b) gráfica de correlación, y (c) gráfica de comparación.

La gráfica de función de pérdida ilustra la evolución del entrenamiento del modelo a lo largo de las épocas en el eje x , cada una representando una iteración completa de los datos. En el eje y se muestra la pérdida, que típicamente reduce conforme el modelo aprende. La línea continua, etiquetada como **Entrenamiento**, muestra la pérdida calculada con los datos de entrenamiento, mientras que la línea discontinua, etiquetada como **Validación**, refleja el desempeño con un conjunto apartado del original para pruebas (10.6 %), proporcionando una medida de cómo el modelo generalizaría a nuevos datos.

La gráfica de correlación muestra en el eje x los valores predichos (**pred**) y en el eje y los valores de prueba (**test**). En estas gráficas, la línea diagonal representa la correlación ideal; teóricamente, si todos los puntos se alinean con esta línea, indicaría una excelente correlación entre los datos de prueba y los predichos.

Finalmente, la gráfica de comparación representa los resultados predichos (**pred**) en comparación con los valores de prueba (**test**). Su propósito es destacar las discrepancias entre los resultados generados por la arquitectura y el conjunto de datos reservado (20 %) para esta evaluación.

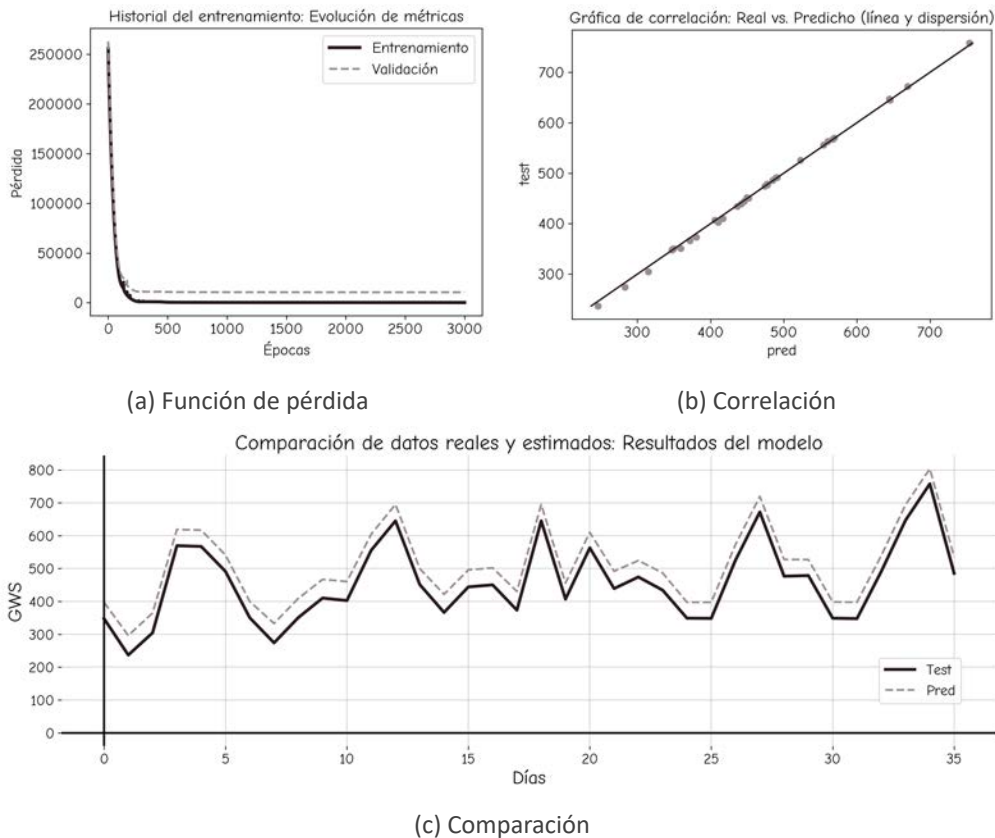


Figura 4.1: Ejemplo de las gráficas que serán presentadas en la sección de resultados, mostrando: (a) la evolución de la función de pérdida durante el entrenamiento y validación del modelo, indicativa de la optimización del aprendizaje; (b) la correlación entre los valores de GWS predichos por el modelo y los valores reales, demostrando la precisión de las predicciones; y (c) una comparación temporal de los valores de GWS reales y estimados, proporcionando una visualización directa del rendimiento del modelo en el tiempo.

4.1. MLP para estimar el GWS con Temperatura

Las métricas de evaluación para los entrenamientos *mlp_1* y *mlp_2* se detallan en la Tabla 4.1.1. Comenzando desde la izquierda, la primera columna muestra la clave de identificación del entrenamiento (*fit*), la segunda columna presenta el número de variables de entrada (*var*), la tercera columna expone el número de capas ocultas o intermedias (*capas h*), seguida por el número de neuronas por capa (*n*), en la cuarta columna, el número de épocas (*epochs*) y, por último, se indican las estadísticas que evalúan el rendimiento de los modelos: el error cuadrático medio (*MSE*), el error absoluto medio (*MAE*), el coeficiente de correlación del momento del producto de Pearson (*correlation*), también conocido como PPMCC o PCC (HELM, 2020) y el valor *p* del coeficiente de correlación de Karl Pearson (*P-value*), descritos en la sección del marco teórico.

Aunque más adelante, se hace una compilación de los resultados de estas métricas para comparar todas las arquitecturas, podemos adelantar que el *MSE* obtenido es considerablemente alto, dado que los valores a predecir oscilan entre 400 mm y 600 mm. Esto implica que, en promedio, el modelo está cometiendo un error de 26.26 mm con respecto a los valores reales, lo cual indica una discrepancia significativa. Por otro lado, el *MAE* de 21 mm sugiere que, en promedio, el modelo

tiene errores de aproximadamente 21 unidades en la misma escala que las predicciones.

En cuanto a la correlación, podemos deducir que esta no supera el 50 %, lo que significa que el modelo no logra capturar adecuadamente la relación entre los valores reales y los predichos. Aunque el valor P es extremadamente bajo, lo que indica que las diferencias observadas entre los valores predichos y los reales no son atribuibles al azar, esto no necesariamente es un buen indicativo. Este bajo *P-value* podría estar sugiriendo un ajuste excesivo del modelo (*overfitting*) o simplemente un mal rendimiento en las predicciones, lo que requiere una revisión y ajuste del modelo.

fit	var	capas h	n	epochs	MSE	MAE	correlation	P-value
<i>mlp_1</i>	1	1	30	300	698.823	21.076	23.2 %	2.34e-18
<i>mlp_2</i>	3	3	100	300	601.507	20.266	44.5 %	3.22e-68

Tabla 4.1.1: Métricas de evaluación de los modelos MLP para la predicción de GWS utilizando temperatura como variable de entrada. Cada modelo se diferencia por el número de variables de entrada (*var*), capas ocultas (*capas*), neuronas por capa (*h*), y épocas de entrenamiento (*epochs*). Se presentan los valores del error cuadrático medio (MSE), error absoluto medio (MAE), correlación entre los valores predichos y reales, y el valor-P asociado a la prueba de correlación.

La Figura 4.1.1 muestra las gráficas de la función de pérdida correspondientes a los entrenamientos *mlp_1* y *mlp_2*. En estas gráficas, se muestra la evolución de la pérdida a lo largo de las distintas épocas de entrenamiento. Se observa que el modelo logra una reducción significativa del error durante las primeras épocas, estabilizándose conforme avanza el entrenamiento. Este comportamiento sugiere que el modelo ha alcanzado un punto de convergencia, donde entrenar durante más épocas no resultará en mejoras significativas en el rendimiento. Como no existen diferencias marcadas entre la curva de entrenamiento y la de validación, esto nos deja ver que el modelo no está sobreajustado.




Figura 4.1.1: Evolución de la función de pérdida durante el entrenamiento y la validación de dos modelos MLP. (a) *mlp_1* utiliza una sola variable y 30 neuronas en cada una de sus capas ocultas. (b) *mlp_2* utiliza tres variables y 100 neuronas en sus capas. Cada gráfico muestra la pérdida en escala logarítmica frente al número de épocas, reflejando cómo la pérdida decrece a medida que el modelo aprende de los datos.

En la Figura 4.1.2, se muestran los diagramas de dispersión correspondientes a los entrenamientos

mlp_1 y mlp_2 . En ambos gráficos, la mayoría de los puntos se agrupan en torno a un valor cercano a 500, independientemente de que los valores reales oscilen entre aproximadamente 440 y 560. Esto indica que el modelo tiende a predecir valores cercanos a 500, sin captar adecuadamente la variabilidad de los datos reales. Una correlación óptima ocurre cuando los puntos se agrupan cercanos a la diagonal; sin embargo, en estos modelos, esto no se cumple. Esto podría significar que el modelo es demasiado simple para captar la complejidad de los datos.




Figura 4.1.2: Gráficos de dispersión comparando los valores predichos contra los valores reales de prueba para dos configuraciones del modelo MLP. (a) mlp_1 muestra los resultados usando una variable de entrada. (b) mlp_2 utiliza tres variables. La línea diagonal representa la perfecta correlación entre predicciones y valores reales, sirviendo como referencia para evaluar la exactitud de cada modelo.

4.2. MLP para estimar el GWS con Precipitación

Las métricas de evaluación para los dos modelos mlp_3 y mlp_4 se presentan en la Tabla 4.2.1; se puede observar que la pérdida (MSE) se mantiene en niveles significativamente altos. No se evidencia una correlación aceptable entre las predicciones y los valores reales, y la confianza en las predicciones (P -value) es muy baja, algo que también se puede constatar con las gráficas de dispersión mostradas a continuación en la Figura 3.1.1.3.

fit	var	shape	h	epochs	MSE	MAE	correlation	P-value
mlp_3	1	900	3	1000	992.77	24.705	-0.044	0.1
mlp_4	1	900	1	300	1835.076	26.987	0.047	0.078

Tabla 4.2.1: Métricas de evaluación para los modelos MLP que utilizan la precipitación como variable de entrada. Los modelos se diferencian por el número de capas ocultas (h) y la cantidad de épocas durante las cuales se entrenaron. MSE indica el error cuadrático medio, MAE el error absoluto medio, y $Correlación$ mide la relación lineal entre las predicciones y los valores reales. P -value evalúa la significancia estadística de la correlación observada.

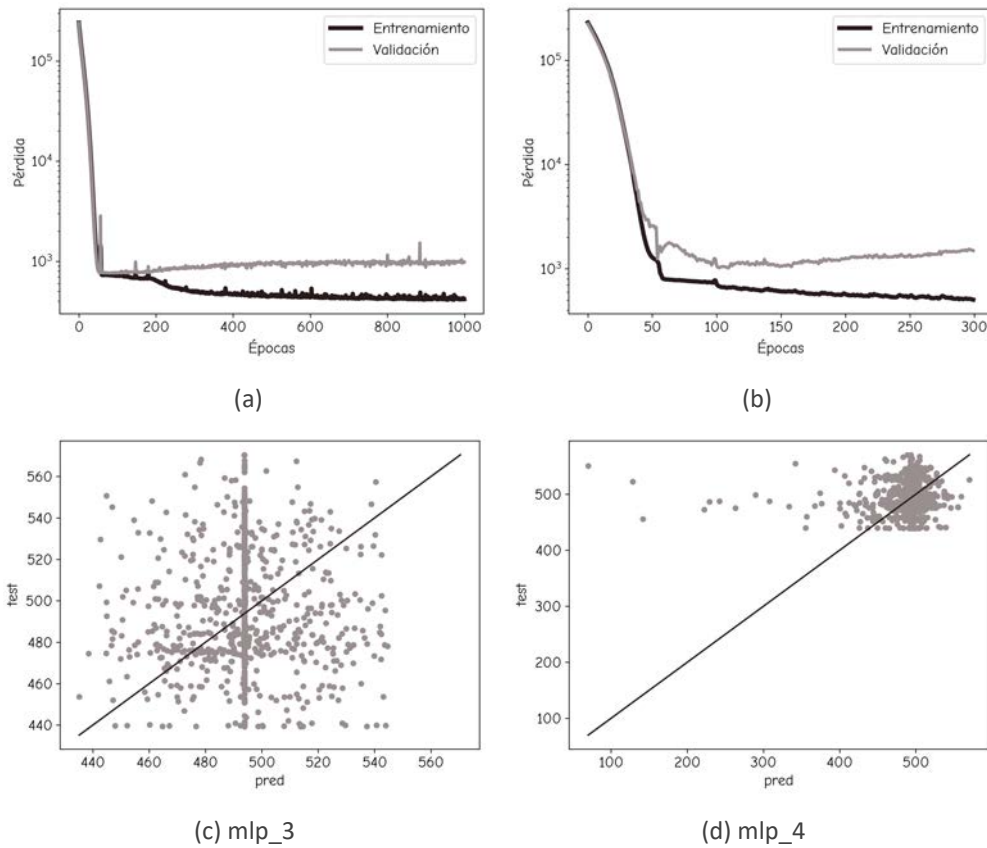


Figura 4.2.1: Evaluación de los modelos MLP para precipitación a través de gráficas de la función de pérdida y de dispersión. Las gráficas (a) y (b) muestran la función de pérdida (loss) a lo largo de las épocas de entrenamiento y validación para los modelos *mlp_3* y *mlp_4*, respectivamente. Las gráficas (c) y (d) corresponden a la dispersión de los valores predichos frente a los reales, demostrando la capacidad predictiva de cada modelo en el conjunto de prueba.

4.3. MLP para estimar el GWS con Evaporación

Los entrenamientos *mlp_5* y *mlp_6* (Tabla 4.3.1), aunque utilizan las mismas 36 neuronas en la primera capa, es decir, con los valores de la evaporación actual, difieren en el número de épocas empleadas para su entrenamiento. Al incrementar las épocas de 100 a 5000, se observa una mejoría en las métricas que miden el rendimiento de los modelos. En este caso, tanto la pérdida *loss* como el error *MAE* disminuyen de 775.46 a 408.23 y de 21.716 a 13.610, respectivamente. La correlación muestra un aumento significativo de 0.131 a 0.725 y el *P-value* también disminuye.

Al continuar con la configuración de 36 neuronas en la entrada, pero aumentando a dos capas intermedias con 100 neuronas (*mlp_7*) y 5000 épocas, se puede observar un incremento en la correlación y una disminución en la pérdida, el *MAE* y el *P-value*, tanto que este último deja de ser representativo. Las estadísticas descriptivas mejoran aún más al agregar una capa adicional a la red neuronal, como se puede observar en el modelo *mlp_8*, que conserva las mismas 36 neuronas en la capa de entrada, ahora tres capas ocultas de 100 neuronas y 5000 épocas para su entrenamiento.

Sin embargo, una mejora notable se presenta en el modelo *mlp_9*, que comienza con las 10 variables de evaporación, es decir, con 360 neuronas en la capa de entrada, tres capas intermedias de

300 neuronas y 5000 épocas para su entrenamiento. Este esquema destaca sobre el resto, dado que presenta *loss*, el *MAE* y el *P-value* más bajos, y una correlación cercana al 100 % (0.967).

fit	var de E	shape	h	epochs	loss	MAE	correlation	P-value
<i>mlp_5</i>	1	36	1	100	775.46	21.716	0.131	9.8e-07
<i>mlp_6</i>	1	36	1	5000	408.23	13.610	0.725	5.2e-226
<i>mlp_7</i>	1	36	2	5000	239.03	10.014	0.838	0.0
<i>mlp_8</i>	1	36	3	5000	186.60	7.82	0.869	0.0
<i>mlp_9</i>	10	360	3	5000	47.04	4.08	0.967	0.0
<i>mlp_10</i>	10	360	1	300	106.52	8.01	0.931	0.0

Tabla 4.3.1: Métricas de evaluación para diversos modelos MLP utilizando datos de evaporación como variable de entrada. La tabla incluye el identificador del modelo, el número de variables (var de E), la estructura de la entrada (shape), el número de neuronas en las capas ocultas (h), la cantidad de épocas durante las cuales se entrenó cada modelo, y las métricas de rendimiento incluyendo el error cuadrático medio (loss), el error absoluto medio (MAE), la correlación entre las predicciones y los valores reales, y el p-value asociado a esta correlación. Los modelos se diferencian por la cantidad de épocas y la configuración de las entradas y capas ocultas.

A continuación, en la Figura 4.3.1, se presentan las gráficas de los seis entrenamientos. Como se mencionó anteriormente, derivado de las métricas que evaluaron el rendimiento de los modelos, se puede observar que el entrenamiento *mlp_9* muestra la mejor correlación entre las predicciones y los valores reales.

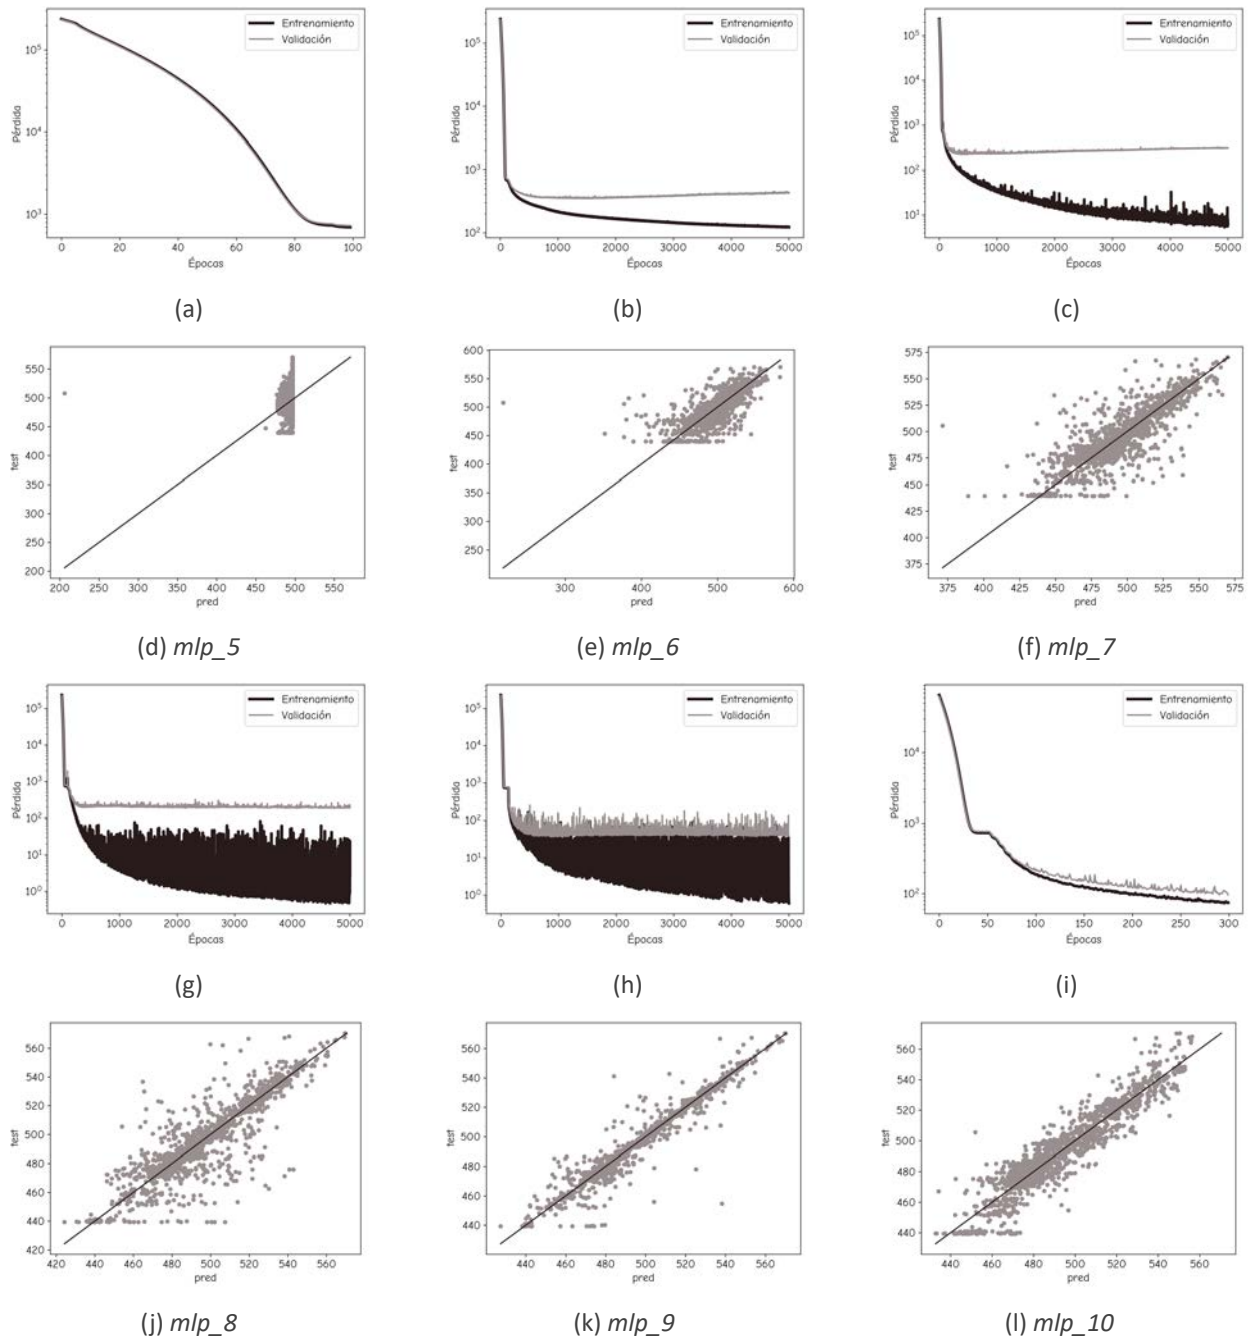


Figura 4.3.1: Evaluación de modelos MLP para la predicción utilizando variables de evaporación. Las subfiguras (a) a (c) y (g) a (i) muestran la función de pérdida a lo largo de las épocas de entrenamiento y validación para diferentes configuraciones de modelos, destacando cómo la pérdida decrece con el aumento de las épocas. Las subfiguras (d) a (f) y (j) a (l) ilustran gráficos de dispersión entre los valores predichos y los valores reales de prueba para cada modelo, indicando la precisión y el ajuste del modelo. Cada gráfico corresponde a una configuración diferente del modelo, desde (*mlp₅*) hasta (*mlp₁₀*), mostrando cómo varían las métricas de desempeño como la correlación y la precisión en función de las distintas configuraciones y profundidades de entrenamiento.

Es importante destacar que, aunque los resultados obtenidos a través de los entrenamientos empleando Redes de Perceptrón Multicapa comienzan a mostrar cifras satisfactorias, dichos entrena-

mientos se limitan a predecir el promedio del almacenamiento de agua subterránea en el área de estudio.

4.4. RFR para obtener las variables predictoras

También se evaluó la importancia de las características mediante el método *feature_importances* de random forest, el cual calcula la media y la desviación estándar del aumento y disminución del *MSE* dentro de cada árbol (sklearnRF, 2023). Los resultados de este análisis se muestran en la Figura 4.4.1. Estos indican que las variables que mejor predicen el GWS son, en primer lugar, *Es* con un 25 %, seguido de *Et* con un 17 % y *E* con un 13 %. Las demás variables se ordenan en importancia descendente de la siguiente manera: *SMroot*, *Ep*, *t_max*, *Ei*, *t_mean*, *Smsurf*, *S*, *Eb*, *precip*, *Ew*, *t_min*.




Figura 4.4.1: Importancia de las variables en la predicción del almacenamiento de agua subterránea utilizando un modelo de Random Forest Regressor (librería *feature_importances*). El gráfico muestra la relevancia asignada a cada variable, donde las barras más largas indican una mayor influencia en la capacidad predictiva del modelo. Variables como *Es*, *Et* y *E* se destacan como las más influyentes, mientras que otras, como *t_min* y *Ew*, tienen una importancia mínima. Esta información es crítica para entender qué factores contribuyen más a las predicciones del modelo.

Utilizando la misma arquitectura del modelo *mlp_9*, pero con la actualización en la selección de variables, las diferencias en las métricas de rendimiento del modelo son notables, como se puede observar en la Tabla 4.4.1. El entrenamiento *mlp_11* resulta ser el más óptimo, presentando las mejores métricas hasta el momento.

fit	var	shape	d	epochs	loss	MAE	correlation	P-value
<i>mlp_9</i>	10	360	3	5000	47.04	4.08	0.967	0.0
<i>mlp_11</i>	5	180	3	5000	12.75	1.48	0.99	0.0

Tabla 4.4.1: Comparación de las métricas de rendimiento entre los modelos *mlp_9*, que incluye las 10 variables de GLEAM y *mlp_11*, que se basa solo en las 5 variables más importantes según el análisis de RFR. Este cuadro resalta cómo la selección y reducción de variables afectan a la precisión del modelo, evidenciado por diferencias significativas en el error cuadrático medio (loss), error absoluto medio (MAE), correlación y el valor-p.

Aunque se obtuvieron resultados similares en los entrenamientos *mlp_9* y *mlp_11*, verificados a través de las gráficas de dispersión presentadas en la Figura 4.4.2 para la estimación del almacenamiento de agua subterránea, finalmente el alcance de estos modelos se limita a predecir el valor promedio en el área de estudio. Por lo que se continúa con el siguiente modelo, el cual permite preservar el componente espacial de las imágenes de entrada y, de la misma forma, obtener como salida una matriz de valores que se pueda transformar en una imagen que cubra el área de interés.




Figura 4.4.2: Comparación de los diagramas de dispersión para las predicciones de los modelos *mlp_9* y *mlp_11*, que muestran los valores predichos (eje x) frente a los valores reales de prueba (eje y). Cada punto representa una observación individual, donde una alineación más cercana a la línea diagonal indica una mayor precisión en la predicción.

4.5. CNN para estimar el GWS

El modelo se entrenó a lo largo de 3000 épocas, y su arquitectura se evaluó tanto para la predicción de un día como para 1382 días. Como se ilustra en la Tabla 4.5.1, se obtuvo una correlación cercana al 99 %, un valor de P de 0.0, una pérdida de 200.886 y un error cuadrático medio de 9.15. Esto también es evidente en la gráfica de pronóstico correspondiente al año 2021, presentada en la Figura 4.5.1, donde se comparan los datos predichos con los reales.

día	var	forma	d	épocas	loss	MAE	correlation	P-value
1	5	36	1	3000	200.88	9.15	0.999	3.054e-52
	3	256						
	1	900						
1382	5	36	1	3000	200.88	9.15	0.993	0.0
	3	256						
	1	900						

Tabla 4.5.1: Resultados del aprendizaje con la arquitectura CNN utilizando variables de Evaporación, Temperatura y Precipitación como entradas (5,3,1, respectivamente). Se muestra la evaluación para configuraciones que varían por número de días considerados (1 día y 1382 días), número de variables (3 y 5), y dimensiones de las entradas (36, 256, y 900). Los resultados incluyen la pérdida (loss), el error medio absoluto (MAE), la correlación entre predicciones y valores reales, y el valor P para probar la significancia estadística de la correlación.




Figura 4.5.1: Resultados del entrenamiento y validación del modelo CNN con tres tipos diferentes de variables de entrada, evaluados a lo largo de diferentes periodos. La gráfica (a) muestra la curva de pérdida (loss) durante el entrenamiento frente al número de épocas; la gráfica (b) ilustra la correlación lineal de las predicciones para un día, destacando la precisión del modelo en un intervalo corto; mientras que la gráfica (c) muestra la dispersión de las predicciones frente a los valores reales durante 1382 días, proporcionando una visión a largo plazo de la consistencia y variabilidad del modelo.

Aunque los resultados del modelo *cnn_1* demuestran su capacidad para incorporar la componente espacial, generando una imagen que representa la estimación del almacenamiento de agua subterránea para un día específico (t) dentro del intervalo temporal estudiado, sus predicciones están limitadas únicamente a este período. Es decir, el modelo no puede extrapolar sus estimaciones más allá de la ventana temporal analizada. Por este motivo, se propone la siguiente arquitectura LSTM, que aprovecha la componente temporal de los datos y permite realizar predicciones fuera del intervalo temporal original.

4.6. LSTM para estimar el GWS

Las métricas de evaluación de los modelos se detallan en la Tabla 4.6.1. La selección de los pasos de aprendizaje se identificó como una restricción crítica durante los entrenamientos. Se descubrió que incrementar los pasos de aprendizaje más allá de 60 impedía la finalización de los entrenamientos. De manera similar, el aumento del número de épocas más allá de 300 resultaba en un aumento en

las métricas de *loss* y *MAE*, indicando posibles complicaciones como el sobreajuste o ineficiencias en la convergencia del modelo.

<i>fit</i>	<i>var</i>	<i>shape</i>	<i>d</i>	<i>epochs</i>	<i>loss</i>	<i>MAE</i>	<i>correlation</i>	<i>P-value</i>
<i>lstm_1</i>	5	100	1	100	2113.51	44.18	0.6227	5.64e-148
<i>lstm_2</i>	1	100	1	100	8235.74	76.84	0.99	3.79e-36
<i>lstm_3</i>	1	100	1	300	3669.32	48.86	0.99	3.68e-40

Tabla 4.6.1: Resultados de los entrenamientos usando arquitectura LSTM para tres configuraciones diferentes. Cada fila corresponde a un modelo distinto identificado como *fit*, donde *var* representa el número de variables de entrada, *shape* la cantidad de datos en cada secuencia, *d* la dimensionalidad de la salida, *epochs* el número de épocas de entrenamiento, *loss* y *MAE* que indican el error medio y el error absoluto medio respectivamente, *correlation* la correlación entre las predicciones y los valores reales, y *P-value* la significancia estadística de la correlación.

Las gráficas de dispersión y de entrenamiento de los modelos *LSTM* se presentan a continuación en la Figura 4.6.1. En la primera fila se muestra la evolución de la función de pérdida (*loss*) durante el entrenamiento del modelo. El eje Y representa el valor de la pérdida, mientras que el eje X indica el número de épocas (*epochs*) de entrenamiento. Al inicio del entrenamiento (época 0), en las tres gráficas se observa que las líneas comienzan con un valor de pérdida elevado (aproximadamente 250,000). En las primeras épocas, la pérdida disminuye drásticamente tanto para el conjunto de entrenamiento como para el de validación, lo cual sugiere que el modelo está aprendiendo rápidamente en las etapas iniciales del entrenamiento. Posteriormente, ambas líneas se estabilizan en valores bajos y permanecen constantes durante el resto de las épocas, indicando que el modelo ha alcanzado un punto de equilibrio en el cual no se observa una mejora significativa en su rendimiento.

En la segunda fila, las gráficas de dispersión ilustran que los puntos están bastante dispersos alrededor de la línea de identidad. Esto sugiere que las predicciones no son muy precisas, ya que existe una considerable variabilidad y la mayoría de los puntos no se encuentran cerca de la línea de identidad. Esta dispersión indica que las predicciones del modelo presentan un error significativo.

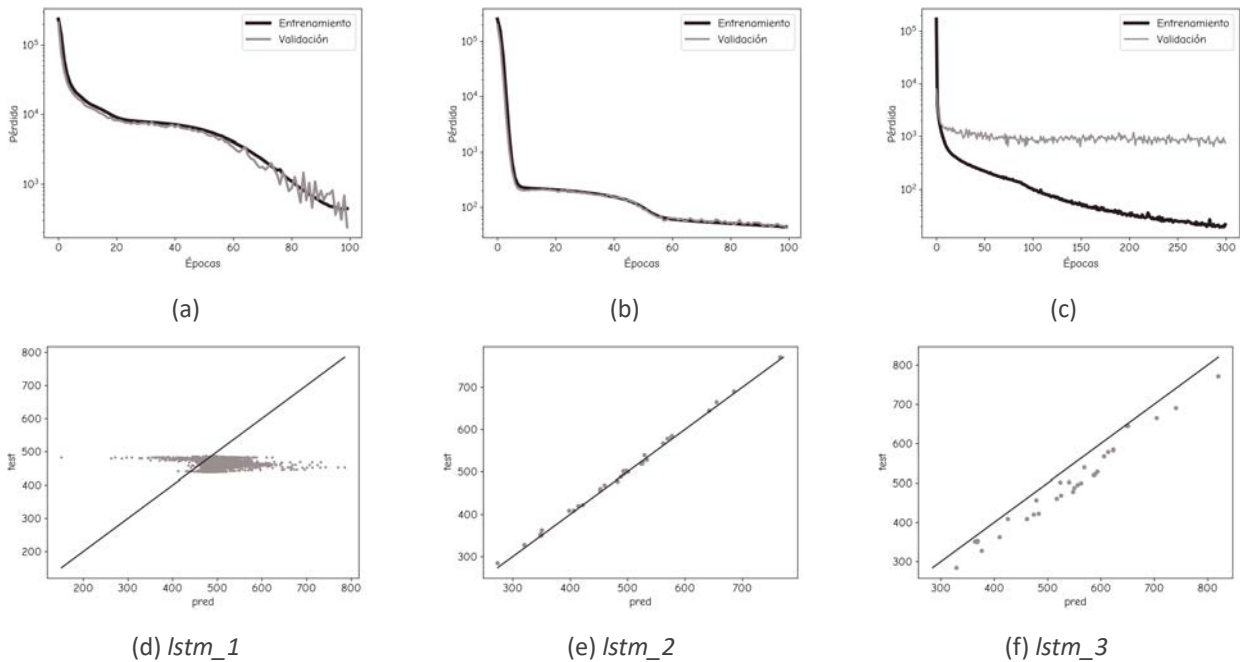


Figura 4.6.1: Entrenamiento y correlación de las arquitecturas LSTM. Las gráficas (a), (b), y (c) muestran la función de pérdida durante el entrenamiento y validación para cada modelo LSTM, demostrando cómo se reduce la pérdida a lo largo de las épocas. Las gráficas (d), (e), y (f) exhiben la relación de dispersión entre los valores predichos por los modelos y los valores reales de los datos de prueba, reflejando la precisión y el ajuste de cada modelo.

Las arquitecturas LSTM están diseñadas específicamente para capturar las dependencias temporales en los datos, lo que las hace ideales para realizar predicciones más allá de la ventana temporal de estudio. En este caso, las LSTM pueden predecir valores del GWS para 1 día, 1 semana o incluso 31 días, como se realizó en esta investigación. Sin embargo, estas predicciones se limitan a un único valor agregado, perdiendo la resolución espacial que es clave para representar las estimaciones de GWS en forma de imágenes.

A diferencia de las CNN, que generan como salida una matriz de valores que puede transformarse en una imagen con los valores estimados de GWS para cada píxel, las LSTM no están diseñadas para este propósito. Por lo tanto, aunque permiten extender las predicciones temporalmente, no ofrecen la resolución espacial necesaria para el análisis geográfico (Graves y cols., 2013).

Esta limitación resalta la necesidad de un modelo híbrido como el CRNN, que combina la capacidad de las LSTM para capturar dependencias temporales con la habilidad de las CNN para generar salidas espaciales. Este próximo modelo permitirá realizar predicciones de GWS con resolución espacial, ofreciendo una estimación más completa y geográficamente representativa.

4.7. CRNN para estimar el GWS

En la Tabla 4.7.1 se describen las métricas obtenidas para los dos modelos CRNN. Ambos exhiben una correlación cercana al 1 y un *P-value* de cero. La distinción principal radica en los valores de pérdida (*loss*) y error absoluto medio (*MAE*) observados durante el entrenamiento. Aunque a pri-


mera vista estas métricas puedan parecer elevadas, el análisis de la función de pérdida (ver Figura 4.7.1) indica un comportamiento adecuado de los modelos, sin evidencia de sobreajuste. La pérdida muestra una alta magnitud inicialmente, pero decrece rápidamente y se estabiliza en valores bajos tanto para el conjunto de entrenamiento como para el de validación.

fit	step	epochs	loss	MAE	correlation	P-value
asíncrono	30	300	3542.21	46.30	0.9982	0.0
síncrono	31	300	261.70	10.65	0.9982	0.0


Tabla 4.7.1: Resultados de entrenamiento para modelos CRNN asincrónicos y sincrónicos. La tabla compara los dos modelos en términos de pasos temporales (30 y 31), número de épocas de entrenamiento (300), pérdida (loss), error absoluto medio (MAE), correlación entre las predicciones y valores reales, y el p-value asociado a la correlación. Todos los modelos fueron evaluados con la misma dimensionalidad de entrada, 36.

Es importante tener en cuenta que tanto el *MAE* como la función de *loss* en los modelos LSTM están relacionados con un período de tiempo específico, el cual está segmentado en bloques de 30 y 31 días. Cada uno de estos días contiene 36 puntos de resolución por imagen. Esto significa que las métricas no solo se calculan sobre un solo día o una única muestra, sino que abarcan la totalidad de los puntos de resolución en cada imagen para el conjunto del período.

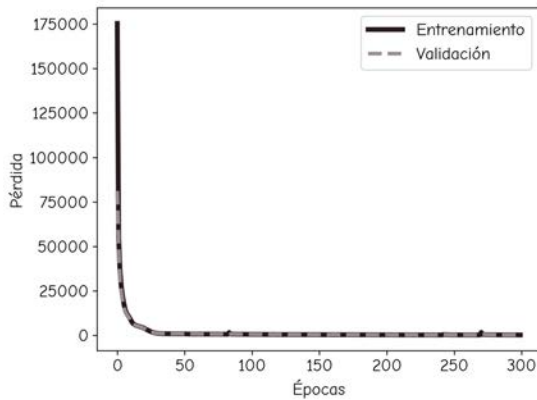
Por lo tanto, el cálculo del *MAE* y *loss* se extiende a 1080 puntos en el caso del modelo asíncrono (correspondiente a [30 días × 36 puntos de resolución]), y a 1116 puntos para el modelo síncrono (correspondiente a [31 días × 36 puntos de resolución]). Esta diferencia en los puntos de resolución entre los dos modelos se debe a la variación en la duración de los bloques temporales empleados para el entrenamiento y la validación de cada arquitectura.




(a)



(b)



(c) CRNN Asíncrono



(d) CRNN Sincrónico

Figura 4.7.1: Gráficas de la función de pérdida durante el entrenamiento y la validación para modelos CRNN asincrónicos y sincrónicos. Las gráficas (a) y (c) corresponden al entrenamiento y validación del modelo asincrónico, mientras que las gráficas (b) y (d) presentan los resultados para el modelo sincrónico. Estas visualizaciones destacan las diferencias en el comportamiento de la convergencia entre ambos enfoques a lo largo de 300 épocas.

Una evidencia significativa de la capacidad estimativa y predictiva de la arquitectura CRNN para el GWS se refleja en las gráficas que comparan la serie temporal de prueba contra los valores predichos o estimados. En la Figura 4.7.3, se presentan los resultados de la evaluación. La primera gráfica ilustra la comparación para un periodo de 250 días entre las series *Test* y *Pred*. La línea continua representa los valores reales del GWS obtenidos de los datos de prueba (*Test*), mientras que la línea punteada representa las predicciones del modelo (*Pred*). La similitud entre ambas líneas a lo largo del tiempo indica que el modelo captura de manera efectiva las fluctuaciones temporales en el almacenamiento de agua subterránea. Adjunto a esta, se encuentra la gráfica de correlación que engloba el mes predicho, es decir, los 30 días \times 36 valores pronosticados por el modelo.

En la segunda columna, se muestra el rendimiento del modelo CRNN sincrónico. Dado que el número de variables de entrada es igual al de salida, se exhiben gráficas de correlación tanto para un día como para el periodo completo de prueba, que comprende 1449 días. Además, en la gráfica que compara las series estimadas contra las reales, se presenta un periodo de 1000 días. Es im-

portante aclarar que se utilizan los valores medios del área; la inclusión de los 36 valores por día resultaba en una visualización menos clara de la similitud entre ambas líneas.

Entrenamiento asíncrono 30 pasos




Figura 4.7.2: Resultados del entrenamiento asíncrono para el modelo CRNN. (a) Correlación de los valores predichos frente a los valores reales para un período de prueba de 30 días, cada día con 36 valores de GWS. (b) Dispersión completa de las predicciones frente a los valores reales para el período completo de prueba. Debajo (c), se muestra la serie temporal de los valores de GWS reales y predichos, destacando la capacidad del modelo para seguir las fluctuaciones temporales en los datos.

Entrenamiento síncrono, 31 pasos

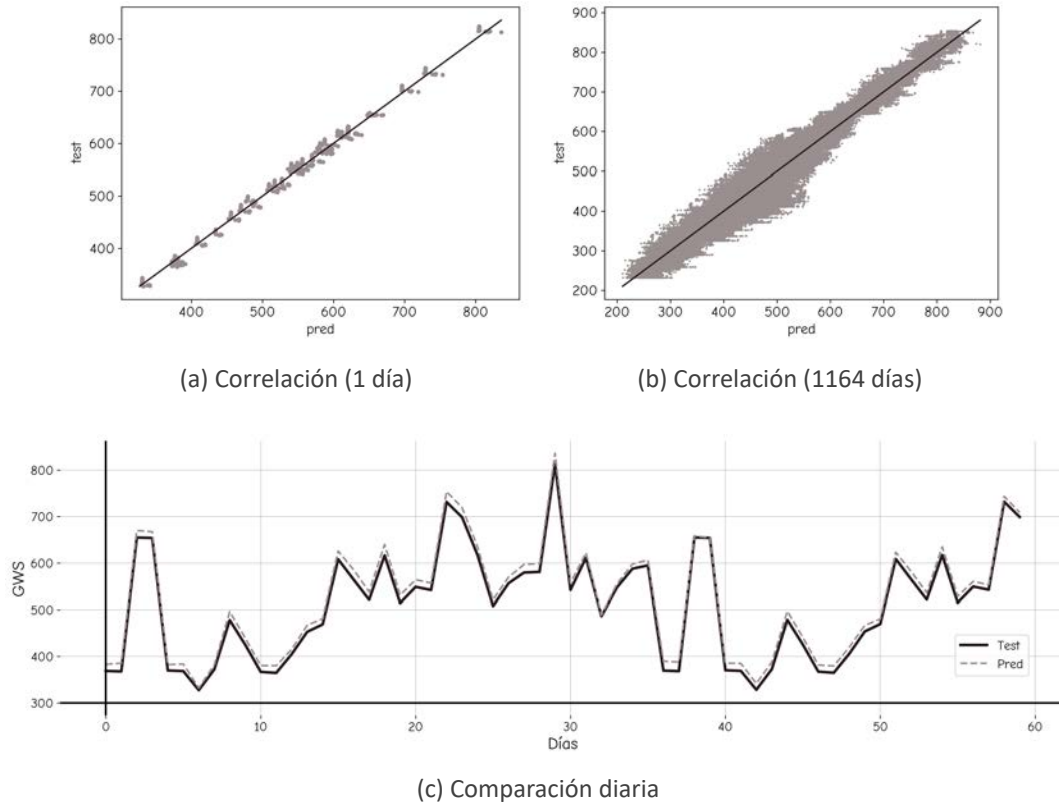


Figura 4.7.3: Resultados del entrenamiento síncrono para el modelo CRNN a 31 pasos. (a) Gráfica de correlación entre los valores predichos y los valores reales para un período de prueba de 31 días, mostrando una alta precisión en la predicción diaria. (b) Dispersión de todas las predicciones frente a los valores reales durante el período completo de prueba, destacando la densidad de puntos alrededor de la línea de perfecta correlación. La gráfica inferior muestra la serie temporal de los valores de GWS reales y predichos, ilustrando la capacidad del modelo para capturar las tendencias y variaciones diarias.

4.8. Análisis de los resultados

Todos los modelos analizados en este estudio operaron sobre el mismo período de tiempo y se aplicaron a la misma área geográfica. Durante la fase de preparación de datos, se empleó una rutina estándar para reservar un porcentaje idéntico de datos para pruebas en cada modelo, asegurando así una base comparativa uniforme. Antes de su aplicación en los modelos, los datos fueron normalizados consistentemente.

Los resultados que se detallan a continuación representan los más significativos, destacando cómo cada modelo logró aproximarse a los valores reales minimizando los errores. En esta sección, se explora más a fondo las razones detrás de estos resultados, particularmente en términos del impacto del tamaño de la muestra en el desempeño del modelo. Aunque se utilizó el mismo porcentaje de datos para todas las pruebas, la naturaleza de los datos de entrada varió según la arquitectura específica del modelo. Por ejemplo, mientras que los modelos iniciales utilizaban promedios de datos de almacenamiento de agua subterránea, las arquitecturas como las CNN aprovecharon imágenes en su formato original sin la necesidad de convertirlas en una secuencia lineal de valores.

Las arquitecturas evaluadas incluyen tanto modelos **asíncronos** como **síncronos**. Por un lado, las arquitecturas asíncronas (LSTM y CRNN) hacen predicciones a distintos intervalos de tiempo (un día y 30 días), permitiendo observar cómo las predicciones varían a lo largo del tiempo. Por otro lado, los modelos síncronos, como el MLP y el CNN, realizan predicciones simultáneas respecto al tiempo de las variables de entrada.

Es importante destacar que los modelos MLP y LSTM generaron resultados promedios del almacenamiento de agua subterránea, lo cual implica una pérdida de la resolución espacial. En contraste, las arquitecturas CNN y CRNN sí permiten preservar la resolución espacial, generando una imagen con los 36 puntos de resolución correspondientes a cada píxel, proporcionando una visualización espacial del recurso hídrico.

En la Tabla 4.8.1 se sintetizan los resultados de los modelos probados, con una estructura de nueve columnas. La primera columna contiene la clave asignada a cada modelo, utilizando la misma nomenclatura presentada en capítulos anteriores. En la columna **var**, se muestra el número de variables de entrada que utiliza cada modelo; por ejemplo, el modelo *mlp_9* emplea 10 variables de evaporación, mientras que modelos como *mlp_11*, *crnn_31p* y *crnn_30p* se limitan a utilizar las 5 variables seleccionadas por el algoritmo de bosques aleatorios. LSTM, por su parte, utiliza una única variable de entrada. El modelo *cnn_1*, por otro lado, es el único que combina múltiples variables: 5 de evaporación, 3 de temperatura y 1 de precipitación.

La columna **forma** indica cómo se estructuraron los datos de entrada para cada arquitectura, considerando el total de puntos de las imágenes. Así, para evaporación se consideraron los 36 puntos de resolución, 256 para temperatura y 900 para precipitación. Posteriormente, se detalla el número de capas ocultas de cada modelo en la columna **h**, seguido del número de **épocas**. Finalmente, se presentan las métricas clave de evaluación: el *loss*, *MAE*, la correlación y el *P-value*, que proporcionan una evaluación cuantitativa del rendimiento de cada arquitectura.

modelo	var	forma	h	épocas	loss	MAE	correlación	P-value
<i>mlp_9</i>	10	360	3	5000	47.04	4.08	96.7 %	0.0
<i>mlp_11</i>	5	180	3	5000	12.75	1.48	99 %	0.0
<i>cnn_1</i>	[5,3,1]	[36,256,900]	1	3000	200.88	9.15	99.9 %	3.054e-52
<i>lstm_3</i>	1	[1, 36]	1	300	3669.32	48.86	99 %	3.68e-40
<i>crnn_síncrono</i>	5	[31,6,6,5]	6	300	261.70	10.65	99.82 %	0.0
<i>crnn_asíncrono</i>	5	[30,6,6,5]	6	300	3542.21	46.30	99.82 %	0.0

Tabla 4.8.1: Comparación de métricas de desempeño para los modelos de aprendizaje automático aplicados en esta investigación para la predicción de GWS. La tabla presenta el número de variables *var*, la estructura de entrada *forma*, la cantidad de épocas *épocas*, junto con las métricas de evaluación: pérdida *loss*, error absoluto medio *MAE*, correlación y el *valor-p*. Los modelos incluyen MLP, CNN, y LSTM, tanto en configuraciones sincrónicas como asíncronas de la arquitectura CRNN, destacando sus eficacias relativas en términos de precisión y error.

Se decidió probar dos modelos con la arquitectura del Perceptrón Multicapa. El primero, iden-

tificado como *mlp_9*, fue inicialmente un ejercicio experimental que arrojó resultados óptimos, alcanzando una correlación del 96 % entre las predicciones y los datos de prueba. Este alto grado de correlación sugirió que las variables de evaporación tenían un papel crucial en la predicción del almacenamiento de agua subterránea, lo cual fue un indicativo de que se estaba avanzando en la dirección correcta. Sin embargo, aunque estas pruebas iniciales fueron útiles para comprender los requisitos estructurales de una red neuronal básica, el proceso de probar cada variable de manera individual resultó ser un enfoque demasiado extenso y poco eficiente en cuanto al tiempo.

Para mejorar la eficiencia y determinar de manera más precisa qué variables eran las más predictivas, se recurrió al algoritmo de *Random Forest Regression*, conocido por su eficacia en la identificación de variables predictivas en conjuntos de datos grandes y complejos, incluidas series temporales (Breiman, 2001a). Este análisis reveló que las variables más influyentes fueron *SMroot*, *Et*, *Eb*, *Smsurf* y *Ew*. Al incorporar estas cinco variables en el modelo MLP, los resultados mejoraron significativamente: la correlación aumentó del 96 % al 99 %, mientras que tanto el *loss* como el *MAE* disminuyeron de 47 a 12 y de 4 a 1.48, respectivamente, en una muestra de 1455 registros.

Con base en estos resultados, se consolidó un modelo básico de *MLP* utilizando un conjunto más reducido de variables, las cuales fueron seleccionadas por el algoritmo RF. Este modelo confirmó la importancia de las variables de evaporación sugeridas por RF, como se muestra en la Figura 4.8.1, la cual ilustra la correlación entre los valores predichos y los valores reales obtenidos del modelo *mlp_11*.




Figura 4.8.1: Gráfica de comparación entre los valores de GWS reales y los predichos por el modelo MLP utilizando cinco variables de evaporación seleccionadas a través de análisis de importancia de características con RFR. La gráfica muestra un periodo de tres meses y destaca la precisión del modelo en seguir las fluctuaciones de los datos reales.

Aunque técnicamente es posible utilizar el Perceptrón Multicapa con cualquier tipo de dato, siempre que este sea transformado en un vector unidimensional (Bishop, 2006), es esencial considerar que este enfoque no aprovecha las dependencias espaciales o temporales intrínsecas en los datos. Por esta razón, se exploró la arquitectura de Redes Neuronales Convolucionales, que demostró una excelente capacidad de estimación, evidenciada por una correlación cercana al 100 % y un error absoluto medio de 9.15, con una pérdida de 200 en una muestra de $[1455 \times 36]$ (Figura 4.8.2).




Figura 4.8.2: Gráfica de los resultados de correlación entre los valores de GWS reales y predichos utilizando una arquitectura CNN sincronizada. La predicción utiliza tres variables climáticas: evaporación, temperatura y precipitación. Esta muestra aleatoria destaca la eficacia del modelo en capturar las tendencias y fluctuaciones de los niveles de GWS.

La estimación del Almacenamiento de Agua Subterránea con CNN, basada en variables climáticas, demostró ser altamente efectiva. Sin embargo, el objetivo principal de esta investigación es desarrollar predicciones futuras, razón por la cual se optó por implementar arquitecturas LSTM, reconocidas por su eficacia en tareas de predicción para series temporales (Goodfellow y cols., 2016). Aunque los indicadores iniciales de rendimiento del modelo LSTM, como la pérdida (*loss*), el error absoluto medio (*MAE*) y la correlación, mostraron valores óptimos de 110.25, 7.48 y 97 % respectivamente, se observaron limitaciones al intentar incrementar el horizonte de predicción. Específicamente, a medida que se extendía el número de días de predicción, aumentaba la complejidad del aprendizaje, lo cual deterioraba el rendimiento del modelo. Las Figuras 4.8.3 y 4.8.4 ilustran las diferencias en las gráficas de correlación para las predicciones a uno y a 31 días, respectivamente, destacando los desafíos asociados con la extensión del horizonte de predicción. Notablemente, las predicciones se mantuvieron consistentemente por debajo de los 400 mm, lo cual podría indicar una limitación en la capacidad del modelo para capturar eventos de alta intensidad o la variabilidad en las diferencias de magnitudes entre las variables de entrada y de GWS.




Figura 4.8.3: Gráfica de comparación de la correlación diaria de GWS utilizando una arquitectura LSTM que predice con base en una única variable de evaporación. Aunque las predicciones no coinciden perfectamente con los datos reales, el modelo logra seguir la tendencia general del GWS, destacando su capacidad para capturar la dinámica temporal del sistema.




Figura 4.8.4: Gráfica de correlación de la arquitectura LSTM para 31 días de predicción de GWS, mostrando datos cada 36 valores diarios. Esta visualización resalta la capacidad del modelo para seguir las variaciones diarias del GWS durante un mes. Se nota una diferencia consistente de aproximadamente 100mm entre las predicciones y los valores reales, lo que sugiere que el modelo podría no estar capturando adecuadamente la variabilidad espacial de los datos.

Finalmente, se desarrolló un modelo que reúne las características para analizar series temporales de imágenes satelitales: las Redes Neuronales Convolucionales Recurrentes. Las CNN permiten capturar los cambios o características espaciales en cada fotograma de la serie temporal, mientras que las LSTM, adecuadas para manejar estos datos secuenciales, capturan dependencias temporales a largo plazo.

La integración de estas dos arquitecturas permitió lograr predicciones a 30 días con una correlación de casi el 100 %, lo que indica una relación extremadamente fuerte y positiva entre las variables dependientes y el almacenamiento de agua subterránea. Los cambios en las variables de evaporación están altamente correlacionados con los cambios en el GWS. A pesar de que el Error Absoluto Medio fue de 49 y se observó una pérdida relativamente alta de 3542.21 en comparación con otros modelos (ver Figura 4.8.5), esta pérdida no es significativa considerando lo siguiente:




Figura 4.8.5: Comparativa de las métricas de rendimiento, específicamente el error absoluto medio (MAE) y la pérdida (loss), de los diferentes modelos incluyendo MLP, LSTM, CNN y CRNN. Estas gráficas muestran cómo cada modelo maneja los errores en la predicción del almacenamiento de agua subterránea. Los picos en la gráfica de pérdida indican modelos con mayores dificultades en la precisión de las estimaciones, mientras que los valores más bajos en la gráfica de MAE sugieren una mayor exactitud en las predicciones.

El conjunto de datos del satélite GRACE consta de 261,864 registros (Figura 4.8.6), cada uno correspondiente a uno de los 36 puntos por imagen distribuidos a lo largo de las 7,274 imágenes

disponibles para el periodo de estudio. Recordemos que las métricas de pérdida y error absoluto medio (*loss* y *MAE*), presentadas anteriormente en la Tabla 4.8.1, derivan de evaluar el modelo con el conjunto de prueba, es decir, del 20 % del conjunto total.




Figura 4.8.6: Estadísticas descriptivas de los datos de GWS correspondientes a cada píxel de las imágenes utilizadas en esta investigación. Este análisis incluye la media, desviación estándar, mínimos, máximos y percentiles para proporcionar una comprensión detallada de la distribución de los valores de GWS y su variabilidad, facilitando así la interpretación de errores y comparaciones con las muestras obtenidas.

La longitud del conjunto de prueba varía en función de la arquitectura de red neuronal utilizada, como se muestra en la Tabla 4.8.2. El modelo de *MLP* tiene el menor número de muestras (1455), debido a que utiliza únicamente el valor promedio del *GWS* de los 36 disponibles por día. Por otro lado, en las arquitecturas de *CNN* y *LSTM*, la longitud de los datos se mantiene en $[1455 \times 36]$, reflejando que estos datos no han sido manipulados. Sin embargo, para la arquitectura de *CRNN*, la longitud de los datos alcanza un total de 1,558,440, ya que el bloque de evaluación comprende $[1443 \text{ grupos de } \times 30 \text{ días de predicción } \times 36 \text{ puntos de resolución}]$.

Modelo	Datos de entrenamiento	Valores de salida	Resultados
MPL 5	1455	1	Promedio de la imagen
CNN	52380	36	1 imagen de $[6 \times 6]$
LSTM	52380	36	1 imagen después de $[6 \times 6]$
CRNN 30p	1558440	1080	30 imágenes después de $[6 \times 6]$

Tabla 4.8.2: Comparación de los modelos utilizados en términos de cantidad de datos de entrenamiento, valores de salida y el tipo de resultados generados. MPL 5 genera un valor único representando el promedio de la imagen, mientras que CNN y LSTM producen 36 valores correspondientes a una imagen de $[6 \times 6]$. CRNN 30p, aunque muestra valores altos de pérdida y error absoluto medio (MAE), procesa una cantidad significativamente mayor de datos, con 1080 valores distribuidos en 30 imágenes de $[6 \times 6]$, lo que puede explicar la dispersión de errores observada.

Como se destacó anteriormente, la pérdida es casi insignificante dentro del rango de las muestras seleccionadas para evaluar los modelos. La gráfica de barras en la Figura 4.8.7 ilustra el error normalizado por muestra, es decir, la pérdida que podría experimentar un píxel en los modelos *CNN*, *LSTM* y *CRNN_30p*. En este contexto, considerando que un píxel oscila entre un máximo de 853.99

mm y un mínimo de 231.84 mm de GWS (véase estadísticas de GWS en la Figura 4.8.6), una pérdida media de 4.244×10^3 mm representa menos del 0.002 % del almacenamiento total de agua subterránea en un píxel de $25^\circ \times 25^\circ$. Por esta razón, las líneas negra y gris, que representan la pérdida máxima y mínima respectivamente en estos modelos, se posicionan prácticamente en el origen de la gráfica de caja.




Figura 4.8.7: Distribución de la pérdida de los modelos MLP_5, CNN, LSTM y CRNN_30p. A la izquierda, la pérdida normalizada por el número de muestra. A la derecha, un boxplot detalla la variabilidad de la pérdida entre los diferentes conjuntos de muestras, con referencias a valores mínimos y máximos, mediana y los cuartiles.

Es importante destacar que, aunque el error en el modelo *MLP* es uno de los más elevados, la razón es que su función de pérdida se distribuye en un área mayor, y que los datos de este modelo están promediados sobre dicha área. Esta es la razón por la cual su caja en la gráfica es más pequeña y está centrada en un rango más estrecho (entre 400 mm y 600 mm), lo que sugiere que las pérdidas están más concentradas y presentan menor variabilidad. En contraste, las cajas correspondientes a los modelos *CNN*, *LSTM* y *CRNN_30p* son más altas y abarcan un rango más amplio de pérdidas, dado que estos modelos trabajan con datos puntuales, es decir, para cada píxel individual. Esto explica por qué muestran una mayor dispersión en las pérdidas.

En general, los modelos analizados demostraron un rendimiento sobresaliente dentro de sus respectivas limitaciones. El algoritmo *Random Forest* fue especialmente útil para guiar la investigación hacia la dirección óptima. Los modelos de *Perceptrón Multicapa* mostraron eficacia en la estimación del promedio del Almacenamiento de Agua Subterránea, mientras que las *Redes Neuronales Convolucionales* sobresalieron en las estimaciones para toda el área de estudio, notablemente sin requerir un preprocesamiento adicional para homologar resoluciones. Las *Redes LSTM* demostraron capacidad para estimar el GWS con un día de anticipación, alcanzando métricas prometedoras incluso cuando se emplearon de manera independiente.

Finalmente, las *Redes Neuronales Convolucionales Recurrentes* no solo cumplieron, sino que superaron las expectativas iniciales de esta investigación al aprovechar tanto las características espaciales como temporales de los datos para predecir los cambios en el GWS a 30 días.

Esta precisión se puede apreciar en la gráfica de correlación de la Figura 4.8.8, donde el modelo

CRNN muestra un ajuste notable a los valores reales. Las líneas de predicción (línea punteada) y los datos de prueba (línea continua) siguen patrones muy similares a lo largo del tiempo, con pequeñas desviaciones que indican la capacidad del modelo para capturar la dinámica temporal de los datos. La cercanía entre las dos líneas a lo largo de casi todo el período sugiere que el modelo CRNN es altamente preciso y capaz de seguir las fluctuaciones del GWS de manera efectiva.

El modelo también predice con éxito los picos y valles en los datos de GWS, lo que es crucial para aplicaciones prácticas. La capacidad de anticipar eventos extremos, como cambios bruscos que se demuestran complejos y no lineales en el GWS, convierte a este modelo en una herramienta valiosa para la gestión y predicción de recursos hídricos.




Figura 4.8.8: Comparación entre los valores reales del almacenamiento de agua subterránea y las predicciones del modelo CRNN a lo largo de 30 días. Esta gráfica destaca la precisión del modelo, que logra una correlación cercana al 100% en la predicción de 30 días consecutivos, evidenciando su capacidad para capturar las dinámicas temporales del GWS con gran exactitud.

5 Conclusiones

Inicialmente, esta investigación podría haber comenzado con una Red Neuronal Convolutiva, dado que es idónea para el manejo de imágenes (LeCun y cols., 1998; Krizhevsky y cols., 2012; Simonyan y Zisserman, 2014). Sin embargo, se optó por explorar un enfoque más simple, guiado por el principio de la navaja de Ockham en el aprendizaje automático, que sugiere la preferencia por la hipótesis más sencilla cuando dos alternativas explican igual de bien un fenómeno (Webb, 2010; Good, 1977) (*Entities are not to be multiplied beyond necessity*).

La arquitectura MLP, aunque fue la más sencilla de programar, resultó en un proceso de prueba y error, valioso para comprender mejor la estructura de los datos. Con retrospectiva, considero que hubiera sido más eficiente implementar primero el modelo de Bosques Aleatorios antes de explorar las redes neuronales, ya que este algoritmo habría permitido identificar rápidamente las variables más relevantes. No obstante, esta exploración fue útil como ejercicio práctico para comprender las interacciones entre las variables.

Se observó que la red CNN fue capaz de predecir de manera efectiva el almacenamiento de agua subterránea utilizando como entradas variables climáticas como la temperatura, evaporación y precipitación. Esta capacidad para inferir el GWS, utilizando variables indirectas como las climáticas, subraya la fuerte correlación entre las diferentes componentes del ciclo hidrológico. Estos resultados coinciden con lo señalado en la literatura, que destaca la relevancia de estas variables para estimar, predecir y monitorear el cambio en el almacenamiento de agua subterránea, tanto en modelos basados en datos como en modelos físicos. Además, el hecho de que los valores de entrada provengan de diferentes satélites, y aun así el modelo logró predecir con precisión el GWS, demuestra la robustez de estas variables.

Esta investigación ha demostrado con sus arquitecturas de IA, que la procedencia heterogénea de las variables utilizadas no es una limitante. Al contrario, si los datos son consistentes en cuanto a su origen y resolución, la red puede aprender patrones importantes y evitar errores recurrentes que se suelen encontrar en capturas de campo, que están más expuestas a la variabilidad humana.

Finalmente, si bien la CNN ha demostrado ser una herramienta eficaz, la arquitectura CRNN se destacó al predecir 30 días de datos con 36 valores de resolución por día, obteniendo una correlación cercana al 100 %. Estos resultados subrayan no solo el potencial de las CRNN para capturar de manera simultánea tanto patrones espaciales como temporales, sino también su capacidad para predecir el GWS con gran precisión a largo plazo. En este sentido, los modelos CRNN representan una alternativa prometedora para el monitoreo continuo del agua subterránea, constituyendo una mejora significativa respecto a las arquitecturas previamente probadas. Los resultados obtenidos

confirman que las CRNN no solo facilitan una mejor comprensión del comportamiento de las variables en escenarios complejos, sino que también resultan altamente eficaces para estimar el GWS en entornos donde no es posible capturar todas las variables y sus variantes.

5.1. Trabajos futuros

El uso de datos de percepción remota, combinado con técnicas avanzadas de Inteligencia Artificial, se ha consolidado como un recurso invaluable para investigadores y administradores de recursos hídricos, especialmente en contextos donde el trabajo de campo resulta costoso e inaccesible. En el caso de México, donde los estudios sobre agua subterránea suelen estar limitados debido a los altos costos asociados, sería interesante evaluar el costo-beneficio de integrar más información derivada de la percepción remota. Esta integración permitiría construir una base de datos más sólida que apoye la caracterización de áreas con problemas e identificación de zonas con potencial hídrico. Permitiendo una gestión más proactiva e informada frente a la creciente variabilidad climática, contribuyendo así a la sostenibilidad de los recursos hídricos.

Por otro lado, futuros estudios podrían beneficiarse al incluir datos históricos sobre los niveles de contaminantes originados por actividades humanas, como la salinidad del suelo provocada por la irrigación intensiva. Además, sería relevante considerar censos de crecimiento poblacional, agropecuario y ganadero. La integración de datos sobre el hundimiento del terreno, obtenidos mediante técnicas de interferometría, podría proporcionar una visión más integral. Estos datos son clave para correlacionar cambios en los niveles y el almacenamiento de agua subterránea con impactos sociales y ambientales.

Otro enfoque prioritario es la ampliación de la escala espacial de los datos, más que en extender la ventana de predicción. Una investigación que busque correlacionar variables con datos de mayor resolución podría ser clave para lograr este objetivo. En esta investigación ya se observó que la estructura más precisa de los patrones de evaporación predice con mayor exactitud el GWS mediante el uso de redes neuronales convolucionales. Por lo tanto, teóricamente, bastaría con predecir la evaporación en un período más largo para estimar el GWS con mayor eficacia.

Finalmente, incorporar estos enfoques no solo profundizaría el conocimiento hidrológico, sino que fortalecería las estrategias de gestión y sostenibilidad de los recursos hídricos subterráneos a nivel nacional.

Referencias

- Acuna, A. P. (2023). *Información satelital del agua subterránea: Herramienta clave para sustentabilidad ambiental*. PERSPECTIVAS IMTA. Descargado de <https://www.imta.gob.mx/gobmx/DOI/perspectivas/2023/b-imta-perspectivas-2023-08.pdf> doi: doi.org/10.24850/b-imta-perspectivas-2023-08
- Afzaal, H., Farooque, A. A., Abbas, F., Acharya, B., y Esau, T. (2020). Groundwater estimation from major physical hydrology components using artificial neural networks and deep learning. *Water*, 12(1). Descargado de <https://www.mdpi.com/2073-4441/12/1/5> doi: 10.3390/w12010005
- Ahmed, M., Sultan, M., Elbayoumi, T., y Tissot, P. (2019). Forecasting grace data over the african watersheds using artificial neural networks. *Remote Sensing*, 11(15). Descargado de <https://www.mdpi.com/2072-4292/11/15/1769> doi: 10.3390/rs11151769
- Ahmed, M., Sultan, M., Wahr, J., Yan, E., Milewski, A., Sauck, W., ... Welton, B. (2011, 04). Integration of grace (gravity recovery and climate experiment) data with traditional data sets for a better understanding of the time-dependent water partitioning in african watersheds. *Geology*, 39, 479-482. doi: 10.1130/G31812.1
- Ahmed Ouameur, M., Caza-Szoka, M., y Massicotte, D. (2020). Machine learning enabled tools and methods for indoor localization using low power wireless network. *Internet of Things*, 12, 100300. Descargado de <https://www.sciencedirect.com/science/article/pii/S2542660520301323> doi: <https://doi.org/10.1016/j.iot.2020.100300>
- Algren, M., Fisher, W., y Landis, A. E. (2021). Chapter 8 - machine learning in life cycle assessment. En J. Dunn y P. Balaprakash (Eds.), *Data science applied to sustainability analysis* (p. 167-190). Elsevier. Descargado de <https://www.sciencedirect.com/science/article/pii/B9780128179765000097> doi: <https://doi.org/10.1016/B978-0-12-817976-5.00009-7>
- Ali, S., Liu, D., Fu, Q., Cheema, M. J. M., Pham, Q. B., Rahaman, M. M., ... Anh, D. T. (2021). Improving the resolution of grace data for spatio-temporal groundwater storage assessment. *Remote Sensing*, 13(17). Descargado de <https://www.mdpi.com/2072-4292/13/17/3513> doi: 10.3390/rs13173513
- Alsdorf, D. E., Rodríguez, E., y Lettenmaier, D. P. (2007). Measuring surface water from space. *Reviews of Geophysics*, 45(2). Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2006RG000197> doi: <https://doi.org/10.1029/2006RG000197>
- ARSET. (2020). *Arset, groundwater monitoring using observations from nasas gravity recovery and climate experiment (grace) missions*. Descargado de <https://appliedsciences.nasa.gov/get-involved/training/english/arset-groundwater-monitoring-using-observations-nasas-gravity>
- Barthel, R., Foster, S., y Villholth, K. (2017, 06). Interdisciplinary and participatory approaches : the key to effective groundwater management. *Hydrogeology Journal*, 25(7), 1923-1926. Descargado de <https://www.imta.gob.mx/gobmx/DOI/perspectivas/2022/b-imta-perspectivas-2022-37.pdf> doi: doi.org/10.24850/b-imta-perspectivas-2022-37

- Belyadi, H., y Haghghat, A. (2021). Chapter 5 - supervised learning. En H. Belyadi y A. Haghghat (Eds.), *Machine learning guide for oil and gas using python* (p. 169-295). Gulf Professional Publishing. Descargado de <https://www.sciencedirect.com/science/article/pii/B9780128219294000044> doi: <https://doi.org/10.1016/B978-0-12-821929-4.00004-4>
- Bhanja, S., y Das, A. (2018). Impact of data normalization on deep neural network for time series forecasting. *CoRR, abs/1812.05519*. Descargado de <http://arxiv.org/abs/1812.05519>
- Bierkens, M. F. P., y Wada, Y. (2019). Non-renewable groundwater use and groundwater depletion: a review. *Environmental Research Letters*, 14(6), 063002. Descargado de <https://dx.doi.org/10.1088/1748-9326/ab1a5f> doi: 10.1088/1748-9326/ab1a5f
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Blondel, M., y Roulet, V. (2024). The elements of differentiable programming. *ArXiv*, 338-339. Descargado de <https://api.semanticscholar.org/CorpusID:268553523>
- Breiman, L. (2001a). Random forests. *Machine learning*, 45(1), 5–32.
- Breiman, L. (2001b, octubre). Random Forests. *Machine Learning*, 45(1), 5–32. Descargado 2014-03-09, de <http://link.springer.com/article/10.1023/A%3A1010933404324> doi: 10.1023/A:1010933404324
- Breiman, L., Friedman, J., Stone, C. J., y Olshen, R. (1984). *Classification and regression trees*. Chapman and Hall/CRC.
- Brookfield, A. E., Hill, M. C., Rodell, M., Loomis, B. D., Stotler, R. L., Porter, M. E., y Bohling, G. C. (2018). In situ and grace-based groundwater observations: Similarities, discrepancies, and evaluation in the high plains aquifer in kansas. *Water Resources Research*, 54(10), 8034-8044. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2018WR023836> doi: <https://doi.org/10.1029/2018WR023836>
- Bull, D. R. (2014). Chapter 4 - digital picture formats and representations. En D. R. Bull (Ed.), *Communicating pictures* (p. 99-132). Oxford: Academic Press. Descargado de <https://www.sciencedirect.com/science/article/pii/B9780124059061000040> doi: <https://doi.org/10.1016/B978-0-12-405906-1.00004-0>
- Castellazzi, P., Martel, R., Rivera, A., Huang, J., Pavlic, G., Calderhead, A. I., ... Salas, J. (2016). Groundwater depletion in central mexico: Use of grace and insar to support water resources management. *Water Resources Research*, 52(8), 5985-6003. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/2015WR018211> doi: <https://doi.org/10.1002/2015WR018211>
- Chen, J. L., Wilson, C. R., Famiglietti, J. S., y Rodell, M. (2005). Spatial sensitivity of the gravity recovery and climate experiment (grace) time-variable gravity observations. *Journal of Geophysical Research: Solid Earth*, 110(B8). Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2004JB003536> doi: <https://doi.org/10.1029/2004JB003536>
- Chen, L., He, Q., Liu, K., Li, J., y Jing, C. (2019). Downscaling of grace-derived groundwater storage based on the random forest model. *Remote Sensing*, 11(24). Descargado de <https://www.mdpi.com/2072-4292/11/24/2979> doi: 10.3390/rs11242979
- CILA. (1944). *Tratado de aguas internacionales de 1944*. Autor. Descargado de <https://www.ibwc.gov/Files/1944Treaty.pdf>
- CONAGUA. (1960). *Ordenamientos de aguas subterráneas de conagua*. Descargado de <https://datos.gob.mx/busca/dataset/ordenamientos-de-aguas-subterraneas-de-conagua> (Relación de acuíferos con ordenamiento, indicando el tipo (veda, reglamento, reserva), la fecha de su emisión, sus límites y cobertura geográfica (shape files).

- Mapa que ilustra la ubicación de los acuíferos con ordenamiento.)
- CONAGUA. (2023). *Actualización de la disponibilidad media anual de agua en el acuífero conejos - médanos (0823), estado de chihuahua*. Comisión Nacional del Agua. Descargado de https://sigagis.conagua.gob.mx/gas1/Edos_Acuiferos_18/chihuahua/DR_0823.pdf
- CONAGUA. (2024a). *Actualización de la disponibilidad media anual de agua en el acuífero conejos- Médanos (0823), estado de chihuahua*. https://sigagis.conagua.gob.mx/gas1/Edos_Acuiferos_18/chihuahua/DR_0823.pdf. SUBDIRECCIÓN GENERAL TÉCNICA, GERENCIA DE AGUAS SUBTERRÁNEAS.
- CONAGUA. (2024b). *Conagua / disponibilidad por acuíferos*. https://sigagis.conagua.gob.mx/gas1/sections/Disponibilidad_Acuiferos. México. (Accessed: 2024-08-24)
- Connor, R., y Miletto, M. (2022). *Informe mundial de las naciones unidas sobre el desarrollo de los recursos hídricos 2022: aguas subterráneas: hacer visible el recurso invisible; resumen ejecutivo*. <https://agua.org.mx/wp-content/uploads/2017/06/retos-de-la-investigaci%C3%B3n-del-agua-en-mexico.pdf>. (Programa Mundial de la UNESCO de Evaluación de los Recursos Hídricos)
- Coppola, E., Szidarovszky, F., Poulton, M., y Charles, E. (2003). Artificial neural network approach for predicting transient water levels in a multilayered groundwater system under variable state, pumping, and climate conditions. *Journal of Hydrologic Engineering*, 8(6), 348-360. Descargado de <https://ascelibrary.org/doi/abs/10.1061/%28ASCE%291084-0699%282003%298%3A6%28348%29> doi: 10.1061/(ASCE)1084-0699(2003)8:6(348)
- Coulibaly, P., Anctil, F., Aravena, R., y Bobée, B. (2001). Artificial neural network modeling of water table depth fluctuations. *Water Resources Research*, 37(4), 885-896. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2000WR900368> doi: <https://doi.org/10.1029/2000WR900368>
- Cubas, F., Llano, y de Rosenzweig, L. J. (2017). *El misterio del agua subterránea en México*. <https://agua.org.mx/biblioteca/misterio-del-agua-subterranea-en-mexico/>. Fondo para la comunicación y la educación ambiental. (Accedido el 10 de agosto de 2024)
- Date, S. (2023). *Time series analysis, regression, and forecasting. with tutorials in python*. OTexts. Descargado de <https://timeseriesreasoning.com/contents/time-series-decomposition/> (Accessed: 2023-06-01)
- Derek, E., Baihua, F., E, S. A., y E, S. L. (2016). Groundwater dependent ecosystems: classification, identification techniques and threats. *Integrated groundwater management: concepts, approaches and challenges*, 313–346.
- Dickey, J., Bentley, C., Bilham, R., Carton, J., Eanes, R., Herring, T., ... others (1998). Satellite gravity and the geosphere: Contributions to the study of the solid earth and its fluid earth. *Research Gate*. Descargado de https://www.researchgate.net/publication/247441902_Satellite_Gravity_and_the_Geosphere_Contributions_to_the_Study_of_the_Solid_Earth_and_Its_Fluid_Earth
- Donkor, E. A., Mazzuchi, T. A., Soyer, R., y Roberson, J. A. (2014). Urban water demand forecasting: Review of methods and models. *Journal of Water Resources Planning and Management*, 140(2), 146-159. Descargado de <https://ascelibrary.org/doi/abs/10.1061/%28ASCE%29WR.1943-5452.0000314> doi: 10.1061/(ASCE)WR.1943-5452.0000314
- Douville, H., Ribes, A., Decharme, B., Alkama, R., y Sheffield, J. (2013, 01 de 6). Anthropogenic influence on multidecadal changes in reconstructed global evapotranspiration. *Nature*

- Climate Change*, 3(1), 59-62. Descargado de <https://doi.org/10.1038/nclimate1632>
doi: 10.1038/nclimate1632
- Du, Q., y Xie, W. (2019). *Deep learning for remote sensing data*. CRC Press.
- Döll, P., Müller Schmied, H., Schuh, C., Portmann, F. T., y Eicker, A. (2014). Global-scale assessment of groundwater depletion and related groundwater abstractions: Combining hydrological modeling with information from well observations and grace satellites. *Water Resources Research*, 50(7), 5698-5720. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/2014WR015595> doi: <https://doi.org/10.1002/2014WR015595>
- Eamus, D., Zolfaghar, S., Villalobos-Vega, R., Cleverly, J., y Huete, A. (2015). Groundwater-dependent ecosystems: recent insights from satellite and field-based studies. *Hydrology and Earth System Sciences*, 19(10), 4229–4256. Descargado de <https://hess.copernicus.org/articles/19/4229/2015/> doi: 10.5194/hess-19-4229-2015
- Endel, F., y Piringer, H. (2015). Data wrangling: Making data useful again. *IFAC-PapersOnLine*, 48(1), 111-112. Descargado de <https://www.sciencedirect.com/science/article/pii/S2405896315001986> (8th Vienna International Conference on Mathematical Modelling) doi: <https://doi.org/10.1016/j.ifacol.2015.05.197>
- ESRI. (2023). *Fundamentals of netcdf data storage*. <https://pro.arcgis.com/en/pro-app/latest/help/data/multidimensional/fundamentals-of-netcdf-data-storage.htm>. (Accessed: 2023-06-01)
- Famiglietti, J. S., Lo, M., Ho, S. L., Bethune, J., Anderson, K. J., Syed, T. H., ... Rodell, M. (2011). Satellites measure recent rates of groundwater depletion in california's central valley. *Geophysical Research Letters*, 38(3). Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2010GL046442> doi: <https://doi.org/10.1029/2010GL046442>
- Fang, J., Zhou, Y., Yu, Y., y Du, S. (2016, 11). Fine-grained vehicle model recognition using a coarse-to-fine convolutional neural network architecture. *IEEE Transactions on Intelligent Transportation Systems*, PP, 1-11. doi: 10.1109/TITS.2016.2620495
- Fang, K., y Shen, C. (2020). Near-real-time forecast of satellite-based soil moisture using long short-term memory with an adaptive data integration kernel. *Journal of Hydrometeorology*, 21(3), 399 - 413. Descargado de <https://journals.ametsoc.org/view/journals/hydr/21/3/jhm-d-19-0169.1.xml> doi: 10.1175/JHM-D-19-0169.1
- FAO. (2017). *The state of the world's land and water resources for food and agriculture, managing systems at risk*. <http://www.fao.org/3/i1688e/i1688e.pdf>. (Accessed: 2024-08-09)
- Fieres, J., Schemmel, J., y Meier, K. (2006, 01). Training convolutional networks of threshold neurons suited for low-power hardware implementation. En (Vol.-28, p. 21 - 28). doi: 10.1109/IJCNN.2006.246654
- Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., ... Michaelsen, J. (2015, 08 de 12). The climate hazards infrared precipitation with stations a new environmental record for monitoring extremes. *Scientific Data*, 2(1), 150066. Descargado de <https://doi.org/10.1038/sdata.2015.66> doi: 10.1038/sdata.2015.66
- Galván, S. G. G., Rivera, J. J. C., y Álvarez, R. H. (2018). *Coloquios sobre el agua subterránea en México* (Primera edición ed.). Comisión de Biblioteca y Asuntos Editoriales. (Queda permitida la reproducción parcial o total, directa o indirecta del contenido de esta obra por tratarse de un texto de divulgación. Sin embargo, deberá citarse la fuente correspondiente en todo momento.)
- García, H. O., y Castro, J. E. (2015, 7). Imposition, resistance, and alternatives in the face of an inter-regional water crisis in Mexico: El Zapotillo project. *WATERLAT-GOBACIT Working Papers*,

- 2(1). (Thematic Area Series — SATCTH TA6. Basins and Hydrosocial Territories)
- GLEAM. (2011). *Global land evaporation amsterdam model*. Autor. Descargado de <https://www.gleam.eu/> (Accessed: 2024-02)
- Gleeson, T., Wada, Y., Bierkens, M., y van Beek, L. (2012). Water balance of global aquifers revealed by groundwater footprint. *Nature*, 488(7410), 197-200. Descargado de <https://doi.org/10.1038/nature11295> doi: 10.1038/nature11295
- Godfray, H. C. J., Beddington, J. R., Crute, I. R., Haddad, L., Lawrence, D., Muir, J. F., ... Toulmin, C. (2010). Food security: The challenge of feeding 9 billion people. *Science*, 327(5967), 812-818. Descargado de <https://www.science.org/doi/abs/10.1126/science.1185383> doi: 10.1126/science.1185383
- Gonzalo, H. K. (2018, 04). Capítulo 7. agua subterránea en México, retos y pendientes para la transformación de su gestión. Escuela Nacional de Ciencias de la Tierra, UNAM.
- Good, I. (1977). Explicativity: a mathematical theory of explanation with statistical applications. *Proceedings of the Royal Society of London. A. Mathematical and Physical Sciences*, 354(1678), 303–330.
- Goodfellow, I., Bengio, Y., y Courville, A. (2016). *Deep learning*. MIT press.
- GRACE-FO. (2024). *Grace-fo: from range observations to global mass change*. NASA Jet Propulsion Laboratory, California Institute of Technology. Descargado de <https://grace.jpl.nasa.gov/resources/40/grace-fo-from-range-observations-to-global-mass-change/>
- Graves, A., Mohamed, A.-r., y Hinton, G. (2013). Speech recognition with deep recurrent neural networks. En *2013 IEEE International Conference on Acoustics, Speech and Signal Processing* (pp. 6645–6649).
- Guo, G., Liu, S., Wu, Y., Li, J., Zhou, R., y Zhu, X. (2018). Short-term water demand forecast based on deep learning method. *Journal of Water Resources Planning and Management*, 144(12), 04018076. Descargado de <https://ascelibrary.org/doi/abs/10.1061/%28ASCE%29WR.1943-5452.0000992> doi: 10.1061/(ASCE)WR.1943-5452.0000992
- Géron, A. (2019). *Hands-on machine learning with scikit-learn, keras, and tensorflow: Concepts, tools, and techniques to build intelligent systems*. O'Reilly Media, Inc.
- Han, J., Kamber, M., y Pei, J. (2011). *Data mining: Concepts and techniques*. Morgan Kaufmann.
- He, K., Zhang, X., Ren, S., y Sun, J. (2015, 02). Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. *IEEE International Conference on Computer Vision (ICCV 2015)*, 1502. doi: 10.1109/ICCV.2015.123
- HELM. (2020). *Regression and correlation*. SIGMA NETWORK. Descargado de https://nucinkis-lab.cc.ic.ac.uk/HELM/HELM_Workbooks_41-45/WB43-all.pdf (Helping Engineers Learn Mathematics, Loughborough University)
- Hersbach, H., Bell, B., Berrisford, P., Biavati, G., Horányi, J., A. and Muñoz Sabater, Nicolas, J., ... Thépaut, J. (2023). *Era5 hourly data on single levels from 1940 to present*.
- Hersbach, H., Bell, B., Berrisford, P., Horányi, A., Sabater, J. M., Nicolas, J., ... Dee, D. (2019). *Global reanalysis: goodbye era-interim, hello era5*.
- Hochreiter, Sepp, Schmidhuber, y Jürgen. (1997, 11). Long short-term memory. *Neural Comput.*, 9(8), 1735–1780. Descargado de <https://doi.org/10.1162/neco.1997.9.8.1735> doi: 10.1162/neco.1997.9.8.1735
- Hochreiter, S. (1991). Untersuchungen zu dynamischen neuronalen netzen. *Diploma, Technische Universität München*, 91(1), 31.
- Hsu, K.-L., Gupta, H. V., y Sorooshian, S. (1995). Artificial neural network modeling of the rainfall-

- runoff process. *Water Resources Research*, 31(10), 2517-2530. Descargado de <https://doi.org/10.1029/95WR01955> doi: <https://doi.org/10.1029/95WR01955>
- Huang, Z., Pan, Y., Gong, H., Yeh, P. J.-F., Li, X., Zhou, D., y Zhao, W. (2015). Subregional-scale groundwater depletion detected by grace for both shallow and deep aquifers in north china plain. *Geophysical Research Letters*, 42(6), 1791-1799. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/2014GL062498> doi: <https://doi.org/10.1002/2014GL062498>
- Humphrey, V., Rodell, M., y Eicker, A. (2023). Using satellite-based terrestrial water storage data: A review. *Surveys in Geophysics*, 44(5), 1489–1517. Descargado de <https://doi.org/10.1007/s10712-022-09754-9> doi: [10.1007/s10712-022-09754-9](https://doi.org/10.1007/s10712-022-09754-9)
- Huntingford, C., Jeffers, E. S., Bonsall, M. B., Christensen, H. M., Lees, T., y Yang, H. (2019, 11). Machine learning and artificial intelligence to aid climate change research and preparedness. *Environmental Research Letters*, 14(12), 124007. Descargado de <https://dx.doi.org/10.1088/1748-9326/ab4e55> doi: [10.1088/1748-9326/ab4e55](https://doi.org/10.1088/1748-9326/ab4e55)
- Hyndman, R., y Athanasopoulos, G. (2018). *Forecasting: principles and practice, 2nd edition*. OTexts: Melbourne, Australia. Descargado de <https://otexts.com/fpp2/buy-a-print-or-downloadable-version.html> (Accessed: 2024-07-01)
- IMTA. (2021). *La gestión del agua subterránea: haciendo visible lo invisible*. Descargado de <https://www.gob.mx/imta/es/articulos/la-gestion-del-agua-subterranea-haciendo-visible-lo-invisible?idiom=es> (Último acceso: 2024-08-08) doi: [10.24850/b-imta-perspectivas-2022-37](https://doi.org/10.24850/b-imta-perspectivas-2022-37)
- Indolia, S., Goswami, A. K., Mishra, S., y Asopa, P. (2018). Conceptual understanding of convolutional neural network- a deep learning approach. *Procedia Computer Science*, 132, 679-688. Descargado de <https://www.sciencedirect.com/science/article/pii/S1877050918308019> (International Conference on Computational Intelligence and Data Science) doi: <https://doi.org/10.1016/j.procs.2018.05.069>
- Isabelle, M. G. (1997). A scaling law for the validation-set training-set size ratio. *AT&T Bell Laboratories, Berkeley, California*. Descargado de <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.33.1337&rep=rep1&type=pdf> doi: [10.1.1.33.1337](https://doi.org/10.1.1.33.1337)
- Jae Young, S., y Lee, S.-I. (2019). Spatio-temporal groundwater drought monitoring using multi-satellite data based on an artificial neural network. *Water*, 11(9). Descargado de <https://www.mdpi.com/2073-4441/11/9/1953> doi: [10.3390/w11091953](https://doi.org/10.3390/w11091953)
- Jambon-Puillet, E., Shahidzadeh, N., y Bonn, D. (2018). Singular sublimation of ice and snow crystals. *Nature Communications*, 9. Descargado de <https://doi.org/10.1038/s41467-018-06689-x> doi: [10.1038/s41467-018-06689-x](https://doi.org/10.1038/s41467-018-06689-x)
- Jeon, W., Ko, G., Lee, J., Lee, H., Ha, D., y Ro, W. W. (2021). Chapter six - deep learning with gpus. En S. Kim y G. C. Deka (Eds.), *Hardware accelerator systems for artificial intelligence and machine learning* (Vol. 122, p. 167-215). Elsevier. Descargado de <https://www.sciencedirect.com/science/article/pii/S0065245820300905> doi: <https://doi.org/10.1016/bs.adcom.2020.11.003>
- Jindal, S. K., Banerjee, S., Patra, R., y Paul, A. (2022). 9 - deep learning-based brain malignant neoplasm classification using mri image segmentation assisted by bias field correction and histogram equalization. En J. Chaki (Ed.), *Brain tumor mri image segmentation using deep learning techniques* (p. 135-161). Academic Press. Descargado de <https://www.sciencedirect.com/science/article/pii/B9780323911719000089> doi: <https://doi.org/10.1016/B978-0-323-91171-9.00008-9>

- Jour, R., Famiglietti, J. S., y Wahr, J. (2008). Detection of continental hydrology and glaciology signals from grace: A review. *Surveys in Geophysics*, 29(1573-0956), 361-374. doi: <https://doi.org/10.1007/s10712-008-9048-9>
- Jung, M., Reichstein, M., Ciais, P., evirratne, S. I., Sheffield, J., Goulden, M. L., ... Zhang, K. (2010, 01 de 10). Recent decline in the global land evapotranspiration trend due to limited moisture supply. *Nature*, 467(7318), 951-954. Descargado de <https://doi.org/10.1038/nature09396> doi: 10.1038/nature09396
- Jyrkama, M. I., y Sykes, J. F. (2007). The impact of climate change on spatially varying groundwater recharge in the grand river watershed (ontario). *Journal of Hydrology*, 338(3), 237-250. Descargado de <https://www.sciencedirect.com/science/article/pii/S0022169407001308> doi: <https://doi.org/10.1016/j.jhydrol.2007.02.036>
- K., K., jabery, A., Ajayi, T. O., Olbricht, G. R., y C., D. (2020). 4 - selected approaches to supervised learning. En K. A. Khalid, jabery, T. Obafemi, Ajayi, G. R. Olbricht, y D. C. Wunsch II (Eds.), *Computational learning approaches to data analytics in biomedical applications* (p. 101-123). Academic Press. Descargado de <https://www.sciencedirect.com/science/article/pii/B9780128144824000048> doi: <https://doi.org/10.1016/B978-0-12-814482-4.00004-8>
- Kratzert, F., Klotz, D., Herrnegger, M., Sampson, A. K., Hochreiter, S., y Nearing, G. S. (2019). Toward improved predictions in ungauged basins: Exploiting the power of machine learning. *Water Resources Research*, 55(12), 11344-11354. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2019WR026065> doi: <https://doi.org/10.1029/2019WR026065>
- Krizhevsky, A., Sutskever, I., y Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. En *Advances in neural information processing systems* (pp. 1097–1105).
- Kuhn, M., y Johnson, K. (2013). *Applied predictive modeling*. Springer New York. Descargado de <https://books.google.com.mx/books?id=xYRDAAAAQBAJ>
- Kukanov, I., Hautamäki, V., y Lee, K. A. (2018, 04). Maximal figure-of-merit embedding for multi-label audio classification.. doi: 10.1109/ICASSP.2018.8461396
- Landerer, F. W., Flechtner, F. M., Save, H., Webb, F. H., Bandikova, T., Bertiger, W. I., ... Yuan, D.-N. (2020). Extending the global mass change data record: Grace follow-on instrument and science data performance. *Geophysical Research Letters*, 47(12), e2020GL088306. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2020GL088306> (e2020GL088306 2020GL088306) doi: <https://doi.org/10.1029/2020GL088306>
- Laurent, C., Pereyra, G., Brakel, P., Zhang, Y., y Bengio, Y. (2016). Batch normalized recurrent neural networks. En *2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (p. 2657-2661). doi: 10.1109/ICASSP.2016.7472159
- Leblanc, M. J., Tregoning, P., Ramillien, G., Tweed, S. O., y Fakes, A. (2009). Basin-scale, integrated observations of the early 21st century multiyear drought in southeast Australia. *Water Resources Research*, 45(4). Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2008WR007333> doi: <https://doi.org/10.1029/2008WR007333>
- Lecun, Y., Bengio, Y., y Hinton, G. (2015). Deep learning. *Nature*, 521, 436-484. Descargado de <https://doi.org/10.1038/nature14539> doi: 10.1038/nature14539
- LeCun, Y., Bottou, L., Bengio, Y., y Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- Lecun, Y., Bottou, L., Bengio, Y., y Haffner, P. (1998, 12). Gradient-based learning applied to docu-

- ment recognition. *Proceedings of the IEEE*, 86, 2278 - 2324. doi: 10.1109/5.726791
- Li, B., Rodell, M., Kumar, S., Beaudoin, H. K., Getirana, A., Zaitchik, B. F., ... Bettadpur, S. (2019). Global grace data assimilation for groundwater and drought monitoring: Advances and challenges. *Water Resources Research*, 55(9), 7564-7586. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2018WR024618> doi: <https://doi.org/10.1029/2018WR024618>
- Liang, M., Hu, X., y Zhang, B. (2015). Convolutional neural networks with intra-layer recurrent connections for scene labeling. En C. Cortes, N. Lawrence, D. Lee, M. Sugiyama, y R. Garnett (Eds.), *Advances in neural information processing systems* (Vol. 28). Curran Associates, Inc. Descargado de https://proceedings.neurips.cc/paper_files/paper/2015/file/9cf81d8026a9018052c429cc4e56739b-Paper.pdf
- Lillesand, T., Kiefer, R. W., y Chipman, J. (2015). *Remote sensing and image interpretation*. John Wiley & Sons.
- Long, D., Shen, Y., Sun, A., Hong, Y., Longuevergne, L., Yang, Y., ... Chen, L. (2014). Drought and flood monitoring for a large karst plateau in southwest china using extended grace data. *Remote Sensing of Environment*, 155, 145-160. Descargado de <https://www.sciencedirect.com/science/article/pii/S0034425714003034> doi: <https://doi.org/10.1016/j.rse.2014.08.006>
- Longuevergne, L., Scanlon, B. R., y Wilson, C. R. (2010). Grace hydrological estimates for small basins: Evaluating processing approaches on the high plains aquifer, usa. *Water Resources Research*, 46(11). Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2009WR008564> doi: <https://doi.org/10.1029/2009WR008564>
- Lu, M., y Ishwaran, H. (2017, 01). A machine learning alternative to p-values. *ResearchGate*.
- Macpherson, T., Churchland, A., Sejnowski, T., DiCarlo, J., Kamitani, Y., Takahashi, H., y Hikida, T. (2021). Natural and artificial intelligence: A brief introduction to the interplay between ai and neuroscience research. *Neural Networks*, 144, 603-613. Descargado de <https://www.sciencedirect.com/science/article/pii/S0893608021003683> doi: <https://doi.org/10.1016/j.neunet.2021.09.018>
- Martens, B., Miralles, D. G., Lievens, H., van der Schalie, R., de Jeu, R. A. M., Fernández-Prieto, D., ... Verhoest, N. E. C. (2017). Gleam v3: satellite-based land evaporation and root-zone soil moisture. *Geoscientific Model Development*, 10(5), 1903–1925. Descargado de <https://gmd.copernicus.org/articles/10/1903/2017/> doi: 10.5194/gmd-10-1903-2017
- McKinney, W. (2012). *Python for data analysis: Data wrangling with pandas, numpy, and ipython*. O'Reilly Media, Inc.
- Megdal, S., y cols. (2014). Groundwater governance in the u.s.-mexico border region. *Journal of Hydrology*. Descargado de <https://doi.org/10.1016/j.jhydrol.2013.12.039>
- MetaData, C. (2023). *Cf metadata conventions*. <http://cfconventions.org/>. (Accessed: 2023-06-01)
- Miralles, D. G., Brutsaert, W., Dolman, A. J., y Gash, J. H. (2020). On the use of the term “evapotranspiration”. *Water Resources Research*, 56(11), e2020WR028055. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2020WR028055> (e2020WR028055 2020WR028055) doi: <https://doi.org/10.1029/2020WR028055>
- Miralles, D. G., Holmes, T. R. H., De Jeu, R. A. M., Gash, J. H., Meesters, A. G. C. A., y Dolman, A. J. (2011). Global land-surface evaporation estimated from satellite-based observations. *Hydrology and Earth System Sciences*, 15(2), 453–469. Descargado de <https://hess.copernicus.org/articles/15/453/2011/> doi: 10.5194/hess-15-453-2011

- Mitchell, T. (1997). *Machine learning*. McGraw-Hill. Descargado de <https://www.cs.cmu.edu/~tom/files/MachineLearningTomMitchell.pdf> (<https://www.cs.cmu.edu/~tom/publications.html>)
- Mohammadi, K. (2008). Groundwater table estimation using modflow and artificial neural networks. En R. J. Abrahart, L. M. See, y D. P. Solomatine (Eds.), *Practical hydroinformatics: Computational intelligence and technological developments in water applications* (pp. 127–138). Berlin, Heidelberg: Springer Berlin Heidelberg. Descargado de https://doi.org/10.1007/978-3-540-79881-1_10 doi: 10.1007/978-3-540-79881-1_10
- Molina, M. O. (2018). Beyond basins: The political delimitation of aquifers in Mexico. *Voices of Mexico, 108*. Descargado de <https://www.waterlat.org/wp-content/uploads/2018/04/Vol-1-1-Iss-1-Art-1.pdf> (Dossier Water. Accedido el 7 de agosto de 2024)
- Mukherjee, A., y Ramachandran, P. (2018). Prediction of gwl with the help of grace tws for unevenly spaced time series data in India: Analysis of comparative performances of svr, ann and lrm. *Journal of Hydrology, 558*, 647-658. Descargado de <https://www.sciencedirect.com/science/article/pii/S0022169418300817> doi: <https://doi.org/10.1016/j.jhydrol.2018.02.005>
- Murphy, K. P. (2021). *Machine learning: A probabilistic perspective*. Cambridge, Mass. [u.a.]: MIT Press.
- Muñoz Sabater, J. (2019). *Era5-land hourly data from 1950 to present*. doi: 10.24381/cds.e2161bac
- Nanteza, J., de Linage, C. R., Thomas, B. F., y Famiglietti, J. S. (2016). Monitoring groundwater storage changes in complex basement aquifers: An evaluation of the grace satellites over East Africa. *Water Resources Research, 52*(12), 9542-9564. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/2016WR018846> doi: <https://doi.org/10.1002/2016WR018846>
- Naranjo, B., Agustin, J., D., K. A., y W., H. D. (2014). Improved methods for satellite-based groundwater storage estimates: A decade of monitoring the high plains aquifer from space and ground observations. *Geophysical Research Letters, 41*(17), 6167-6173. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/2014GL061213> doi: <https://doi.org/10.1002/2014GL061213>
- NASA. (2022). *Fundamentals of remote sensing [Manual de software informático]*. Descargado de https://appliedsciences.nasa.gov/sites/default/files/2022-11/Fundamentals_of_RS_Edited_SC.pdf
- NASA. (2024). *How grace-fo measures gravity*. NASA Jet Propulsion Laboratory, California Institute of Technology. Descargado de <https://gracefo.jpl.nasa.gov/resources/50/how-grace-fo-measures-gravity/>
- NASA, E. (2018). *Groundwater storage (gws)*. Giovanni Measurement Definitions: Groundwater Storage (GWS). Descargado de [https://disc.gsfc.nasa.gov/information/glossary?keywords=giovanni%20measurements&title=Giovanni%20Measurement%20Definitions:%20Groundwater%20Storage%20\(GWS\)](https://disc.gsfc.nasa.gov/information/glossary?keywords=giovanni%20measurements&title=Giovanni%20Measurement%20Definitions:%20Groundwater%20Storage%20(GWS))
- NASA Jet Propulsion Laboratory (JPL) Tellus. (2018). *Jpl grace mascon ocean, ice, and hydrology equivalent water height release 06 coastal resolution improvement (cri) filtered version 1.0*. NASA Physical Oceanography Distributed Active Archive Center. Descargado de https://podaac.jpl.nasa.gov/dataset/TELLUS_GRACE_MASCON_CRI_GRID_RL06_V1 doi: 10.5067/TEMSC-3MJC6
- Nearing, G. S., Kratzert, F., Sampson, A. K., Pelissier, C. S., Klotz, D., Frame, J. M., ... Gupta,

- H. V. (2021). What role does hydrological science play in the age of machine learning? *Water Resources Research*, 57(3), e2020WR028091. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2020WR028091> (e2020WR028091 10.1029/2020WR028091) doi: <https://doi.org/10.1029/2020WR028091>
- Ngo-Duc, T., Laval, K., Ramillien, G., Polcher, J., y Cazenave, A. (2007). Validation of the land water storage simulated by organising carbon and hydrology in dynamic ecosystems (orchidee) with gravity recovery and climate experiment (grace) data. *Water Resources Research*, 43(4). Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2006WR004941> doi: <https://doi.org/10.1029/2006WR004941>
- Nikolos, I. K., Stergiadi, M., Papadopoulou, M. P., y Karatzas, G. P. (2008). Artificial neural networks as an alternative approach to groundwater numerical modelling and environmental design. *Hydrological Processes*, 22(17), 3337-3348. Descargado de <https://onlinelibrary.wiley.com/doi/abs/10.1002/hyp.6916> doi: <https://doi.org/10.1002/hyp.6916>
- NRC. (2008). *Integrating multiscale observations of us waters*. National Academies Press. [https://books.google.com.mx/books?hl=en&lr=&id=VQ5kAgAAQBAJ&oi=fnd&pg=PR1&dq=+National+Research+Council+\(2008\),+Integrating+Multiscale+Observations+of+U.S.+Waters,+210+pp.+The+National+Academies+Press,+Washington,+D.+C.%0A&ots=iWZnZip5bD&sig=mnkSQZINVi6a71ClTeT6UNYHC04&redir_esc=y#v=onepage&q&f=false](https://books.google.com.mx/books?hl=en&lr=&id=VQ5kAgAAQBAJ&oi=fnd&pg=PR1&dq=+National+Research+Council+(2008),+Integrating+Multiscale+Observations+of+U.S.+Waters,+210+pp.+The+National+Academies+Press,+Washington,+D.+C.%0A&ots=iWZnZip5bD&sig=mnkSQZINVi6a71ClTeT6UNYHC04&redir_esc=y#v=onepage&q&f=false). (National Research Council and Division on Earth and Life Studies and Wa)
- Palmer, A., Jiménez, R., y Montaña, J. (2001, 01). Tutorial sobre el coeficiente de correlación lineal de pearson en internet. *ResearchGate*, 5.
- Palsson, F., Sveinsson, J., y Ulfarsson, M. (2017, 06). Multispectral and hyperspectral image fusion using a 3-d-convolutional neural network. *IEEE Geoscience and Remote Sensing Letters*, PP. doi: 10.1109/LGRS.2017.2668299
- Panahi, M., Sadhasivam, N., Pourghasemi, H. R., Rezaie, F., y Lee, S. (2020). Spatial prediction of groundwater potential mapping based on convolutional neural network (cnn) and support vector regression (svr). *Journal of Hydrology*, 588, 125033. Descargado de <https://www.sciencedirect.com/science/article/pii/S0022169420304935> doi: <https://doi.org/10.1016/j.jhydrol.2020.125033>
- Pang-Wei, L., Famiglietti, J. S., Purdy, A. J., Adams, K. H., McEvoy, A. L., Reager, J. T., ... Rodell, M. (2022). Groundwater depletion in california's central valley accelerates during megadrought. *Nature Communications*, 13(1), 7825. Descargado de <https://doi.org/10.1038/s41467-022-35582-x> doi: 10.1038/s41467-022-35582-x
- Parkin, G., Birkinshaw, S., Younger, P., Rao, Z., y Kirk, S. (2007). A numerical modelling and neural network approach to estimate the impact of groundwater abstractions on river flows. *Journal of Hydrology*, 339(1), 15-28. Descargado de <https://www.sciencedirect.com/science/article/pii/S0022169407000285> doi: <https://doi.org/10.1016/j.jhydrol.2007.01.041>
- Perevochtchikova, M., Carrillo R., J. J., y Godoy A., A. E. (2006). Gestión integral del agua en la cuenca de méxico: ¿coincide la cuenca superficial con la subterránea? En *Memorias del v congreso internacional y xi nacional de ciencias ambientales*. Morelos: Universidad Autónoma del Estado de Morelos.
- Pinheiro, P., y Collobert, R. (2014). Recurrent convolutional neural networks for scene labeling. En *International conference on machine learning* (pp. 82–90).
- Ponce, J., Torres, A., Aguilera, F., Silva Sprock, A., Flor, E., Casali, A., ... Pedreño, O. (2014). *In-*

- teligencia artificial*. Iniciativa Latinoamericana de Libros de Texto Abiertos (LATIn). doi: 10.13140/2.1.3720.0960
- Provost, F., y Fawcett, T. (2013). *Data science for business: What you need to know about data mining and data-analytic thinking*. O'Reilly Media, Inc.
- Rateb, A., Scanlon, B. R., Pool, D. R., Sun, A., Zhang, Z., Chen, J., ... Zell, W. (2020). Comparison of groundwater storage changes from grace satellites with monitoring and modeling of major u.s. aquifers. *Water Resources Research*, 56(12), e2020WR027556. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2020WR027556> (e2020WR027556 2020WR027556) doi: <https://doi.org/10.1029/2020WR027556>
- Riebeek, H. (2012). *The gravity of water*. NASA, Earth Observatory. Descargado de <https://earthobservatory.nasa.gov/features/GRACEGroundwater> (Accessed: 2024-02)
- Rivera, C. (2012, 01). Carrillo-rivera jj y a cardona. 2012. groundwater flow systems and their response to climate change: A need for a water-system view approach american journal of environmental sciences 8(3):220-235, issn 1553-345x © 2012,. *American journal of environmental sciences*, 8, 220-235.
- Rivera, C., y Joel, J. (2014). *Coloquio nacional: Agua subterránea en México*. https://agua.org.mx/wp-content/uploads/2014/04/ColoquioNacional_Agua_Subterranea_en_Mexico.pdf. Instituto de Geografía, UNAM. (Por una Gestión Integral del Agua Subterránea (GIAS): Una Propuesta)
- Rivera, C., Jose, Peñuela Arévalo, L., Álvarez, R., Cardona, A., Ortega Guerrero, M., ... Hatch Kuri, G. (2016, 07). Conflictos por el agua subterránea. En (pp. 151-166, Tomo I). Universidad Nacional Autónoma de México. (GEOGRAFÍA DE MÉXICO, Una reflexión espacial contemporánea. José Omar Moncada Maya y Alvaro López López)
- Robins, N. S. (1998). *Groundwater pollution, aquifer recharge and vulnerability* (Vol. 130). Geological Society of London.
- Rodell, M., y Famiglietti, J. (2002). The potential for satellite-based monitoring of groundwater storage changes using grace: the high plains aquifer, central us. *Journal of Hydrology*, 263(1), 245-256. Descargado de <https://www.sciencedirect.com/science/article/pii/S0022169402000604> doi: [https://doi.org/10.1016/S0022-1694\(02\)00060-4](https://doi.org/10.1016/S0022-1694(02)00060-4)
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. doi: 10.1037/h0042519
- Sahoo, S., Russo, T. A., Elliott, J., y Foster, I. (2017). Machine learning algorithms for modeling groundwater level changes in agricultural regions of the u.s. *Water Resources Research*, 53(5), 3878-3895. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/2016WR019933> doi: <https://doi.org/10.1002/2016WR019933>
- Sanchez, E. N., Rios, J. D., Alanis, A. Y., Arana-Daniel, N., y Lopez-Franco, C. (2020). Artificial neural networks, appendix a. En *Neural networks modeling and control* (p. 117-124). Academic Press. Descargado de <https://www.sciencedirect.com/science/article/pii/B9780128170786000167> doi: <https://doi.org/10.1016/B978-0-12-817078-6.00016-7>
- Schmidhuber, J., Gomez, F., Fernandez, S., Graves, A., y Hochreiter., S. (2017). *Recurrent neural networks*. <https://people.idsia.ch/~juergen/rnn.html>. (Accessed: 2023-06-01)
- Seo, J. Y., y Lee, S.-I. (2019). Spatio-temporal groundwater drought monitoring using multi-satellite data based on an artificial neural network. *Water*, 11(9). Descargado de <https://www.mdpi.com/2073-4441/11/9/1953> doi: 10.3390/w11091953
- Seo, J. Y., y Lee, S.-I. (2021). Predicting changes in spatiotemporal groundwater storage through the integration of multi-satellite data and deep learning models. *IEEE Access*, 9, 157571-157583.

doi: 10.1109/ACCESS.2021.3130306

- Seonyoung, P., Park, S., Im, J., Rhee, J., Shin, J., y Park, J. D. (2017). Downscaling gldas soil moisture data in east asia through fusion of multi-sensors by optimizing modified regression trees. *Water*, 9(5). Descargado de <https://www.mdpi.com/2073-4441/9/5/332> doi: 10.3390/w9050332
- Seyoum, W., Kwon, D., y Milewski, A. M. (2019). Downscaling grace twsa data into high-resolution groundwater level anomaly using machine learning-based models in a glacial aquifer system. *Remote Sensing*, 11(7). Descargado de <https://www.mdpi.com/2072-4292/11/7/824> doi: 10.3390/rs11070824
- Seyoum, W., y Milewski, A. M. (2017). Improved methods for estimating local terrestrial water dynamics from grace in the northern high plains. *Advances in Water Resources*, 110, 279-290. Descargado de <https://www.sciencedirect.com/science/article/pii/S0309170817302336> doi: <https://doi.org/10.1016/j.advwatres.2017.10.021>
- Seyoum, W. M., y Milewski, A. M. (2017). Improved methods for estimating local terrestrial water dynamics from grace in the northern high plains. *Advances in Water Resources*, 110, 279-290. Descargado de <https://www.sciencedirect.com/science/article/pii/S0309170817302336> doi: <https://doi.org/10.1016/j.advwatres.2017.10.021>
- SGM. (2010). *Actividades hidrogeológicas del acuífero conejos médanos, estado de chihuahua, primera etapa*. <http://www.cila.gob.mx/as/ahacmE1.pdf>. (Accessed: 2024-Septiembre)
- Shah, M., y Szeliski, R. (2012). *Machine learning and data mining for computer vision*. Springer.
- Shamsudduha, M. (2021). Chapter 4 - groundwater storage dynamics in the himalayan river basins and impacts of global change in the anthropocene. En A. Mukherjee, B. R. Scanlon, A. Aureli, S. Langan, H. Guo, y A. A. McKenzie (Eds.), *Global groundwater* (p. 47-63). Elsevier. Descargado de <https://www.sciencedirect.com/science/article/pii/B9780128181720000049> doi: <https://doi.org/10.1016/B978-0-12-818172-0.00004-9>
- Shanker, M., Hu, M., y Hung, M. (1996). Effect of data standardization on neural network training. *Omega*, 24(4), 385-397. Descargado de <https://www.sciencedirect.com/science/article/pii/0305048396000102> doi: [https://doi.org/10.1016/0305-0483\(96\)00010-2](https://doi.org/10.1016/0305-0483(96)00010-2)
- Shen, C. (2018). A transdisciplinary review of deep learning research and its relevance for water resources scientists. *Water Resources Research*, 54(11), 8558-8593. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2018WR022643> doi: <https://doi.org/10.1029/2018WR022643>
- Shi, B., Bai, X., y Yao, C. (2016). An end-to-end trainable neural network for image-based sequence recognition and its application to scene text recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(11), 2298–2304.
- Shi, B., Bai, X., y Yao, C. (2017). An end-to-end trainable neural network for image-based sequence recognition and its application to scene text recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(11), 2298-2304. doi: 10.1109/TPAMI.2016.2646371
- Shilengwe, C., Banda, K., y Nyambe, I. (2024). Machine learning downscaling of grace/grace-fo data to capture spatial-temporal drought effects on groundwater storage at a local scale under data-scarcity. *Environmental Systems Research*, 13(1), 38. Descargado de <https://doi.org/10.1186/s40068-024-00368-1> doi: 10.1186/s40068-024-00368-1
- Shuhua, Y., y Cheng, H. (2007). Space technique monitoring and prediction of ground water changes. *Progress in Geophysics*, 22(4), 1030–1034.
- Siebert, S., J, B., M., F. J., K., F., J., H., P., D., y T., P. F. (2010). Groundwater use for irrigation – a global inventory. *Hydrology and Earth System Sciences*, 14(10), 1863–1880. Descargado

- de <https://hess.copernicus.org/articles/14/1863/2010/> doi: 10.5194/hess-14-1863-2010
- Siegel, A. F. (2012). Chapter 14 - time series: Understanding changes over time. En A. F. Siegel (Ed.), *Practical business statistics (sixth edition)* (Sixth Edition ed., p. 429-464). Boston: Academic Press. Descargado de <https://www.sciencedirect.com/science/article/pii/B9780123852083000146> doi: <https://doi.org/10.1016/B978-0-12-385208-3.00014-6>
- Simonyan, K., y Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- SINA. (2018). *Estadística del agua en México*. Comisión Nacional del Agua. "http://sina.conagua.gob.mx/publicaciones/EAM_2018.pdf".
- SINA. (2024). *Sistema nacional de información del agua*. Descargado de <https://sinav30.conagua.gob.mx:8080/SINA/?opcion=pozos> (Accedido en septiembre de 2024. Reportes de piezometría por nombre de acuífero)
- sklearn developers. (2024). *Minmaxscaler*. <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.MinMaxScaler.html>. (Accessed: 2024-06-01)
- sklearnF. (2023). *Feature importances with a forest of trees*. https://scikit-learn.org/stable/auto_examples/ensemble/plot_forest_importances.html. (Accessed: 2023-10-10)
- sklearnRF. (2023). *sklearn.ensemble.randomforestregressor*. <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestRegressor.html>. (Accessed: 2023-10-10)
- s. Mumme. (2000). Managing transboundary water resources: Lessons from the u.s.-mexico border. *Water Policy*. Descargado de <https://www.sciencedirect.com/science/article/pii/S1366701708000025>
- Soltani, S. S., Ataie-Ashtiani, B., y Simmons, C. T. (2021). Review of assimilating grace terrestrial water storage data into hydrological models: Advances, challenges and opportunities. *Earth-Science Reviews*, 213, 103487. Descargado de <https://www.sciencedirect.com/science/article/pii/S001282522030533X> doi: <https://doi.org/10.1016/j.earscirev.2020.103487>
- Stobierski, T. (2023). *Data wrangling: What it is & why it's important* (Vol. 2). Harvard. (Accessed: 2023-06-01)
- Stone, A. (2018). Para la planificación adecuada de la sostenibilidad del suministro de agua: Todos los datos científicos asequibles deben ser utilizados. En *Coloquios sobre el agua subterránea en México*. Concord, New Hampshire: Comisión de Biblioteca y Asuntos Editoriales.
- Sun, A. (2013). Predicting groundwater level changes using grace data. *Water Resources Research*, 49(9), 5900-5912. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/wrcr.20421> doi: <https://doi.org/10.1002/wrcr.20421>
- Sun, A., R., S. B., Zizhan, Z., David, W., N., B. S., Mukherjee, A., y Zhong, Z. (2019). Combining physically based modeling and deep learning for fusing grace satellite data: Can we learn from mismatch? *Water Resources Research*, 55(2), 1179-1195. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2018WR023333> doi: <https://doi.org/10.1029/2018WR023333>
- Sun, Y., Wang, P., Zhai, S., Hou, D., Wang, S., y Zhou, Y. (2020). Ultra short-term probability prediction of wind power based on lstm network and condition normal distribution. *Wind Energy*, 23(1), 63-76.
- Szandala, T. (2021, 10). Review and comparison of commonly used activation functions for deep

- neural networks. *ResearchGate*. doi: 10.1007/978-981-15-5495-7_11
- Taher, R., Ebrahimi, H., y Nourani, V. (2019). A review of the artificial intelligence methods in groundwater level modeling. *Journal of Hydrology*, 572(January), 336–351. Descargado de <https://doi.org/10.1016/j.jhydrol.2018.12.037> doi: 10.1016/j.jhydrol.2018.12.037
- Taikan, O., y Shinjiro, K. (2006). Global hydrological cycles and world water resources. *Science*, 313(5790), 1068-1072. Descargado de <https://www.science.org/doi/abs/10.1126/science.1128845> doi: 10.1126/science.1128845
- Tapley, B., Bettadpur, S., Ries, J., Thompson, P., y Watkins, M. (2004, 08). Grace measurements of mass variability in the earth system. *Science (New York, N.Y.)*, 305, 503-5. doi: 10.1126/science.1099192
- Tapley, B. D., M, W. M., Flechtner, F., Reigber, C., Bettadpur, S., Rodell, M., ... Velicogna, I. (2019). Contributions of grace to understanding climate change. *Nature Climate Change*, 9, 358-369. Descargado de <https://doi.org/10.1038/s41558-019-0456-2> doi: 10.1038/s41558-019-0456-2
- Taye, M. M. (2023). Understanding of machine learning with deep learning: Architectures, workflow, applications and future directions. *Computers*, 12(5). Descargado de <https://www.mdpi.com/2073-431X/12/5/91> doi: 10.3390/computers12050091
- TELLUS. (2012). *Grace monthly land water mass grids netcdf release 5.0*. https://podaac.jpl.nasa.gov/dataset/TELLUS_LAND_NC_RL05. NASA Physical Oceanography Distributed Active Archive Center. doi: 10.5067/TELND-NC005
- TF. (2023). *tf.keras.utils.model_to_dot*. https://www.tensorflow.org/api_docs/python/tf/keras/utils/model_to_dot. (Accessed: 2023-06-01)
- Tharsanee, R., Soundariya, R., Kumar, A. S., Karthiga, M., y Sountharajan, S. (2021). 7 - deep convolutional neural network–based image classification for covid-19 diagnosis. En U. Kose, D. Gupta, V. H. C. de Albuquerque, y A. Khanna (Eds.), *Data science for covid-19* (p. 117-145). Academic Press. Descargado de <https://www.sciencedirect.com/science/article/pii/B9780128245361000125> doi: <https://doi.org/10.1016/B978-0-12-824536-1.00012-5>
- the Stanford, A. (2024). *Setting up the data and the model, batch normalization*. <https://cs231n.github.io/>. (Accessed: 2024-06-01)
- Trenberth, K. E., Smith, L., Qian, T., Dai, A., y Fasullo, J. (2007). Estimates of the global water budget and its annual cycle using observational and model data. *Journal of Hydrometeorology*, 8(4), 758 - 769. Descargado de https://journals.ametsoc.org/view/journals/hydr/8/4/jhm600_1.xml doi: 10.1175/JHM600.1
- UCAR. (2023). *Data services and tools for geoscience*. Descargado de <https://www.unidata.ucar.edu/software/netcdf/> (Accessed: 2023-06-01)
- UNESCO. (2021). *Groundwater resources assessment under the pressures of humanity and climate changes*. París, Francia: Autor. Descargado de <https://unesdoc.unesco.org/ark:/48223/pf0000382894> (Accedido en [fecha de acceso])
- USDATA.GOV. (2020). *An official website of the united states government*. Descargado de <https://catalog.data.gov/dataset/aquifers1> (This map layer contains the shallowest principal aquifers of the conterminous United States, Hawaii, Puerto Rico, and the U.S. Virgin Islands, portrayed as polygons. The map layer was developed as part of the effort to produce the maps published at 1:2,500,000 in the printed series "Ground Water Atlas of the United States". The published maps contain base and cultural features not included in these data. This is a replacement for the July 1998 map layer called Principal Aquifers of the 48

- Conterminous United States. Accedido en septiembre de 2024. Aquifers)
- Wada, Yoshihide, van Beek, H., L. P., Bierkens, y P., M. F. (2010). Global depletion of groundwater resources. *Geophysical Research Letters*, 37(20), L20402.
- Wada, Y., y Bierkens, M. F. P. (2014). Sustainability of global water use: past reconstruction and future projections. *Environmental Research Letters*, 9(10), 104003. Descargado de <https://dx.doi.org/10.1088/1748-9326/9/10/104003> doi: 10.1088/1748-9326/9/10/104003
- Watkins, M. M., Wiese, D. N., Yuan, D.-N., Boening, C., y Landerer, F. W. (2015). Improved methods for observing earth's time variable mass distribution with grace using spherical cap mascons. *Journal of Geophysical Research: Solid Earth*, 120(4), 2648-2671. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/2014JB011547> doi: <https://doi.org/10.1002/2014JB011547>
- Webb, G. I. (2010). Occam's razor. En C. Sammut y G. I. Webb (Eds.), *Encyclopedia of machine learning* (pp. 735–735). Boston, MA: Springer US. Descargado de https://doi.org/10.1007/978-0-387-30164-8_609 doi: 10.1007/978-0-387-30164-8_609
- Wenjie, Y., Tongqing, L., Zheng, W., Han, S.-C., Hu, L., Tangdamrongsub, N., ... Zhiyong, H. (2020, 05). Improving regional groundwater storage estimates from grace and global hydrological models over tasmania, australia. *Hydrogeology Journal*, 28, 1-17. doi: 10.1007/s10040-020-02157-3
- Wiese, D. N., Landerer, F. W., y Watkins, M. M. (2016). Quantifying and reducing leakage errors in the jpl rl05m grace mascon solution. *Water Resources Research*, 52(9), 7490-7502. Descargado de <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/2016WR019344> doi: <https://doi.org/10.1002/2016WR019344>
- Wilder, y cols. (2010). Transboundary water management and the u.s.-mexico border. *Journal of the Southwest*. Descargado de <https://journals.uair.arizona.edu/index.php/jws/article/view/21947>
- Willmott, C. J., y Matsuura, K. (2005). Advantages of the mean absolute error (mae) over the root mean square error (rmse) in assessing average model performance. *Climate Research*, 30(1), 79-82. Descargado de <https://doi.org/10.3354/cr030079> doi: 10.3354/cr030079
- WMO. (2020). *Declaración de la omm sobre el estado del clima mundial en 2019*. Autor. Descargado de <https://library.wmo.int/records/item/54506-declaracion-de-la-omm-sobre-el-estado-del-clima-mundial-en-2019>
- Wunsch, A., Liesch, T., y Broda, S. (2021, 04). Groundwater level forecasting with artificial neural networks: a comparison of long short-term memory (lstm), convolutional neural networks (cnns), and non-linear autoregressive networks with exogenous input (narx). *Hydrology and Earth System Sciences*, 25, 1671-1687. doi: 10.5194/hess-25-1671-2021
- Yassin, M., Abba, S. I., Pradipta, A., Makkawi, M. H., Shah, S. M. H., Usman, J., ... Sammen, S. S. (2024). Advancing sdgs: Predicting future shifts in saudi arabia's terrestrial water storage using multi-step-ahead machine learning based on grace data. *Water*, 16(2). Descargado de <https://www.mdpi.com/2073-4441/16/2/246> doi: 10.3390/w16020246
- Yassin, M. A., Abba, S. I., Pradipta, A., Makkawi, M. H., Shah, S. M. H., Usman, J., ... Sammen, S. S. (2024). Advancing sdgs: Predicting future shifts in saudi arabia's terrestrial water storage using multi-step-ahead machine learning based on grace data. *Water*, 16(2). Descargado de <https://www.mdpi.com/2073-4441/16/2/246> doi: 10.3390/w16020246
- Ying, X. (2019, 2). An overview of overfitting and its solutions. *Journal of Physics: Conference Series*, 1168(2), 022022. Descargado de <https://dx.doi.org/10.1088/1742-6596/1168/2/022022> doi: 10.1088/1742-6596/1168/2/022022

- Yu, W., Ibrayim, M., y Hamdulla, A. (2023). Scene text recognition based on improved crnn. *Information*, 14(7). Descargado de <https://www.mdpi.com/2078-2489/14/7/369> doi: 10.3390/info14070369
- Zhang, J., Lu, Z., Li, C., Lei, G., Yu, Z., y Li, K. (2024, August). Estimation of groundwater-level changes based on grace satellite and gldas assimilation data in the songnen plain, china. *Hydrogeology Journal*, 32(5), 1495–1509. Descargado de <https://doi.org/10.1007/s10040-024-02815-w> doi: 10.1007/s10040-024-02815-w
- Zhang, Z., y Dong, Y. (2020). Temperature forecasting via convolutional recurrent neural networks based on time-series data. *Complexity*, 2020(1), 3536572. Descargado de <https://onlinelibrary.wiley.com/doi/abs/10.1155/2020/3536572> doi: <https://doi.org/10.1155/2020/3536572>
- Zihlmann, M., Perekrestenko, D., y Tschannen, M. (2017). Convolutional recurrent neural networks for electrocardiogram classification. En *2017 computing in cardiology (cinc)* (pp. 1–4).
- Zlotnicki, V. (2020). *An earth system data record of changes in earth masses from grace, champ and other satellites*. Distributed by NASA's Physical Oceanography Distributed Active Archive Center (PO.DAAC). Descargado de [NASAgrace.unl.edu](https://nasa-grace.unl.edu)
- Zowam, F. J., y Milewski, A. M. (2024). Groundwater level prediction using machine learning and geostatistical interpolation models. *Water*, 16(19). Descargado de <https://www.mdpi.com/2073-4441/16/19/2771> doi: 10.3390/w16192771
- Zuo, Z., Shuai, B., Wang, G., Liu, X., Wang, X., Wang, B., y Chen, Y. (2015, 6). Convolutional recurrent neural networks: Learning spatial dependencies for image representation. En *Proceedings of the ieee conference on computer vision and pattern recognition (cvpr) workshops*.
- Álvarez, M., y Antonio, J. (2021). *Coloquio internacional: Soluciones basadas en la naturaleza para la gestión hídrica*. <https://www.gob.mx/imta/articulos/coloquio-internacional-soluciones-basadas-en-la-naturaleza-para-la-gestion-hidrica>. Instituto Mexicano de Tecnología del Agua. (Accedido el 10 de agosto de 2024)
- Úrsula Oswald. (2011). *Retos de la investigación del agua en México*. <https://agua.org.mx/wp-content/uploads/2017/06/retos-de-la-investigaci%C3%B3n-del-agua-en-mexico.pdf>. (a Red Temática del Agua, Conacyt (Retac), AFES-Press)