



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO®



Instituto Tecnológico de Toluca

**“ESTIMACIÓN DE OXÍGENO DISUELTO A PARTIR DE CUATRO PARÁMETROS
FISICOQUÍMICOS, EN CUERPOS DE AGUA EN EL ESTADO DE MÉXICO,
MEDIANTE REDES NEURONALES ARTIFICIALES”**

TESIS

**QUE PARA OBTENER EL GRADO DE DOCTORA
EN CIENCIAS AMBIENTALES**

**PRESENTA:
M.C.I.A. ANA IVETTE JATER RUIZ
No. CONTROL:
D22280263**

**DIRECTOR DE TESIS:
DR. FRANCISCO JAVIER ILLESCAS MARTÍNEZ**

**CODIRECTOR:
DR. ROBERTO ALEJO ELEUTERIO**

METEPEC, ESTADO DE MÉXICO, ENERO DE 2026.



Educación
Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO



Instituto Tecnológico de Toluca
División de Estudios de Posgrado e Investigación

Metepec, Edo. de México, 09/Diciembre/2025
DEPI-3200-670/2025


ANA IVETTE JATER RUIZ
CANDIDATA AL GRADO DE DOCTORA
EN CIENCIAS AMBIENTALES

PRESENTE

De acuerdo con los Lineamientos para la Operación de los Estudios de Posgrado en el Tecnológico Nacional de México y las disposiciones en este Instituto, habiendo cumplido con todas las indicaciones que la Comisión Revisora realizó con respecto a su Trabajo de Tesis Titulado: "ESTIMACIÓN DE OXÍGENO DISUELTO A PARTIR DE CUATRO PARÁMETROS FÍSICOQUÍMICOS, EN CUERPOS DE AGUA EN EL ESTADO DE MÉXICO, MEDIANTE REDES NEURONALES ARTIFICIALES", la División de Estudios de Posgrado e Investigación de este Instituto, concede la Autorización para que proceda al envío del trabajo final vía correo Institucional.

Sin más por el momento, quedo de usted.

ATENTAMENTE
Excelencia en Educación Tecnológica
"Educación, integridad y ciencias"


JORGE SÁNCHEZ JAIME
JEFE DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN

 **Educación**
Secretaría de Educación Pública

 **TECNOLÓGICO NACIONAL DE MÉXICO**

INSTITUTO TECNOLÓGICO DE TOLUCA
DIVISIÓN DE ESTUDIOS DE POSGRADO E
INVESTIGACIÓN

ccp. Archivo
JSj/mcdl



2025
Año de
La Mujer
Indígena

Av. Tecnológico S/N, Col. Agrícola Bellavista, Metepec, Edo. de México,
C.P. 52149, Tels. Dirección: 7222087205, Conmut.: 7222087200
e-mail: info@toluca.tecnm.mx | tecnm.mx | toluca.tecnm.mx





Instituto Tecnológico de Toluca
División de Estudios de Posgrado e Investigación


Metepec, Edo. de México, 09/Diciembre/2025
DEPI-3200-669/2025

DR. JORGE SÁNCHEZ JAIME
**JEFE DE LA DIVISIÓN DE ESTUDIOS DE POSGRADO
E INVESTIGACIÓN**


P R E S E N T E

Por este medio comunicamos a usted que la comisión Revisora designada para analizar la Tesis denominada **"ESTIMACIÓN DE OXÍGENO DISUELTO A PARTIR DE CUATRO PARÁMETROS FÍSICOQUÍMICOS, EN CUERPOS DE AGUA EN EL ESTADO DE MÉXICO, MEDIANTE REDES NEURONALES ARTIFICIALES"**, que como parte de los requisitos para obtener el grado académico de Doctor en Ciencias Ambientales presenta el **C. ANA IVETTE JATER RUIZ** con número de control **D22280263** para sustentar el acto de Recepción Profesional, ha dictaminado que dicho trabajo reúne las características de contenido y calidad para proceder a la impresión del mismo.


A T E N T A M E N T E



DR. FRANCISCO JAVIER ILLESCAS MARTÍNEZ
DIRECTOR DE TESIS


DR. ROBERTO ALEJO ELEUTERIO
CODIRECTOR DE TESIS


DR. FEDERICO DEL RAZO LÓPEZ
REVISOR DE TESIS




DRA. MARIA SONIA MIREYA MARTÍNEZ GALLEGOS
REVISORA DE TESIS


DRA. ESTEFANIA MARTÍNEZ TAVERA
REVISORA DE TESIS


DR. VICENTE GARCÍA JIMÉNEZ
REVISOR DE TESIS

ccp. Archivo
JSJ/mccl



2025
Año de
**La Mujer
Indígena**

Av. Tecnológico S/N, Col. Agrícola Bellavista, Metepec, Edo. de México,
C.P. 52149, Tels. Dirección: 7222087205, Conmut.: 7222087200
e-mail: info@toluca.tecnm.mx | toluca.tecnm.mx



Agradecimientos

Esta tesis es el fruto de un largo y exigente recorrido. En primer lugar, agradezco a Dios, por ser la fuente inagotable de fortaleza, sabiduría y esperanza en cada paso de este camino. Gracias por acompañarme en los momentos de duda, darme serenidad en las dificultades y alegría en los logros.

Durante este trayecto, quiero agradecer su apoyo a mis hijos; Lucio y Sofía, gracias por ser mi motor diario y la inspiración más profunda para continuar. A mi madre, a Jesús y a sus abuelos paternos de mis hijos, les agradezco profundamente por su apoyo incondicional.

A mis hermanos Monse, Victor y Jonathan; mis amigas Sandra, Lidia, Diana y a mi prima Lorena. A mis compañeros del laboratorio SLeIA: Francisco, Daniel y Josimar, mi gratitud por su colaboración y compañerismo. A cada uno de ustedes, les expreso mi más sincero agradecimiento por estar presentes en los momentos clave y brindarme fortaleza cuando más lo necesité.

En el ámbito profesional, deseo expresar mi más sincero reconocimiento al Dr. Francisco Javier Illescas Martínez y al Dr. Roberto Alejo Eleuterio, quienes fueron pilares fundamentales en el inicio, desarrollo y dirección de esta tesis y a los Dres. y Dras. que conforman mi comité. Su guía experta, compromiso constante y orientación académica fueron decisivos para llevar este trabajo a buen término. Asimismo, extendiendo un agradecimiento especial a la Dra. Rosa María Valdovinos Rosas, cuyo apoyo y acompañamiento fueron clave para la consolidación final de esta tesis. Su disposición y aportes puntuales enriquecieron significativamente el resultado final del documento.

Por último, pero no menos importante debo agradecer a las instituciones que me han apoyado para realizar mis estudios de doctorado: al Instituto Tecnológico de Toluca, a la Facultad de Ingeniería de la UAEMex por permitirme realizar la estancia y a la SECIHTI, antes CONAHCyT por la beca con número de CVU 1010964.

Dedicatoria

A la versión de mí misma que, sin una formación previa en química ni en sistemas computacionales, asumió con decisión y valentía el desafío académico que esta investigación implicó. A la mujer que, desempeñándose como madre de tiempo completo, logró conciliar sus múltiples responsabilidades, superar barreras y mantenerse firme frente a la adversidad. Este trabajo no solo representa un logro académico, sino también un testimonio de perseverancia, resiliencia y compromiso con el desarrollo personal y profesional.

Resumen

En la actualidad, las aguas superficiales, es decir, aquellas aguas que se encuentran sobre la superficie terrestre como ríos, lagos, presas, lagunas y arroyos, están expuestas a la contaminación provocando el deterioro de estas fuentes, por consiguiente, resulta esencial analizar la calidad del agua mediante diferentes parámetros ambientales. Entre estos, el oxígeno disuelto (OD) es un parámetro vital para el monitoreo y mantenimiento de cuerpos de agua. Factores como la temperatura, el pH y la conductividad eléctrica influyen directamente en la concentración de OD. Además, estas variables facilitan su modelado predictivo, lo que permite optimizar los recursos y reducir los costos asociados con su monitoreo continuo a lo largo del tiempo. Una opción viable es utilizar las redes neuronales artificiales (RNA), las cuales han experimentado un incremento en su uso y capacidad para clasificar imágenes y predecir tendencias, entre otras aplicaciones. En este contexto, se están utilizando cada vez más para predecir parámetros críticos de la calidad del agua, como el OD. Este estudio comparó 7 arquitecturas de RNA, mostrando superioridad frente a 9 modelos clásicos de regresión. Para este análisis, se utilizaron datos provenientes del UCI Machine Learning Repository que contiene información de 37 áreas geográficas. Los resultados experimentales muestran que la red MLP obtuvo mejores resultados que los modelos de clásicos de regresión. Los datos utilizados en este estudio resultan altamente relevantes, ya que permitirán generar modelos predictivos con potencial aplicación en los cuerpos de agua del Estado de México. Dado que los cuerpos de agua de la región presentan problemáticas similares en términos de variabilidad ambiental y presión antropogénica, los modelos desarrollados a partir de los datos del UCI Machine Learning Repository pueden constituir una herramienta eficaz para el análisis, monitoreo y apoyo en la toma de decisiones orientadas a la gestión sostenible de los recursos hídricos.

Abstract

Currently, surface waters those found on the Earth's surface such as rivers, lakes, reservoirs, lagoons, and streams are exposed to pollution, leading to the deterioration of these sources. Consequently, it is essential to analyze water quality using various environmental parameters. Among these, dissolved oxygen (DO) is a vital parameter for monitoring and maintaining water bodies. Factors such as temperature, pH, and electrical conductivity influence DO concentrations. Moreover, these variables enhances predictive modeling, enables the optimization of resources and reduces the associated costs with continuous onitoring over time. Among others a viable option is the use of artificial neural networks (ANNs), which have seen increasing application and capability in tasks such as image classification and trend predictions. In this context, they are increasingly used to predict critical water quality parameters, such as DO. This study compared seven ANN architectures, demonstrating superiority over eight classical regression models. For this analysis, data from the UCI Machine Learning Repository, containing information from 37 different geographic areas was utilized. The experimental results demonstrated that the achieved MLP had a better performance than the classical regression models. Since the water bodies in the region present similar issues in terms of environmental variability and anthropogenic pressure, the models developed from the data in the UCI Machine Learning Repository can serve as an effective tool for analysis, monitoring, and supporting decision-making aimed at the sustainable management of water resources.

Índice general

1. Introducción	1
1.1. Planteamiento del Problema	3
1.2. Objetivos	4
1.2.1. Objetivo general.....	4
1.2.2. Objetivos específicos	4
1.3. Hipótesis.....	4
1.4. Justificación	5
2. Estado del arte	7
3. Marco Teórico	13
3.1. Estudio del agua	13
3.1.1. Parámetros fisicoquímicos de calidad del agua	14
3.1.1.1. Oxígeno Disuelto (OD)	15
3.1.1.2. Potencial de hidrógeno (pH)	16
3.1.1.3. La conductividad eléctrica (CE)	16
3.1.1.4. La temperatura	17
3.2. Redes Neuronales.....	19
3.2.1. Sistema neuronal biológico humano vs Sistema neuronal artificial	19

ÍNDICE GENERAL

3.2.2.	Topología de RNA	20
3.2.3.	Modelos de RNA utilizados	25
3.2.3.1.	Perceptrón Multicapa (MLP)	25
3.2.3.2.	Densa	26
3.2.3.3.	Feedforward Simple	26
3.2.3.4.	Redes Neuronales Recurrentes (RNR)	27
3.2.3.5.	Long Short-Term Memory (LSTM)	27
3.2.3.6.	Las redes neuronales Recurrentes Gated Recurrent Units (GRU)	28
3.2.3.7.	Transformer	28
3.3.	Métodos de regresión	29
3.3.1.	Regresión Lineal Múltiple	29
3.3.2.	Regresión Ridge	30
3.3.3.	Regresión Lasso	30
3.3.4.	Regresión Elastic Net	30
3.3.5.	Regresión Multi-task Lasso	31
3.3.6.	SAR I-1 (<i>Spatial Autoregressive Model</i>)	31
3.3.7.	Aprendizaje de Dependencia Autorregresiva Espacial I (SALD-I)	32
3.3.8.	Aprendizaje de Dependencia Autorregresiva Espacial II (SADL-II) .	32
3.3.9.	Modelo Lineal Generalizado (GLM)	32
3.4.	Métodos de validación	33
4.	Metodología	34
4.1.	Adquisición de datos	35
4.2.	Preparación de datos	35

4.2.1.	Limpieza de los datos	36
4.3.	Transformación de datos.....	36
4.3.1.	Transpuesta de los datos.....	37
4.3.2.	La selección de características	38
4.3.3.	Normalización	38
4.4.	Configuración de modelos	39
4.4.1.	Las RNA.....	40
4.4.2.	Los modelos de regresión	44
4.5.	Evaluación del modelo.....	44
4.5.1.	Coeficiente de determinación (R^2)	44
4.6.	Desempeño del Modelo y Prueba Estadística Significativa.....	45
5.	Resultados	47
5.1.	Resultados de coeficiente de determinación (R^2)	47
5.2.	Resultados de los Rankings promedio de los Algoritmos (Friedman)	51
5.3.	Resultados de los algoritmos en matriz de puntos (Holm and Shaffer).....	55
6.	Conclusiones y recomendaciones	63
6.1.	Conclusiones	63
6.2.	Recomendaciones	66
	Referencias.....	67

Índice de figuras

3.1.	Comparativo de neurona biológica y neurona artificial.....	19
3.2.	Partes de una neurona artificial	20
3.3.	Estructura de red neuronal artificial multicapas	21
3.4.	Estructura de la red neuronal artificial recurrente	21
3.5.	Red neuronal monocapa	22
3.6.	Red neuronal multicapa.....	22
4.1.	Diagrama de flujo para el desarrollo del proyecto	34
5.1.	Resultados de R^2 en OD Máximo de las diferentes RNA y MR	49
5.2.	Resultados de R^2 en OD Medio de las diferentes RNA y MR	50
5.3.	Resultados de R^2 en OD Mínimo de las diferentes RNA y MR.....	51
5.4.	Resultados de los Rankings promedio de los Algoritmos en OD Máximo de las diferentes RNA y MR	53
5.5.	Resultados de los Rankings promedio de los Algoritmos en OD Medio de las diferentes RNA y MR	54
5.6.	Resultados de los Rankings promedio de los Algoritmos en OD Mínimo de las diferentes RNA y MR	55
5.7.	Resultados de algoritmos en matriz de puntos (Holm and Shaffer) de las RNA y modelos de regresión en nivel de OD máximo.....	56
5.8.	Resultados de algoritmos en matriz de puntos (Holm and Shaffer) de las RNA y modelos de regresión en nivel de OD medio.....	57

5.9.	Resultados de algoritmos en matriz de puntos (Holm and Shaffer) de las RNA y modelos de regresión en nivel de OD mínimo	58
5.10.	Resultados cualitativos de predicción de los dos modelos con mejor desempeño, MLP y LRM, para los niveles mínimo de oxígeno disuelto	59
5.11.	Resultados cualitativos de predicción de los dos modelos con mejor desempeño, MLP y LRM, para los niveles medio de oxígeno disuelto	60
5.12.	Resultados cualitativos de predicción de los dos modelos con mejor desempeño, MLP y LRM, para los niveles máximo de oxígeno disuelto	61

Índice de tablas

3.1. Comparación del grado de conectividad en distintos tipos de redes neuronales	24
4.1. Configuración de modelos de diferentes tipos de RNA.....	43

Capítulo 1

Introducción

El análisis de la calidad del agua ha adquirido una relevancia sin precedentes. En la actualidad, es un tema de vital importancia, dado que el acceso a agua limpia constituye un pilar fundamental para salvaguardar la salud humana y el bienestar del ecosistema, además de ser uno de los Objetivos de Desarrollo Sostenible de la ONU ([Koncagül, Connor, y Abete, 2024](#)). La problemática de la contaminación del agua, ya sea de origen natural o provocado por actividades antropogénicas, plantea desafíos significativos en la gestión y conservación de este recurso invaluable ([Díaz, 2023](#)). La evaluación de los parámetros fisicoquímicos del agua desempeña un papel crucial en la determinación de su calidad, así como la detección temprana de posibles riesgos ambientales que podrían derivar de su deterioro.

En los últimos años, la innovación tecnológica en el ámbito del análisis de la calidad del agua no solo ha mejorado la precisión de las mediciones, sino que también ha agilizado significativamente los procesos de su monitoreo ([Zerpa, 2025](#)). Por ejemplo, ([García y cols., 2023](#)) comentan que el aprendizaje automático (ML) optimiza la gestión del agua al mejorar su calidad, distribución y detección de fugas. Un estudio sobre 1,087 artículos destaca cuatro aplicaciones clave del monitoreo del agua: a) detección de contaminantes, b) predicción de niveles, c) detección de fugas y d) evaluación de calidad. Además, las redes neuronales convolucionales (RNC) y el modelo Gradient Tree Boosting (GTB) han demostrado ser eficaces en la predicción de aguas subterráneas y

niveles de riego, resaltando el impacto positivo del Aprendizaje Automático (en inglés Machine Learning) en la infraestructura hídrica.

Como se puede observar, la Inteligencia Artificial (IA) se ha consolidado como un campo que ofrece diversas alternativas para resolver problemas relacionados con el procesamiento de información. Entre los algoritmos más empleados destacan las Redes Neuronales Artificiales (RNA). Se tratan de modelos matemáticos, que son inspirados en el funcionamiento del cerebro humano. Estos modelos están diseñados para reconocer patrones, realizar predicciones y resolver problemas complejos mediante su entrenamiento con grandes cantidades de datos. La implementación de sistemas automatizados de recolección de datos y la capacidad de procesamiento rápido ofrecida por las RNA ha mejorado la eficiencia en la evaluación de los recursos hídricos. Esta revolución tecnológica no solo impulsa la capacidad predictiva, sino que facilita la identificación temprana de contaminantes emergentes y anomalías en los parámetros fisicoquímicos del agua.

En este contexto, la sinergia entre la tecnología y la conservación ambiental se revela como un elemento clave para enfrentar los desafíos actuales en la preservación de la calidad del agua. Este enfoque integral no solo mejora la capacidad predictiva del modelo, sino que también proporciona una visión más completa y detallada de la calidad de los cuerpos de agua. Por lo antes mencionado, en esta tesis se desarrollan modelos de RNA para mejorar la predicción de parámetros fisicoquímicos del agua, teniendo como enfoque principal el análisis de los niveles de oxígeno disuelto en el agua, con el fin de comprobar como se comporta este parámetro de acuerdo con los modelos que se trabajaron en este proyecto de investigación.

1.1. Planteamiento del Problema

El oxígeno disuelto (OD) es un parámetro esencial para evaluar la calidad del agua y la salud de los ecosistemas acuáticos, ya que influye directamente en la biodiversidad y el equilibrio ecológico de cuerpos de agua como lagos, ríos y presas, especialmente en regiones con alta actividad humana, como el Estado de México. Los niveles inadecuados de OD pueden desencadenar eventos críticos como la muerte de organismos acuáticos, alteración de la biodiversidad, degradación ambiental y proliferación de organismos anaeróbicos, lo que favorece la eutrofización y deteriora la calidad del agua (Tavera-Quiroz, Rosso-Pinto, Hernández, Pinto, y Canales, 2023). Además, la falta de OD adecuado presenta riesgos para la salud humana, al comprometer las fuentes de agua potable y afectar actividades económicas como la pesca y el turismo. Sin embargo, medir el OD de manera precisa y económica sigue siendo un desafío, principalmente por el tiempo requerido y la necesidad de equipos especializados. No obstante, cuando se cuenta con instrumentos para mediciones *in situ*, este proceso resulta más accesible y eficiente. Actualmente, la medición directa del OD en cuerpos de agua representa un reto debido a las demandas de recursos, la necesidad de equipos especializados y el tiempo que implica (Dunigan y Ferguson, 2024).

Sin embargo, el OD presenta una relación comprobada con parámetros fisicoquímicos como el pH, la temperatura y la conductividad eléctrica, los cuales son más accesibles de medir. Esto plantea el problema de cómo aprovechar estos parámetros más simples para estimar de manera precisa el OD, utilizando herramientas matemáticas y tecnológicas avanzadas. En este sentido, surge la necesidad de utilizar modelos más efectivos para dicha estimación. Las RNA se perfilan como opciones prometedoras, pero su desempeño aún debe ser evaluado y comparado con modelos tradicionales, como los de regresión lineal y no lineal.

1.2. Objetivos

1.2.1. Objetivo general

Analizar y estudiar la efectividad de redes neuronales artificiales (RNA) con aprendizaje profundo para la predicción de oxígeno disuelto (OD) en agua dulce a través de parámetros fisicoquímicos tales como pH, conductividad y temperatura.

1.2.2. Objetivos específicos

1. Determinar los parámetros de los modelos de RNA que mejor ajusten los datos estudiados para su correcto funcionamiento en la predicción de oxígeno disuelto en cuerpos de agua dulce.
2. Evaluar la efectividad de los resultados obtenidos a través de métricas como el coeficiente de determinación (R^2).
3. Establecer, cuando menos, tres modelos de redes neuronales artificiales (RNA) para la predicción del oxígeno disuelto en cuerpos de agua dulce a partir de los valores de pH, temperatura y conductividad.
4. Comparar los resultados obtenidos con los existentes que se hayan encontrado en el estado del arte para evaluar la viabilidad del ajuste de los datos al modelo, proporcionando una medida de la variación de los datos reales y los datos de predicción del mismo.

1.3. Hipótesis

Utilizando redes neuronales artificiales y con aprendizaje profundo se obtendrá una efectividad del coeficiente de determinación (R^2) superior al 80% en la predicción del oxígeno disuelto (OD) en cuerpos de agua utilizando algunos parámetros fisicoquímicos, tales como: pH, temperatura y conductividad.

1.4. Justificación

Los parámetros fisicoquímicos del agua son fundamentales en la evaluación y gestión de los recursos hídricos, la protección de la salud humana y los ecosistemas acuáticos. Estos ayudan a determinar la disponibilidad y la calidad del agua en una región, lo que es crucial para planificar el uso y la conservación de este recurso vital. Los parámetros fisicoquímicos del agua, como el OD, el pH, la conductividad y la temperatura, son indicadores clave de las características del agua, ya que proporcionan información valiosa para sus diversos usos, como el consumo humano, la agricultura, la industria, entre otros ([Kubitza, 2025](#)).

Diversos estudios, incluidos datos del Instituto Nacional de Estadística y Geografía (INEGI), señalan que más del 70% de los cuerpos de agua en México están contaminados. A nivel mundial, más del 80% de las aguas residuales se vierten en ríos y océanos sin recibir tratamiento, lo que contribuye a la degradación de los ecosistemas acuáticos y la pérdida de biodiversidad ([Instituto Nacional de Estadística y Geografía \(INEGI\), 2021](#)). Además, se estima que el 70% del agua dulce en el planeta está contaminada, representando un desafío crítico para la sostenibilidad del recurso hídrico y la seguridad alimentaria global ([Arreguín-Cortés, López-Pérez, y Cervantes-Jaimes, 2020](#)).

En la actualidad el uso de tecnologías avanzadas ha revolucionado la forma en que se aborda la predicción y el análisis de parámetros ambientales críticos; las redes neuronales artificiales se han considerado modelos destacados por su eficacia al predecir resultados, reconociendo patrones complejos en un conjunto de datos. Las redes pueden aprender y modelar los resultados de pruebas fisicoquímicas; aquellas han demostrado ser una herramienta que proporciona mejores resultados de estimación de calidad en cuerpos de agua dulce en comparación con los métodos tradicionales de muestreo, ya que ofrecen una alternativa para minimizar costos y tiempo en las actividades de muestreo y de laboratorio para obtener dichos resultados ([Guo, Chen, y Teo, 2024](#)).

Es por esta razón que en este trabajo se propone utilizar técnicas de inteligencia artificial, en específico redes neuronales para determinar el resultado de OD, utili-

zando un modelo de aprendizaje automático que pueda predecir su nivel. Con esta herramienta se pretende ofrecer un resultado más rápido y preciso. Cabe señalar que, aunque existen equipos que permiten medir el OD directamente en el lugar del muestreo *in situ*, los métodos convencionales requieren equipos especializados de laboratorio y el análisis de las muestras en un periodo menor a ocho horas para evitar la alteración de los resultados. Estos procedimientos demandan tiempo, materiales y recursos técnicos, lo que puede representar una limitación en laboratorios que no cuentan con equipos para realizar mediciones *in situ*. Debido a la falta de registros confiables sobre la calidad del agua en el Estado de México, se utilizaron datos del UCI Machine Learning Repository. Variables fisicoquímicas como temperatura, pH y conductividad eléctrica, que influyen en el oxígeno disuelto, no están documentadas de manera continua en la región, lo que dificulta crear modelos predictivos robustos con información local. Por ello, el uso de un repositorio validado permite desarrollar y evaluar modelos con una base metodológica sólida y replicable, cuyos resultados pueden servir como referencia para estudios futuros.

Capítulo 2

Estado del arte

Las RNA son modelos computacionales inspirados en el cerebro humano que han demostrado una notable capacidad para aprender y generalizar a partir de datos complejos. Gracias a su arquitectura se han considerado como herramientas eficaces incluyendo el estudio del agua. En particular, su aplicación en la estimación de parámetros fisicoquímicos en cuerpos de agua ha ganado relevancia, ya que permiten predecir con precisión el oxígeno disuelto u otros parámetros.

En la referencia ([de Jesús, Guadalupe-Ramírez, Ambriz-Polo, y López-González, 2023](#)) se propone una Estrategia de Muestreo Dinámico Selectivo (EMDS) para abordar el problema del desequilibrio de clases. Seleccionando de manera dinámica las muestras más representativas durante el entrenamiento de una red neuronal, priorizando aquellas que se encuentran en una posición intermedia dentro del espacio de entrenamiento. Los algoritmos empleados incluyen SDSAS (Selective Dynamic Sampling Approach with Standard backpropagation), SDSAO (Selective Dynamic Sampling Approach with Optimized backpropagation) y DyS (Dynamic Sampling). Las pruebas estadísticas de Friedman e Iman-Davenport confirman diferencias significativas en los resultados, rechazando la hipótesis nula con un estadístico de 30.233 y un p-valor de 2.588×10^{-80} . Además, los resultados de las pruebas *post-hoc* no paramétricas de Holm y Shaffer resaltan las comparaciones en las que se identifican diferencias significativas.

En la referencia ([Abundez y cols., 2024](#)) los autores integraron un mecanismo de aprendizaje activo con un umbral dinámico μ en un modelo de redes neuronales profundas preentrenadas. Dicho mecanismo selecciona de manera eficiente las imágenes ambiguas, para ser validadas por un experto humano. Una vez clasificadas, el modelo se reentrena con estos datos. Se utilizaron las arquitecturas de DenseNet121, EfficientNetB0 y MobileNetV2, los experimentos mostraron una eficacia de 0.811 y 0.914. Al igual que en la detección de anomalías, la medición del OD variables por factores ambientales. Un enfoque basado en aprendizaje activo permitiría identificar estos puntos críticos, validarlos con mediciones confiables y reentrenar los modelos de predicción de OD, optimizando así la precisión de las estimaciones en condiciones ambientales complejas. De manera similar, el uso de arquitecturas eficientes como DenseNet121, EfficientNetB0 o MobileNetV2 podría facilitar modelos robustos para predicción de OD con menor requerimiento computacional y mejores resultados en situaciones de datos escasos o ruidosos.

En la referencia ([Luna, Guaminga, y Tixi, 2023](#)) exploraron el uso de redes neuronales como una alternativa moderna al análisis estadístico en modelos de regresión lineal, destacando que las redes neuronales no requieren cumplir con los supuestos teóricos tradicionales de los modelos estadísticos. En particular, el modelo MLP se compara con el modelo de regresión lineal, ya que la salida se obtiene aplicando una función de activación sobre una combinación lineal de pesos y variables de entrada. Los resultados indican que las predicciones del Perceptrón Multicapa lograron un R^2 superior, mostrando en un porcentaje de 61.2 de los conjuntos de datos simulados mejores valores de R^2 en comparación con la regresión lineal simple.

En la referencia ([Fernández y López, 2023](#)) los autores introducen QUILLAKEEL; una herramienta de software diseñada para evaluar algoritmos evolutivos aplicados a problemas variados de minería de datos, tales como regresión, clasificación y aprendizaje no supervisado. La herramienta integra algoritmos de aprendizaje evolutivo basados en enfoques como Pittsburgh, Michigan e IRL y permite combinar estos métodos con distintas técnicas de pre-procesamiento, facilitando un análisis integral de modelos de aprendizaje en comparación. KEEL fue desarrollado con un enfoque

tanto investigativo como educativo y se organiza en tres módulos principales: gestión de datos, diseño experimental con algoritmos evolutivos y un módulo educativo orientado a objetivos. Además, presentan dos estudios de caso para ejemplificar sus funcionalidades y el proceso de configuración experimental.

En la referencia ([Ubah y cols., 2021](#)) los autores evaluaron la calidad del agua del río Ele en Nnewi, Anambra, para predecir un Índice de Calidad del Agua Superficial (ICA) para un año mediante el uso de una RNA utilizando parámetros como el pH, los Sólidos Disueltos Totales (SDT), la Conductividad Eléctrica (CE) y el Sodio (Na). Utilizaron una arquitectura de MLP de avance y un algoritmo de entrenamiento de retropropagación supervisada de avance para el desarrollo de la red neuronal. Los resultados obtenidos mostraron que los TDS, CE y Na estaban por encima del estándar permisible de la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO) para riego durante las estaciones secas, mientras que el pH se mantuvo normal durante toda la temporada. Los valores de R^2 obtenidos del índice y la predicción de la calidad del agua fueron de 0.981 a 0.990 y 0.981 a 0.988 respectivamente, lo que indica un buen modelo y predicción.

En la referencia ([Kulisz y Kujawska, 2021](#)) los autores exploraron el uso de Redes Neuronales Artificiales (RNA) para predecir el Índice de Calidad del Agua (ICA) utilizando parámetros fisicoquímicos como TDS, cloruro, dureza total, nitrato y manganeso. Los datos fueron recogidos de cinco estaciones de monitoreo en el río Warta entre 2014 y 2018. Para el análisis preliminar, realizaron un estudio de correlación con el programa Statistica13. Posteriormente, la predicción del ICA se llevó a cabo mediante RNA en los entornos de MatLab y Simulink. Los mejores resultados se obtuvieron con redes de 5 neuronas en la capa oculta, alcanzando una alta precisión: un coeficiente de correlación de 0.9792 y, en los conjuntos de entrenamiento, prueba y validación, un RMSE de 0.6245. Estos resultados sugieren que las RNA pueden ser herramientas precisas y útiles para la simulación y monitoreo ambiental del agua.

En la referencia ([Yang, Moayedi, y Mosavi, 2021](#)), los autores evaluaron la capacidad de diferentes modelos de redes neuronales para predecir el oxígeno disuelto (OD) en ríos, un parámetro clave para la calidad del agua. Para ello, se desarrollaron tres

enfoques: el optimizador multiverso (OM), el algoritmo de agujero negro (AN) y la evolución compleja aleatoria (ECA), utilizando datos del río Klamath en Oregón (E.U.) recopilados entre 2015 y 2018. Con estos modelos se realizó la predicción del OD para el año 2019, obteniendo resultados favorables. Las redes basadas en AN y ECA presentaron configuraciones más simples que el modelo MVO; sin embargo, los análisis de error absoluto y el coeficiente de correlación de Pearson mostraron que OM y ECA alcanzaron un desempeño superior al BHA. En términos cuantitativos, las redes MLP combinadas con OM y ECA demostraron ser efectivas para la predicción del OD, logrando valores de Root Mean Squared Error (RMSE) de 1.3148, 1.4426 y 1.3304 para MLP-OM, MLP-AN y MLP-ECA, respectivamente, y Mean Absolute Error (MAE) de 0.9687, 1.0931 y 0.9929, lo que evidencia una buena precisión en la identificación del patrón de OD.

En la referencia ([Corona, Diez, y Morell, 2020](#)) los autores analizaron el uso de Redes Neuronales Artificiales (RNA), específicamente el modelo MLP, para estimar los índices de calidad del agua: Demanda Bioquímica de Oxígeno (DBO) y oxígeno disuelto (OD) en el río Tunjuelito, Colombia. Los resultados obtenidos se compararon con el modelo Generalized Multitarget Linear Regression (GMLR), utilizando el módulo de redes neuronales disponible en MATLAB. Para la configuración, se ajustó la MLP con una capa oculta equivalente a la capa de variables latentes del GMLR y se empleó un conjunto de 16 bases de datos públicas en la experimentación, aplicando el algoritmo de aprendizaje Levenberg-Marquardt backpropagation. La evaluación se realizó mediante el error cuadrático medio (MSE), donde el algoritmo GMLR obtuvo un valor de 0.286, mostrando una eficacia superior en comparación con el modelo de red neuronal PMC.

En la referencia ([González, Landassuri-Moreno, Hernández, y Albino, 2024](#)) los autores desarrollaron un modelo de red neuronal feedforward (FFNN) y un modelo de red neuronal de función de base radial (RBFNN) para predecir el nivel de OD a partir de la DBO y la demanda química de oxígeno (DQO) en el río Surma, Bangladesh. El desempeño de los modelos de las RNA se evaluó mediante el coeficiente de correlación (R), el MSE y el coeficiente de eficiencia (CE). Encontraron que el modelo

RNA era eficaz para estimar el OD en el río Surma. Los indicadores comparativos del RBFNN optimizado con valores de entrada de DBO y DQO para la predicción del OD en la matriz de prueba fueron $MSE = 0.465$, $CE = 0.905$ y $R = 0.904$, y para la matriz de validación fueron $MSE = 1.009$, $CE = 0.966$ y $R = 0.963$. Demostrando que los modelos de red neuronal ofrecen resultados consistentes y confiables.

En la referencia ([Guzmán-Ponce, Ferri, Sánchez-Garreta, y Marcial-Romero, 2022](#)) los autores presentaron un método novedoso de sobremuestreo dinámico que fusiona la técnica de sobremuestreo conocida como SMOTE con el algoritmo de retropropagación secuencial, este enfoque emplea el MSE de retropropagación para determinar automáticamente la tasa de sobremuestreo, utilizando solo las muestras de entrenamiento necesarias para mitigar el problema de desequilibrio de clases sin prolongar excesivamente el tiempo de entrenamiento de redes neuronales (RN). Los experimentos en quince conjuntos de datos multiclase con alto desequilibrio evidencian que el método propuesto, denominado MSEBPOS, es prometedor. En la técnica de sobremuestreo MSE con retropropagación (MSEBPOS y MSEBPOS+GGE) lograron una razón de tamaño inferior a 0.53, lo que implica un ahorro significativo en tiempo de cómputo y almacenamiento.

En la referencia ([Montero, Bastián, y Sanpablo, 2023](#)) los autores desarrollaron una plataforma web utilizando el servidor apache y resilient backpropagation como método de aprendizaje para la red MLP y una combinación entre el algoritmo de los k-emanes y el método de la matriz pseudoinversa para la Red RBFNN. Para la evaluación de las RNA utilizaron conjuntos de datos de diferentes características y cantidad de datos. Los resultados obtenidos en porcentaje de efectividad de los dos tipos de redes neuronales es de 95 % permitiendo que la plataforma importe los datos de entrenamiento y test de la red a partir de archivos delimitados por comas (CSV) y posterior a la ejecución de la simulación son desplegados los resultados obtenidos por la RNA para la utilización e integración de técnicas de inteligencia computacional en sistemas web. La ausencia de referencias a trabajos realizados en México puede deberse a que la aplicación de inteligencia artificial en la estimación de parámetros de calidad del agua es un campo reciente en México y los estudios locales no están

ampliamente publicados ni indexados en las bases consultadas.

Capítulo 3

Marco Teórico

3.1. Estudio del agua

El agua es un recurso esencial para la vida y para el desarrollo de las sociedades, ya que existe una relación directa entre el progreso humano y la demanda hídrica. Desde tiempos antiguos, las poblaciones se han establecido cerca de fuentes de agua, lo que con el tiempo provocó contaminación ([Raghavendra, 2024](#)). Según la Organización Mundial de la Salud y diversos organismos internacionales, la calidad del agua puede definirse como el estado en que se encuentra en relación con sus parámetros físicos, químicos y biológicos, ya sea en condiciones naturales o tras la intervención humana. Generalmente, esta calidad se determina comparando las características físicas y químicas de una muestra con normas o directrices establecidas. Con el avance de la civilización, las descargas de aguas residuales domésticas e industriales incrementaron la contaminación de ríos y lagos, deteriorando los ecosistemas acuáticos y afectando la calidad de los suelos circundantes. Esta problemática resalta la importancia de estudiar el agua, dado su papel esencial en los ecosistemas y en la vida humana. La disponibilidad y calidad del recurso influyen directamente en la salud, la agricultura, la industria y el equilibrio ambiental. Por ello, la evaluación de la calidad del agua se considera una tarea prioritaria dentro de la gestión sostenible de los recursos naturales. Este análisis permite identificar alteraciones en sus propiedades físicoquímicas y anticipar riesgos asociados a la contaminación. En el presente estudio, se analizaron

los niveles de oxígeno disuelto en tres rangos: máximo, medio y mínimo, con el objetivo de comprender mejor la condición del agua y su impacto sobre la biodiversidad acuática y los procesos ecológicos ([Gudiño-Sosa y cols., 2023](#)).

El análisis de la calidad del agua permite comprender los procesos que regulan su comportamiento y anticipar posibles riesgos para los ecosistemas y las actividades humanas. Los parámetros fisicoquímicos, como el OD, el pH, la temperatura y la conductividad eléctrica, son indicadores clave para caracterizar estas interacciones. El OD, por ejemplo, determina la capacidad del agua para sostener organismos aeróbicos y procesos metabólicos, mientras que el pH condiciona la disponibilidad de nutrientes y la toxicidad de ciertos compuestos. La temperatura afecta tanto la solubilidad del oxígeno como la velocidad de reacciones químicas, y la conductividad refleja la concentración de sales disueltas, lo que puede modificar la idoneidad del recurso para distintos usos. Analizar estos parámetros juntos ayuda a planificar cómo cuidar el agua y mantener el equilibrio de los ecosistemas ([Márquez, 2024](#)).

3.1.1. Parámetros fisicoquímicos de calidad del agua

La evaluación de la calidad en los cuerpos de agua se basa en el análisis de los parámetros fisicoquímicos, estos parámetros constituyen indicadores esenciales para evaluar la calidad del agua, ya que determinan su comportamiento químico y físico dentro del ecosistema. Los parámetros fisicoquímicos como el oxígeno disuelto (OD), la conductividad, la temperatura y el pH, ofrecen información clave sobre la composición química y las características físicas del agua ([Contreras, 2023](#)). Mientras que el OD, la conductividad y el pH son indicadores químicos, la temperatura es un parámetro físico. Estos factores están interrelacionados, ya que influyen en las reacciones químicas y en los procesos biológicos dentro del ecosistema acuático ([Chaves-Chaves, 2024](#)). Es importante entender cómo estos factores trabajan juntos, porque su interacción mantiene el equilibrio del agua y la vida que depende de ella. Si cambian, pueden afectar la cantidad de oxígeno y nutrientes, poner en riesgo a los organismos y reducir la calidad del agua. Conocer estas relaciones ayuda a cuidar el recurso ([Y. Zhao y Chen, 2025](#)). El análisis conjunto de estos parámetros permite identificar alteraciones en la

composición del agua, anticipar riesgos ambientales y establecer estrategias para la gestión sostenible del recurso.

3.1.1.1. Oxígeno Disuelto (OD)

El oxígeno disuelto (OD) es un factor determinante para la vida acuática, ya que se ve involucrado en la mayoría de los procesos químicos y biológicos que se llevan a cabo en el agua. El oxígeno disuelto resulta esencial para la respiración de organismos acuáticos, sino que también tiene influencia en la descomposición de materia orgánica y en la estabilidad química del agua. Cuando los niveles de OD disminuyen por debajo de lo óptimo, se generan condiciones hipóxicas o anóxicas que favorecen la proliferación de bacterias anaerobias, son producidos compuestos tóxicos como sulfuro de hidrógeno y amoníaco. El equilibrio del ecosistema puede verse alterado por estos cambios, una reducción de la biodiversidad y afectación la calidad del agua, la vuelve inadecuada para el consumo humano y para la vida acuática. En condiciones aeróbicas (con presencia de oxígeno), se favorece una mayor biodiversidad de especies, incluyendo los peces, que generalmente requieren concentraciones de OD superiores a 4 mg/L para sobrevivir ([Larance y McClain, 2025](#)). Esta relación queda determinado el comportamiento del parámetro analizado y se observa en la Ecuación 3.1:

$$OD = \frac{\sum OD_{pm}}{N_{pm}} \quad (\text{Ecuación 3.1})$$

donde OD_{pm} representa el oxígeno disuelto por punto de muestreo, pm representa punto de muestreo y N_{pm} es el número total de puntos de muestreo donde se tomó la medición ([Zhang, Li, y Wang, 2024](#)).

La concentración de OD está influenciada por factores externos, durante el día la fotosíntesis son incrementados los niveles de oxígeno, mientras que en la noche la respiración de los organismos pueden verse reducidos. Además, la presencia de contaminantes orgánicos se ve incrementado el consumo de oxígeno por parte de

3.1. ESTUDIO DEL AGUA

bacterias descomponedoras, lo que puede generar desequilibrios en el ecosistema.

Por ello, el monitoreo constante del OD es clave para detectar variaciones que indiquen contaminación o cambios en la dinámica natural del cuerpo de agua ([Dewangan y cols., 2024](#)).

3.1.1.2. Potencial de hidrógeno (pH)

El pH es un parámetro esencial para evaluar la calidad del agua, ya que mide la concentración de iones hidrógeno (H^+) presentes en la solución. Este valor se expresa en una escala que va de 0 a 14, donde un pH menor a 7 corresponde a condiciones ácidas, un pH igual a 7 indica neutralidad y un pH mayor a 7 señala condiciones alcalinas. Mantener el pH dentro de un rango adecuado es fundamental para la estabilidad de los ecosistemas acuáticos. El intervalo óptimo para la mayoría de las especies acuáticas se encuentra entre 6.5 y 8.5, ya que valores fuera de este rango pueden generar estrés fisiológico en peces, afectar la fotosíntesis de plantas acuáticas y alterar la actividad de microorganismos esenciales para los ciclos biogeoquímicos.

Cambios en el pH pueden modificar la solubilidad de metales pesados, como hierro, cobre o zinc, y alterar la forma química de compuestos tóxicos, afectando su biodisponibilidad ([Rios Marin, Pena Salamanca, y Benitez Benitez, 2021](#)). Variaciones en este parámetro pueden afectar la disponibilidad de nutrientes esenciales y alterar la toxicidad de ciertos compuestos, lo que influye directamente en la salud de los organismos acuáticos. Además, el pH está relacionado con otros factores como la temperatura y la concentración de dióxido de carbono, por lo que su monitoreo constante es clave para mantener la estabilidad del medio y prevenir desequilibrios que comprometan la calidad del agua.

3.1.1.3. La conductividad eléctrica (CE)

La conductividad eléctrica (CE) es un indicador clave de la calidad del agua, ya que refleja su capacidad para conducir corriente eléctrica, la cual depende directamente de la concentración de iones disueltos, principalmente sales como cloruros, sulfatos y carbonatos. Este parámetro permite estimar el grado de mineralización del agua y

puede evidenciar procesos naturales, como la disolución de rocas, o impactos antropogénicos, como descargas industriales y agrícolas. Valores elevados de CE suelen asociarse con contaminación por fertilizantes, aguas residuales o infiltración de lixiviados, mientras que niveles muy bajos pueden indicar aguas con baja capacidad tampón, susceptibles a cambios bruscos en su composición química. Además, la conductividad está estrechamente relacionada con la salinidad, lo que influye en la distribución de especies acuáticas y en la regulación osmótica de los organismos ([Solís-Castro, Zúñiga-Zúñiga, y Mora-Alvarado, 2018](#)).

La CE también puede variar según factores naturales como la temperatura y el caudal del agua, ya que el aumento de temperatura incrementa la movilidad iónica, elevando la conductividad. En ecosistemas acuáticos, este parámetro sirve como indicador indirecto de procesos como la evaporación, que concentra sales, o la mezcla de aguas con diferentes características químicas. Asimismo, la CE se utiliza en estudios de monitoreo para detectar cambios rápidos en la calidad del agua, ya que responde de manera inmediata a la incorporación de contaminantes disueltos, lo que la convierte en una herramienta útil para la gestión y control de recursos hídricos ([Dewangan y cols., 2024](#)).

3.1.1.4. La temperatura

La temperatura es otro factor determinante en la dinámica de los ecosistemas acuáticos, ya que regula la solubilidad de gases, la velocidad de reacciones químicas y la actividad metabólica de los organismos. Un incremento en la temperatura disminuye la solubilidad del oxígeno disuelto, lo que puede generar condiciones de hipoxia perjudiciales para especies sensibles. Asimismo, temperaturas elevadas aceleran la descomposición de materia orgánica, aumentando la demanda bioquímica de oxígeno (DBO) y favoreciendo la proliferación de microorganismos. Por el contrario, temperaturas muy bajas pueden ralentizar la actividad biológica y alterar la disponibilidad de nutrientes. Estos cambios térmicos pueden ser consecuencia de variaciones estacionales o de impactos humanos, como descargas térmicas provenientes de plantas industriales ([Yavuz, 2025](#)).

El análisis conjunto de estos parámetros permite comprender el estado de un cuerpo de agua y detectar posibles alteraciones causadas por actividades humanas o fenómenos naturales. Su monitoreo y modelado mediante herramientas tecnológicas avanzadas, como redes neuronales artificiales, facilita la toma de decisiones para la gestión y conservación de los recursos hídricos.

3.2. Redes Neuronales

El estudio del cerebro y su funcionamiento ha sido una fuente inagotable de inspiración para el desarrollo de las Redes Neuronales Artificiales (RNA). Desde los trabajos pioneros de Ramón y Cajal en 1911 ([De Castro y Merchán, 2016](#)), se ha comprendido que las neuronas biológicas son células especializadas del sistema nervioso encargadas de procesar y transmitir información mediante señales eléctricas y químicas. Estas neuronas se comunican a través de sinapsis, formando redes altamente interconectadas que posibilitan funciones cognitivas como el aprendizaje, la memoria y la toma de decisiones ([Schmidgall y cols., 2024](#)).

3.2.1. Sistema neuronal biológico humano vs Sistema neuronal artificial

El sistema nervioso humano opera a través de una extensa red de neuronas interconectadas que procesan y transmiten información. Cada neurona posee una estructura funcional clave: las dendritas, que actúan como canales de entrada al recibir estímulos; el soma, que funciona como centro de cómputo al integrar la información; y el axón, que transmite las señales procesadas hacia otras neuronas o células efectoras ([Ponce, 2024](#)). Como se puede observar en la Figura 3.1 se representa un comparativo de una neurona biológica y una neurona artificial.




Figura 3.1: Comparativo de neurona biológica y neurona artificial ([Márquez, 2024](#)).

3.2. REDES NEURONALES

En el campo de la IA, las RNA funcionan como sistemas de procesamiento distribuido, capaces de almacenar conocimientos obtenidos por experiencia y de utilizarlos en el futuro (Haykin, 2016). Como se puede observar en la Figura 3.2 se representan las partes de una neurona artificial:




Figura 3.2: Partes de una neurona artificial
(Chuchuca Alvarracin y Sicha Rodríguez, 2022) .

3.2.2. Topología de RNA

La arquitectura de las RNA varía según distintos criterios, lo que influye en su capacidad de aprendizaje y generalización para resolver problemas específicos (Goodfellow, Bengio, y Courville, 2016). En esta sección se analizarán las topologías de las RNA considerando la propagación de la señal, número de capas, grado de conectividad y conexiones entre neuronas y modularidad.

a. Propagación de la señal Las RNA pueden clasificarse según la dirección en la que se propagan las señales a través de sus neuronas:

a.1) Redes Feedforward:

La información fluye en una única dirección, desde la capa de entrada hasta la de salida, sin ciclos o retroalimentación (Bhogal y Singh, 2025). Como se puede ver la Figura 3.3 representa una RNA de múltiples capas.




Figura 3.3: Estructura de red neuronal artificial multicapas
(Yagawa y Oishi, 2021).

a.2) Redes Neuronales Recurrentes (RNR): Permiten la retroalimentación de información mediante conexiones entre neuronas de capas anteriores y posteriores, lo que las hace adecuadas para secuencias y datos temporales (Mienye, 2024) tal y como se puede observar la estructura de una RNR en la Figura 3.4.




Figura 3.4: Estructura de la red neuronal artificial recurrente
(Olabe, 2025)

b. Número de capas

La cantidad de capas en una RNA influye en su capacidad de abstracción y aprendizaje:

b.1) Las redes neuronales de capa única, como el perceptrón simple propuesto por Rosenblatt (Rosenblatt, 2021), se caracterizan por tener únicamente una capa de entrada y una capa de salida, sin capas ocultas intermedias. Esta estructura las

3.2. REDES NEURONALES

convierte en el tipo más básico de red.

En la Figura 3.5 se muestra un ejemplo de red neuronal monocapa. Su simplicidad permite una implementación y entrenamiento rápido.




Figura 3.5: Red neuronal monocapa
(Rodríguez-Sánchez, 2023)

b.2) Redes neuronales de múltiples capas Este tipo de redes incorporan varias capas ocultas, lo que permite modelar relaciones más complejas y resolver problemas no lineales (Rautaray, Agrawal, y Pandey, 2024). En la Figura 3.6 se puede observar el esquema de la Red neuronal multicapa, las cuales se caracterizan por flujos de información unidireccionales.




Figura 3.6: Red neuronal multicapa
(Rautaray y cols., 2024)

c. Grado de conectividad y conexiones entre neuronas

El grado de conectividad entre neuronas determina cómo fluye la información en una red neuronal ([Aggarwal, 2023](#)). Este concepto es clave para entender estructuras más complejas como las redes modulares ([Domínguez, 2025](#)), y las redes jerárquicas. En la Tabla 3.1 se puede observar una comparación del grado de conectividad en distintos tipos de redes neuronales.

3.2. REDES NEURONALES

Tabla 3.1: Comparación del grado de conectividad en distintos tipos de redes neuronales.

Tipo de RNA	Conectividad	Características
Multilayer Perceptron (MLP)	Totalmente conectada entre capas	Las neuronas de una capa están conectadas a todas las neuronas de la siguiente capa.
Feedforward simple	Con una sola capa oculta	No hay conexiones hacia atrás. Flujo unidireccional de información.
Densa	Cada neurona está conectada a todas las neuronas de la siguiente capa	Es un tipo de capa, no una arquitectura.
Recurrente	Conectividad hacia adelante y hacia atrás en el tiempo (memoria de pasos anteriores)	Las neuronas están conectadas entre sí dentro de la misma capa para mantener contexto temporal.
Long Short-Term Memory (LSTM)	Con puertas de control internas para manejar mejor la conectividad temporal	Mantiene conexiones recurrentes controladas con memoria a largo plazo.
Gated Recurrent Unit (GRU)	Con una arquitectura más simple y menos parámetros	Mantiene conectividad temporal, pero con menor complejidad computacional que LSTM.

3.2.3. Modelos de RNA utilizados

Los modelos seleccionados MLP, LSTM y GRU son arquitecturas ampliamente utilizadas en el aprendizaje profundo debido a su capacidad para resolver distintos tipos de problemas. El MLP resulta adecuado para tareas donde las relaciones entre variables son principalmente estáticas, mientras que las redes Feedforward simples se caracterizan por un flujo unidireccional de información sin conexiones hacia atrás, y las capas densas permiten una conectividad total entre neuronas de capas consecutivas. Por otro lado, las redes recurrentes, junto con sus variantes las redes LSTM y GRU son diseñadas para manejar dependencias temporales y secuenciales, lo que las hace ideales en contextos donde los datos presentan correlación en el tiempo. Estas arquitecturas se eligieron por su eficacia comprobada en predicción y modelado de series, así como por su flexibilidad para adaptarse a diferentes volúmenes y características de datos.

3.2.3.1. Perceptrón Multicapa (MLP)

Es un tipo de red feedforward que consta de al menos tres capas de neuronas. Cada neurona en una capa está completamente conectada a las neuronas de la siguiente capa ([Kruse, Mostaghim, Borgelt, Braune, y Steinbrecher, 2022](#)). Este tipo de red se entrena mediante el algoritmo de retropropagación del error, permitiendo ajustar los pesos w_{ij} y los sesgos b_j para minimizar el error en las salidas ([Aggarwal, 2023](#)).

El modelo matemático de la red MLP pretende que cada neurona en una capa reciba entradas x_i y las combine linealmente con pesos w_{ij} , la combinación lineal de estas entradas se expresa como se muestra en la ecuación 3.2:

$$z_j = \sum_{i=1}^n w_{ij} x_i + b_j \quad (\text{Ecuación 3.2})$$

En donde z_j representa la combinación lineal que realiza una neurona j .

3.2.3.2. Densa

La RNA Densa, al igual que el MLP, se conecta a todas las neuronas de la capa siguiente. Las redes completas se emplean principalmente en tareas de clasificación y regresión ([Géron, 2022](#)).

En el modelo matemático de la red Densa se multiplican las entradas x por la matriz de pesos W y se suman los sesgos b , utilizando una propagación hacia adelante, ([Bueno, 2019](#)) como se muestra en la ecuación 3.3:

$$\mathbf{h} = \sigma(W\mathbf{x} + \mathbf{b}) \quad (\text{Ecuación 3.3})$$

En donde σ representa la función de activación y $\mathbf{h}$ denota la salida de la capa densa.

3.2.3.3. Feedforward Simple

La Feedforward Simple es apropiada para problemas sencillos de clasificación y regresión, pero su capacidad es limitada en comparación con arquitecturas más sofisticadas ([Chollet, 2021](#)). En el modelo matemático de la red Feedforward Simple, la salida de la capa oculta se obtiene mediante una combinación lineal de las entradas y los pesos, a la que se le suma el sesgo ([Pajankar y Joshi, 2022](#)). La ecuación 3.4 representa la salida de la capa oculta, que sirve como entrada para la siguiente capa, mientras que la ecuación 3.5 muestra la salida final de la red:

$$\mathbf{h} = \sigma(W_1\mathbf{x} + \mathbf{b}_1) \quad (\text{Ecuación 3.4})$$

$$\mathbf{y} = \phi(W_2\mathbf{h} + \mathbf{b}_2) \quad (\text{Ecuación 3.5})$$

En donde, $\mathbf{y}$ representa el vector de salida final de la red Feedforward Simple y ϕ denota la función de activación de la capa de salida.

3.2.3.4. Redes Neuronales Recurrentes (RNR)

Estas redes presentan una arquitectura que es útil para modelar secuencias temporales y patrones dependientes del tiempo, crea un sistema de memoria en la red (Bishop y Bishop, 2024). El modelo matemático de la red RNR, se puede observar en las ecuaciones 3.6 que representa como se calcula el estado oculto en el tiempo t considerando la actual entrada x_t como el estado oculto anterior h_{t-1} . La combinación de estas influencias pasa a través de una función de activación σ y en la ecuación 3.7 representa la salida de la red en el tiempo t se obtiene al aplicar una función ϕ sobre la combinación lineal del estado oculto h_t y su sesgo b_y (Dhayalkar, 2025):

$$\text{Estado oculto: } h_t = \sigma(W_h x_t + U_h h_{t-1} + b_h) \quad (\text{Ecuación 3.6})$$

$$\text{Salida de la red: } y_t = \phi(W_y h_t + b_y) \quad (\text{Ecuación 3.7})$$

3.2.3.5. Long Short-Term Memory (LSTM)

Un ejemplo comúnmente utilizado de RNR en la actualidad es la red LSTM que es capaz de aprender y recordar dependencias a largo plazo en secuencias de datos. Su arquitectura se compone de unidades de retención de información llamadas “celdas de memoria”, las cuales están interconectadas mediante puertas que operan como reguladores para supervisar el flujo de información (Gülen, 2025). El modelo matemático de la LSTM se muestra en la ecuación 3.8, se puede apreciar las puertas de olvido, entrada, salida y actualización del estado (c_{t-1}) (Alcocer, Tello-Leal, y Alvarado, 2018).

$$(h_t, C_t) = \text{LSTM}(x_t, h_{t-1}, C_{t-1}; \theta) \quad (\text{Ecuación 3.8})$$

En donde $\text{LSTM}(\cdot)$ representa la función completa que realiza una celda LSTM, incluyendo las compuertas, x_t es el vector de entrada en el instante temporal t y

h_{t-1} es el estado oculto del paso anterior, que representa la memoria a corto plazo.

3.2.3.6. Las redes neuronales Recurrentes Gated Recurrent Units (GRU)

Son una versión mejorada de las RNR estándar, que emplean dos mecanismos principales: la puerta de actualización y la puerta de reinicio, las cuales permiten superar el problema del desvanecimiento del gradiente que ocurre en las RNA estándar ([Bustamante Freire, 2023](#)). El modelo matemático de la red GRU se muestra en la ecuación 3.9 que calcula una puerta de control que decide cuánto del estado anterior y de la nueva entrada se usará para actualizar la memoria.

$$\mathbf{z}_t = \sigma(W_z \mathbf{x}_t + U_z \mathbf{h}_{t-1} + b_z) \quad (\text{Ecuación 3.9})$$

En donde $\mathbf{x}_t$ es el vector de entrada en el instante temporal t , $\mathbf{h}_{t-1}$ es el estado oculto del paso anterior, W_z es la matriz de pesos asociada a la entrada, $\mathbf{x}_t$ para el cálculo de la puerta de actualización, U_z es la matriz de pesos asociada al estado oculto, $\mathbf{h}_{t-1}$ para la puerta de actualización y σ es la función sigmoide.

3.2.3.7. Transformer

Representan una arquitectura que incorpora un mecanismo de atención, el cual permite al modelo adaptarse y enfocarse dinámicamente en diferentes partes de la entrada según la relevancia de la información. Su arquitectura consta de múltiples capas, cada una con una capa de atención y una red completamente conectada ([Le, Wang, y Le, 2024](#)).

En la ecuación 3.10 se muestra cómo aprende a enfocar la atención en partes relevantes de la secuencia para cada posición, permitiendo capturar dependencias a largo plazo sin recurrir a mecanismos recurrentes como los utilizados en LSTM ([Gerber, 2025](#)).

$$\text{Attention}(Q, K, V) = \text{softmax} \left(\frac{QK^T}{d_k} \right) V \quad (\text{Ecuación 3.10})$$

En donde Q es la matriz de *queries*, K es la matriz de *keys*, V es la matriz de *values* y QK^T es el producto punto entre consultas y claves.

3.3. Métodos de regresión

Los métodos de regresión modelan relaciones lineales entre variables, siendo adecuados para problemas de menor complejidad y con un enfoque en la interpretabilidad y rapidez en el análisis. Estos modelos funcionan bien cuando la relación entre las variables es lineal o simple, y emplean técnicas de regularización para reducir el sobreajuste y simplificar los modelos ([Kronberger, Burlacu, Kommenda, Winkler, y Affenzeller, 2024](#)).

3.3.1. Regresión Lineal Múltiple

La regresión lineal múltiple es una extensión de la regresión lineal simple que permite modelar la relación entre una variable dependiente y dos o más variables independientes, usa una o varias variables explicativas para predecir el resultado de una variable respuesta ([Bevans, 2023](#)). La ecuación general de un modelo de regresión lineal múltiple se expresa de la siguiente forma en la Ecuación 3.11 en donde se define a Y como variable dependiente y X_p como variables independientes ([Carrasquilla-Batista y cols., 2016](#)).

$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_p X_p + c \quad (\text{Ecuación 3.11})$$

3.3. MÉTODOS DE REGRESIÓN

En donde β_p es el coeficiente asociado a la última variable predictora x_p en el modelo.

3.3.2. Regresión Ridge

Estos modelos son técnicas de regresión regularizada diseñadas para mejorar la generalización del modelo y evitar el sobreajuste cuando hay muchas variables explicativas o colinealidad. Incluyen penalizaciones (L_2 y L_1 , respectivamente), siguen siendo modelos lineales porque la penalización afecta únicamente los coeficientes (TailoredRead, 2025). La regresión Ridge introduce una penalización L_2 para reducir la magnitud de los coeficientes del modelo, evitando así el sobreajuste (Carrera y Montes Rojas, 2024). Queda representada en la Ecuación 3.12:

$$\min_{\beta} \sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^p \beta_j X_{ij})^2 + \lambda \sum_{j=1}^p \beta_j^2 \quad (\text{Ecuación 3.12})$$

En donde y_i es el valor observado de la variable dependiente para la observación i , β_0 es el intercepto del modelo y β_j el coeficiente asociado a la variable independiente X_j .

3.3.3. Regresión Lasso

La regresión Lasso introduce una penalización L_1 que puede hacer que algunos coeficientes sean exactamente 0, seleccionando así las variables más importantes (Carrera y Montes Rojas, 2024), como podemos observar en la ecuación 3.13.

$$\min_{\beta} \sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^p \beta_j X_{ij})^2 + \lambda \sum_{j=1}^p |\beta_j| \quad (\text{Ecuación 3.13})$$

En donde y_i es el valor observado de la variable dependiente para la observación i , β_0 el intercepto del modelo, β_j el coeficiente asociado a la variable independiente X_j y X_{ij} el valor de la variable independiente j para la observación i .

3.3.4. Regresión Elastic Net

Ambos modelos son técnicas de regresión regularizada que combinan o extienden ideas de los modelos Ridge y Lasso, pero tienen características y aplicaciones distintas,

3.3. MÉTODOS DE REGRESIÓN

combina las penalizaciones $L1$ (Lasso) y $L2$ (Ridge) para aprovechar lo mejor de ambos

enfoques (Dingsen, 2024), como se observa en la ecuación 3.14.

$$\min_{\beta} \sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^p \beta_j X_{ij})^2 + \lambda_1 \sum_{j=1}^p |\beta_j| + \lambda_2 \sum_{j=1}^p \beta_j^2 \quad (\text{Ecuación 3.14})$$

En donde X_{ij} es el valor de la variable independiente j para la observación i , p el número de predictores, λ_1 el parámetro de regularización L1 (Lasso) y λ_2 el parámetro de regularización L2 (Ridge), la magnitud de los coeficientes es reducida mediante este procedimiento.

3.3.5. Regresión Multi-task Lasso

El modelo Multi-task Lasso resulta adecuado cuando se manejan múltiples tareas de predicción relacionadas y se busca compartir información entre ellas, mejorando así la eficiencia y precisión (Malenica y cols., 2023). Como se muestra en la ecuación 3.15:

$$\min_n \sum_{i=1}^n \sum_{k=1}^m (y_{ik} - \beta_0 - \sum_{j=1}^p \beta_{jk} X_{ij})^2 + \lambda \sum_{j=1}^p |\beta_{jk}| \quad (\text{Ecuación 3.15})$$

En donde $\sum_{i=1}^n \sum_{k=1}^m (y_{ik} - \beta_0 - \sum_{j=1}^p \beta_{jk} X_{ij})^2$ la suma de los errores al cuadrado para todas

las respuestas, $\lambda \sum_{j=1}^p |\beta_{jk}|$ la penalización L1 que favorece la selección de variables

en todas las respuestas.

3.3.6. SAR I-1 (Spatial Autoregressive Model)

3.3. MÉTODOS DE REGRESIÓN

El modelo autorregresivo espacial (SAR I-1) se define como un econométrico que incorpora dependencias espaciales en los datos. Se utiliza para modelar fenómenos donde las observaciones están influenciadas por ubicaciones cercanas ([Pineda-Ríos](#),

3.3. MÉTODOS DE REGRESIÓN

[Giraldo, y Porcu, 2019](#)). Matemáticamente, este modelo se expresa como la ecuación 3.16:

$$Y = \rho W Y + X \beta + c \quad (\text{Ecuación 3.16})$$

En donde W es la matriz de pesos espaciales, WY la variable dependiente espacialmente rezagada, X la matriz de variables explicativas ($n \times p$) y c el término de error aleatorio.

3.3.7. Aprendizaje de Dependencia Autorregresiva Espacial I (SADL-I)

La regresión espacial se define como una técnica estadística utilizada para analizar datos espaciales considerando la influencia que las observaciones vecinas ejercen entre sí (Fotheringham, Oshan, y Li, 2023).

La función objetivo del modelo SADL-I está dada por la ecuación 3.17:

$$\min_{D, W} \frac{1}{2\sigma^2} \sum_t (Y_t - X_t W)^T (Y_t - X_t W) - \frac{1}{2} \sum_t |T| \ln(\det(I - D)) + \lambda R(W) \quad (\text{Ecuación 3.17})$$

En donde D es la matriz a optimizar que representa una transformación sobre los datos, W la matriz de pesos, T el conjunto de índices, Y_t el vector de observaciones en el tiempo t , X_t la matriz de características, σ^2 la varianza del ruido y λ el parámetro de regularización que controla la penalización sobre W .

3.3.8. Aprendizaje de Dependencia Autorregresiva Espacial II (SADL-II)

El SADL-II está diseñado para escenarios en los que la información previa sobre la independencia condicional es incompleta. Este modelo convexo se permite aprender simultáneamente la independencia condicional y la dependencia espacial bajo las restricciones espaciales establecidas (L. Zhao, Gkountouna, y Pfoser, 2023).

El modelo SADL-II se incorporan restricciones topológicas espaciales avanzadas para optimizar el aprendizaje de la independencia condicional se mejora la cuantificación de la intensidad de la dependencia espacial (L. Zhao, Gkountouna, y Pfoser, 2025).

3.3.9. Modelo Lineal Generalizado (GLM)

El GLM es una generalización de la regresión lineal clásica que permite que la variable dependiente tenga una distribución diferente de la normal y que la relación entre

las variables dependientes e independientes no necesariamente sea lineal (Islam y Biswas, 2025).

La ecuación general para un modelo lineal generalizado (GLM) se expresa en la ecuación 3.18 como:

$$g(E(Y)) = X\beta \quad (\text{Ecuación 3.18})$$

En donde $g(\cdot)$ es la función de enlace que relaciona la media de la variable respuesta con el predictor lineal, $E(Y)$ el valor esperado de la variable respuesta Y .

3.4. Métodos de validación

Coefficiente de determinación (R^2)

El R^2 es una medida de la calidad del ajuste del modelo a los datos, o una medida de la bondad de ajuste en los modelos de regresión, que indica cuánto de la variación en la variable dependiente puede ser explicada por la variable independiente en el modelo, es decir, R^2 se utiliza para evaluar que tan bien los valores predichos por el modelo se ajustan a los valores observados (Walpole, Myers, Myers, y Ye, 2024). La ecuación 3.19 representa como obtener (R^2):

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (\text{Ecuación 3.19})$$

En esta expresión, y_i representa los valores observados de la variable dependiente, mientras que $\hat{y}_i$ corresponde a los valores predichos por el modelo. La media de los valores observados se denota como $\bar{y}$. Por su parte, la cantidad $\sum (y_i - \hat{y}_i)^2$ indica la suma de los cuadrados de los errores de predicción (SSE), y $\sum (y_i - \bar{y})^2$ representa la suma total de cuadrados respecto a la media (SST). Estos componentes permiten evaluar el ajuste del modelo al comparar la variabilidad explicada con la variabilidad total de los datos.

Capítulo 4

Metodología

En la Figura 4.1 se ilustra el proceso de predicción del oxígeno disuelto (OD) utilizando modelos de RNA y métodos de regresión, de la cual en las siguientes secciones se explica su desarrollo.




Figura 4.1: Diagrama de flujo para el desarrollo del proyecto

(Ruiz y cols., 2025)

4.1. Adquisición de datos

Los datos utilizados para evaluar los modelos de redes neuronales artificiales (RNA) y los métodos clásicos de regresión se obtuvieron del UCI Machine Learning repository; <https://archive.ics.uci.edu/dataset/733/water+quality+prediction-1>, una fuente reconocida internacionalmente por su diversidad y calidad en conjuntos de datos para investigación. Este dataset corresponde a mediciones realizadas durante 705 días consecutivos, que incluyen 423 días para entrenamiento y 282 días para prueba, abarcando parámetros fisicoquímicos esenciales como pH, temperatura, conductividad y oxígeno disuelto, los cuales corresponden a 37 zonas diferentes del estado de Georgia, Estados Unidos de América, lo que proporciona una representación amplia y diversa de las condiciones ambientales del estado. Los datos se dividieron en dos conjuntos, el de entrenamiento el cual consta de 423 días consecutivos iniciando el 28 de junio de 2016 y el conjunto de prueba contiene 282 días consecutivos, posteriores al término de los días del conjunto de entrenamiento, finalizando el 1 de enero de 2018. Esta división permite comprobar qué tan bien los modelos pueden predecir datos nuevos, manteniendo un orden temporal que refleja cómo ocurre realmente el fenómeno en el tiempo.

4.2. Preparación de datos

Una vez obtenidos los datos, se continuó con la preparación de los datos, cuyo objetivo principal fue garantizar la homogeneidad y calidad del conjunto antes de su uso en los modelos predictivos. Esta fase es fundamental en cualquier proyecto de aprendizaje automático, ya que la presencia de valores atípicos o datos faltantes pueden afectar significativamente el rendimiento y la estabilidad de los algoritmos. En este contexto, la preparación de los datos incluyó diversas tareas orientadas a mejorar la confiabilidad del conjunto. Entre ellas se encuentran la detección y tratamiento de valores nulos, la normalización y estandarización de variables para evitar sesgos. Además, se implementaron procedimientos para identificar y mitigar la influencia de valores extremos, que podrían distorsionar la estimación de parámetros en los modelos. Estas acciones no solo contribuyen a la calidad del análisis, sino que también

4.3. TRANSFORMACIÓN DE DATOS

reducen el riesgo de sobreajuste y mejoran la capacidad de generalización del modelo. En esta sección se detallan los pasos específicos realizados durante la preparación de los datos, justificando cada decisión metodológica para poder explicar como estas transformaciones impactan en la robustez y confiabilidad de los resultados obtenidos.

4.2.1. Limpieza de los datos

Una de las primeras etapas dentro del proceso de preparación de los datos consistió en la limpieza de los datos, una tarea esencial para garantizar la calidad y confiabilidad de la información antes de su uso en los modelos predictivos. Esta fase implicó una revisión exhaustiva de los datos con el objetivo de identificar y corregir inconsistencias que pudieran afectar el análisis posterior. En primer lugar, se inspeccionaron los datos y depuraron los datos para identificar y tratar valores faltantes, duplicados o atípicos, se revisaron los datos y se eliminaron aquellos que tenían información incorrecta, para asegurar que todos los valores fueran válidos. Esta etapa fue crucial para reducir el ruido en los datos, mejorar la estabilidad de los modelos y evitar sesgos en la estimación de los parámetros. Al garantizar la integridad de la información desde el inicio, asegurando la validez de los resultados obtenidos en etapas posteriores ([de Arregui, 2024](#)).

4.3. Transformación de datos

Una vez realizada la preparación inicial del conjunto de datos, se procedió a aplicar un proceso de transformación conocido como preprocesamiento, cuyo propósito fue adaptar las variables a un formato adecuado para el entrenamiento de los modelos. Este paso resultó esencial, dado que los algoritmos de aprendizaje automático, en particular las redes neuronales artificiales, requieren que la información esté organizada bajo una estructura específica para garantizar un aprendizaje eficiente y evitar inconsistencias en la interpretación. Dentro de las transformaciones implementadas, se incluyó la transposición de los datos, operación que permitió reorganizar las matrices de entrada de manera que las variables, tales como pH, temperatura y conductividad, se ubiquen en la disposición esperada por el modelo. Esta reorganización aseguró

que cada observación y cada característica se representen correctamente en la matriz de entrenamiento.

Adicionalmente, el proceso contempló otras tareas relevantes, entre ellas la normalización y estandarización, con el objetivo de ajustar los valores de las variables a una misma escala, evitando que aquellas con magnitudes mayores influyan de manera desproporcionada en el aprendizaje, la codificación de variables categóricas, que consiste en convertir datos no numéricos en representaciones numéricas compatibles con el modelo y el tratamiento de valores faltantes, mediante la imputación o eliminación de registros incompletos para garantizar la consistencia del conjunto de datos.

Estas transformaciones no solo facilitaron el entrenamiento del modelo, sino que también contribuyeron a mejorar su calidad, reducir el riesgo de errores y permitir que la red neuronal identificara relaciones complejas entre las variables. En consecuencia, este proceso constituyó un paso crítico dentro de la metodología para asegurar la robustez y confiabilidad de los resultados obtenidos ([OAP, 2025](#)).

4.3.1. Transpuesta de los datos

En este apartado se realizó la transpuesta de los datos, una parte del proceso fundamental para reorganizar la estructura del conjunto y adaptarla al formato requerido por los modelos de las RNA. La transpuesta de los datos consiste en intercambiar las filas por las columnas dentro de una matriz. Este proceso permitió reorganizar la estructura del conjunto de datos con el fin de adaptarla al formato requerido por los modelos de RNA. En otras palabras, los datos fueron reestructurados de manera que cada fila representara una observación o instancia temporal, y cada columna correspondiera a una variable o parámetro físicoquímico medido.

La transposición de los datos es un paso importante en el flujo de procesamiento, ya que los modelos de aprendizaje automático requieren que la información se encuentre organizada de manera uniforme para poder ser interpretada correctamente. En el caso de las RNA, la disposición de las entradas influye directamente en la forma en

4.3. TRANSFORMACIÓN DE DATOS

que la red procesa y aprende las relaciones entre las variables. Por ejemplo, si los datos no se encuentran correctamente orientados, el modelo podría asociar erróneamente las características, afectando su desempeño y la precisión de las predicciones. Esta operación permitió que las variables estuvieran correctamente organizadas para facilitar su análisis y procesamiento, especialmente para alimentar los modelos de RNA que requieren formatos específicos de entrada ([FasterCapital, 2025](#)).

4.3.2. La selección de características

En este apartado se llevó a cabo la selección de características, un paso crucial dentro del proceso de preparación de datos, cuyo objetivo principal fue identificar las variables más relevantes para la predicción del oxígeno disuelto. Este procedimiento consistió en analizar la relación entre las distintas variables disponibles y la variable objetivo, creando un nuevo conjunto de datos, en donde se seleccionaron cuidadosamente las variables de interés que presentaban una correlación significativa con el oxígeno disuelto, tales como temperatura, pH y conductividad. A partir de esta selección, se conformó un nuevo conjunto de datos. Los datos se dividieron en dos conjuntos, el de entrenamiento el cual consta de 423 días consecutivos iniciando el 28 de junio de 2016 y el conjunto de prueba contiene 282 días consecutivos, posteriores al término de los días del conjunto de entrenamiento, finalizando el 1 de enero de 2018 para entrenar modelos de regresión y redes neuronales artificiales. Esta selección no solo reduce la dimensionalidad, sino que también contribuye a mejorar la eficiencia computacional, evitando el procesamiento de datos irrelevantes que podrían producir ruido y afectar la precisión de los modelos. Además la reducción de dimensionalidad obtenida mediante la selección de características contribuye a disminuir el riesgo de sobreajuste, mejorar la interpretabilidad del modelo y optimizar el tiempo de procesamiento, aspectos esenciales para el desarrollo de modelos de regresión y RNA.

4.3.3. Normalización

Finalmente, una vez que las características fueron seleccionadas, es común observar que presentaron diferentes rangos y unidades de medida. Por ejemplo, una variable

como la temperatura puede estar en grados Celsius, mientras que la conductividad se mide en microsiemens y el pH en una escala de 0 a 14. Estas diferencias pueden afectar significativamente el rendimiento de los modelos de predicción, ya que las variables con valores más grandes tienden a dominar el proceso de aprendizaje, generando sesgos y dificultando la convergencia del modelo. Para evitar este problema, se aplicó la técnica de normalización Min-Max, propuesta por Rodríguez (2024), cuyo objetivo fue escalar los valores de cada variable dentro de un rango estándar entre [0, 1]. Esta técnica modificó la escala original de los datos al recalibrar sus límites. Con este procedimiento, el menor valor de cada variable pasó a representarse como 0 y el mayor como 1. De este modo, todas las características mantuvieron su relación original, pero en una escala uniforme. Esta técnica evitó que las variables con mayor escala dominen el proceso de aprendizaje y permitió que los modelos pudieran converger más rápidamente durante el entrenamiento. La fórmula general utilizada para la normalización se presenta en la ecuación 4.1:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (\text{Ecuación 4.1})$$

donde x representa un valor original, $x_{\min}$ y $x_{\max}$ son el mínimo y el máximo de la variable, respectivamente, y x' es el valor normalizado.

Gracias a este procedimiento, todas las características mantuvieron su relación original, pero en una escala uniforme, lo que facilitó que el modelo tratara cada variable con la misma importancia. Además, esta técnica contribuyó a que los algoritmos de aprendizaje, especialmente las redes neuronales, convergieran más rápido durante el entrenamiento, reduciendo el tiempo de cómputo y mejorando la estabilidad del proceso.

4.4. Configuración de modelos

Después de preparar y transformar los datos, se llevó a cabo la configuración de los modelos que se usaron para hacer las predicciones. En esta tesis se utilizaron dos enfoques principales: las RNA y los modelos de regresión lineal. Para cada modelo, se

4.3. TRANSFORMACIÓN DE DATOS

ajustaron algunos parámetros importantes, como la cantidad de capas y neuronas

(en las RNA) o la forma en que se relacionan las variables (en la regresión lineal). Este proceso es esencial porque los algoritmos de aprendizaje automático, especialmente las redes neuronales artificiales, requieren que la información esté organizada de manera específica para poder aprender patrones de forma eficiente y evitar errores en la interpretación ([Flores-Asis, González-Rosas, y Rodríguez-Gasga, 2024](#)).

4.4.1. Las RNA

Para interpretar adecuadamente los resultados obtenidos, es importante considerar la procedencia del conjunto de datos utilizado. Se empleó un conjunto de datos proveniente de Estados Unidos, obtenido del UCI Machine Learning Repository, debido a que en el Estado de México no se cuenta con análisis equivalentes ni con bases de datos públicas, confiables y sistematizadas que contengan información detallada y continua sobre la calidad de los cuerpos de agua. En particular, variables fisicoquímicas como la temperatura, el pH y la conductividad eléctrica, las cuales influyen directamente en la concentración de oxígeno disuelto (OD), presentan una disponibilidad limitada y heterogénea a nivel regional, lo que dificulta el desarrollo de modelos predictivos robustos a partir de información local.

En esta sección se detallan las configuraciones aplicadas a distintos tipos de RNA, considerando aspectos como el número de capas ocultas, la cantidad de neuronas, la función de activación, el optimizador y la tasa de aprendizaje. Estos elementos son fundamentales para ajustar el comportamiento del modelo y mejorar su capacidad de aprendizaje frente al conjunto de datos disponible.

Durante la fase de experimentación del proyecto, al inicio se trabajó con una red convolucional utilizando como entrada los resultados de la base de datos de los 4 parámetros fisicoquímicos (pH, OD, conductividad, temperatura), se utilizó un entorno virtual llamado google colab, en donde se cargó la base de datos en un archivo .csv, se dividió la base en conjunto de entrenamiento (train) y prueba (test), se extrajeron características relevantes de los datos de entrada mediante la convolución con filtros. En la primera capa convolucional se utilizaron 32 filtros con un tamaño de kernel de 3, esto significa que se aplicarán 32 filtros diferentes a la entrada, cada uno con una

ventana de 3 valores. En la segunda capa convolucional, se utilizan 256 filtros con un tamaño de kernel de 2, estas capas convolucionales están diseñadas para aplicar operaciones de convolución a datos, esto permite que la red extraiga características relevantes de los datos de entrada para su posterior procesamiento. Durante las pruebas iniciales, los resultados no fueron tan buenos como se esperaba. Por esta razón, se decidió reducir el número de variables y trabajar únicamente con tres parámetros fisicoquímicos: pH, conductividad y temperatura. Esta selección se hizo porque son los que tienen mayor relación con el oxígeno disuelto. Después de este ajuste, se optó por probar más modelos de Redes Neuronales Artificiales (RNA) con el objetivo de encontrar la mejor opción y mejorar la precisión de las predicciones.

Como se mencionó anteriormente, se exploró el potencial de siete redes neuronales artificiales (RNA), con el objetivo de identificar cuál ofrecía el mejor desempeño en la predicción del oxígeno disuelto. Entre estas arquitecturas se incluyó el Perceptron Multicapa (MLP), al que denominamos MLPV3, caracterizado por su capacidad para modelar relaciones complejas entre variables mediante múltiples capas de procesamiento. En esta red, se tomó un conjunto de valores de entrada, llamados features, que representan parámetros fisicoquímicos relevantes y se procesaron a través de varias capas de neuronas interconectadas. Cada neurona realizó una combinación lineal de las entradas recibidas, seguida de la aplicación de una función de activación, como ReLU, con el propósito de capturar patrones complejos y relaciones no lineales presentes en los datos. Al final, la red produjo una salida que fue nuestra predicción de oxígeno disuelto. La arquitectura utilizada contenía tres capas: la primera con 128 neuronas, la segunda con 64 y la última encargada de producir la salida. Los resultados reflejaron la robustez del MLPV3 frente a la variabilidad de los datos y confirmaron su potencial como herramienta para el monitoreo y gestión de la calidad del agua. Cabe resaltar que el desempeño logrado no solo depende de la estructura de la red, sino también de la correcta preparación de los datos y la selección de hiperparámetros, aspectos que fueron cuidadosamente ajustados durante el proceso.

Otra arquitectura que trabajamos fue la red densa que es un perceptrón multicapa (MLP), a la que denominamos MLPV1, compuesta por tres capas totalmente conecta-

4.4. CONFIGURACIÓN DE MODELOS

das. La primera capa recibía un vector de entrada con tantas neuronas como características tenga el conjunto de datos y era transformado en 128 neuronas; la segunda reducía esa representación a 64 neuronas; y la tercera producía la salida de nuestra variable a predecir. En el flujo de datos, cada capa se aplicaba una combinación lineal seguida de la función de activación ReLU en las dos primeras capas para capturar relaciones no lineales, mientras que la última capa se mantenía lineal.

Se realizó una arquitectura de red feedforward simple a la que denominamos MLPV2, es un perceptrón multicapa se compone por tres capas densas. La primera capa recibía como entrada el número de características del conjunto de datos y era transformada en 128 neuronas; la segunda reducía esa representación a 64 neuronas; y la tercera producía la salida de nuestra variable a predecir. Cada capa aplicó una combinación lineal y las dos primeras se utilizaba la función de activación ReLU para capturar relaciones no lineales, mientras que la última permanecía lineal.

Asimismo, se empleó una red neuronal recurrente (RNR), su arquitectura fue primero, una capa recurrente que recibió como entrada tantas características como tenga el conjunto de datos y utilizaba 64 neuronas ocultas para procesar la secuencia temporal. Después, la salida era conducida por tres capas densas, que redujeron progresivamente la dimensionalidad desde 128 neuronas hasta el número de salidas correspondiente a nuestra variable objetivo.

La arquitectura de la red GRU se construyó para procesar series temporales que tomó de secuencias de entrada y mediante las cuales se generaban las predicciones de la variable objetivo. La primer capa con 64 unidades ocultas, procesaba la secuencia completa. De la salida de la GRU se tomó solo el último paso temporal. Ese vector era conducido por una capa densa de 64→128 neuronas con activación ReLU para añadir no linealidad, y finalmente se enviaba por una capa totalmente conectada, que mapeaba 128 al número de salidas y con lo cual se obtenían las predicciones finales.

La red neuronal artificial de Memoria a Corto y Largo Plazo (MCLP), utiliza una capa con 64 neuronas ocultas para aprender los patrones y dependencias a lo largo del tiempo entre las variables de entrada. Después, la salida final de la secuencia se pasa por una capa densa de 128 neuronas con activación ReLU, que introduce no linealidad

y se permite una mejor representación de las relaciones complejas entre los datos. Finalmente, una segunda capa totalmente conectada es utilizada para convertir estos valores en las salidas finales, correspondientes a las variables objetivo del modelo.

La arquitectura de la red Transformers se conformó mediante la combinación de capas densas y una capa de atención multicabezal. En primer lugar, la entrada era procesada por una capa densa con 64 neuronas y activación ReLU, luego se expandía por la capa atención multicabezal, en la cual se aplicaba atención sobre la representación para capturar relaciones entre las características. Después, se redujo era reducida con otra capa densa de 32 neuronas.

La Tabla 4.1 presenta las principales estructuras, características y configuraciones de los modelos de RNA utilizados en este trabajo. En esta tabla se incluyen tres versiones de redes feedforward, en las cuales se modifican las funciones de activación, el número de neuronas ocultas y el algoritmo de aprendizaje; la red neuronal recurrente (RNR), la red de memoria a corto y largo plazo (LSTM), la red neuronal tipo Transformer y las Unidades Recurrentes Gated (GRU). Estos modelos fueron desarrollados en una estación de trabajo equipada con un procesador Intel Xeon E-2186G (12) a 4.700 GHz y una tarjeta gráfica NVIDIA GeForce RTX 3060 con 6 GB de memoria de video. El sistema disponía con 64 GB de memoria RAM. Se utilizó la versión 535.86.05 del controlador NVIDIA-SMI y la versión 12.2 de CUDA para la aceleración por GPU. En cuanto al software, se emplearon TensorFlow 2.14.0, scikit-learn 1.3.0, Python 3.10.11, pandas 2.1.0, numpy 1.23.5, jupyterlab 3.6.3, notebook 6.5.4, ipykernel 6.25.2 e ipython 8.15.0.

Tabla 4.1: Configuración de modelos de diferentes tipos de RNA.

RNA	Lote	Capas ocultas	Optimizador	Tasa de aprendizaje	Función de pérdida	Épocas	Función de activación
MLPV1	32	64 / 32	ADAM	0.001	MSE	1000	ReLU
MLPV2	32	64 / 32	LBFGS	0.1	MSE	100	ReLU
MLPV3	32	128 / 64	LBFGS	0.1	MSE	1000	Linear
GRU	32	64 / 32	ADAM	0.001	MSE	1000	ReLU
LSTM	32	64 / 32	ADAM	0.001	MSE	1000	ReLU
RNR	32	64 / 32	LBFGS	0.1	MSE	1000	ReLU
Transformer	32	64 / 32	ADAM	0.001	MSE	100	ReLU

4.4.2. Los modelos de regresión

Además de las Redes Neuronales Artificiales (RNA), en este trabajo se incorporaron diversos modelos de regresión lineal como parte del análisis comparativo. El objetivo de incluir estos métodos fue evaluar su capacidad para predecir el oxígeno disuelto y contrastar su desempeño frente a modelos más complejos. Para ello, se desarrolló un script automatizado en Python que permitió ejecutar, evaluar y comparar de manera sistemática cada uno de los modelos seleccionados. El uso del script facilitó la estandarización del proceso, asegurando que todos los modelos fueran entrenados bajo las mismas condiciones experimentales (mismos datos de entrada, división entrenamiento-prueba y métricas de evaluación).

Los modelos de regresión lineal permiten estudiar cómo se relaciona una variable dependiente con una o varias variables independientes bajo el supuesto de una relación lineal. Esta característica los convierte en herramientas simples, interpretables y útiles como punto de partida en problemas predictivos. Entre los métodos aplicados se encuentran: la Regresión Lineal Múltiple (LMR), el modelo de regresión Lasso, el modelo de regresión ElasticNet, la regresión Multi-task, el modelo SADL-I, el modelo SAR-I, el modelo SADL-2 y finalmente el modelo GLM.

Cada uno de estos modelos ofrece una forma distinta de ajustar y predecir los datos. Aunque son más simples que las RNA, su facilidad de interpretación, rápida configuración y bajo costo computacional los convierten en herramientas valiosas para establecer una línea base. Además, su inclusión permitió contrastar los resultados con los modelos más complejos y evaluar qué enfoque ofrece el mejor desempeño para el problema planteado.

4.5. Evaluación del modelo

4.5.1. Coeficiente de determinación (R^2)

El coeficiente de determinación (R^2) es una métrica estadística ampliamente utilizada para evaluar el desempeño de modelos de regresión y en general. Su función principal es indicar qué tan bien las predicciones del modelo se ajustan a los datos reales, es

decir, mide la proporción de la variabilidad de la variable dependiente que puede ser explicada por el modelo. Se utilizó un conjunto de datos de prueba para validar el modelo mediante el R^2 , el cual indica que tan bien las predicciones del modelo se ajustan a los datos reales.

Este cálculo comparó el error del modelo (diferencia entre valores reales y predichos) con la variabilidad total de los datos. Si el modelo predice perfectamente, el numerador será cero y $R^2 = 1$, lo que indica un ajuste perfecto. Por el contrario, si el modelo no mejora respecto a simplemente usar el promedio, R^2 será cercano a cero. Incluso puede ser negativo si el modelo es peor que una predicción basada en la media.

4.6. Desempeño del Modelo y Prueba Estadística Significativa

Para evaluar la efectividad de los modelos neuronales y de regresión, se utilizó el coeficiente de determinación (R^2) como métrica de rendimiento. El R^2 se describe como una medida del ajuste del modelo en regresiones, la cual indica qué proporción de la variabilidad total presente en la variable dependiente puede ser explicada por las variables independientes incluidas en el modelo. El R^2 se define como se puede observar en la ecuación 4.2:

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (\text{Ecuación 4.2})$$

donde y_i es la i -ésima observación de la variable dependiente Y , $\hat{y}$ es el valor estimado y $\bar{y}$ es la media muestral, respectivamente (Walpole y cols., 2024).

Para determinar si existen diferencias estadísticamente significativas entre los modelos, se aplicó la prueba no paramétrica de Friedman (DataScientest, 2023). El primer paso de esta prueba consiste en calcular los rangos de desempeño de los algoritmos en cada conjunto de datos por separado. A cada modelo se le asigna un rango según su rendimiento: el de mejor desempeño recibe el rango 1, el segundo mejor el rango 2, y así sucesivamente.

En caso de empates, se asignan rangos promedios. La estadística de Friedman se define como se puede observar en la ecuación 4.3:

$$X^2 = \frac{12N}{K(K+1)} \sum_{j=1}^K \frac{R_j^2}{K(K+1)^2} \quad (Ecuación 4.3)$$

donde R son los rangos promedio, N y K son el número de conjuntos de datos y modelos, respectivamente. La estadística de Iman-Davenport ([Arnáiz-González, 2024](#)) se calcula como se puede observar en la ecuación 4.4:

$$F_F = \frac{(N-1)X^2}{N(K-1) - X^2} \quad (Ecuación 4.4)$$

y está distribuida según la distribución F con $(K-1)$ y $(K-1)(N-1)$ grados de libertad. Para identificar qué pares de modelos presentan diferencias significativas, se utilizaron pruebas *post-hoc*: Holm y Shaffer, según la metodología descrita por ([Estadístico de Friedman ajustado por Iman-Davenport, 2023](#)), el método de Holm ordena los valores p de menor a mayor, $p_1 \leq p_2 \leq \dots \leq p_m$, correspondientes a la secuencia de hipótesis $H_1, H_2, \dots, H_m$; así, rechaza las hipótesis $H_1, \dots, H_{i-1}$ una a una hasta que no se puedan hacer más rechazos. Para esto, el método de Holm rechaza $H_1, H_2, \dots, H_{i-1}$ si i es el menor entero tal que $p_i \leq \frac{\alpha}{m-i+1}$, donde $m = \frac{K(K-1)}{2}$. El método de Shaffer sigue un procedimiento muy similar al propuesto por Holm, pero rechaza H_i si $p_i \leq \frac{\alpha}{t_i}$, donde t_i es el número máximo de hipótesis que pueden ser verdaderas dado que cualquier $(i-1)$ hipótesis son falsas. Independientemente de los valores observados de p , las hipótesis $H_1, H_2, \dots, H_m$ determinan $t_1, t_2, \dots, t_m$. En este trabajo, se realizó la prueba estadística no paramétrica en el software KEEL con un nivel de confianza $\alpha = 0.05$ ([Guerrero, 2024](#))

Capítulo 5

Resultados

En este apartado se presentan los resultados obtenidos durante la experimentación y la prueba estadística de las diferentes muestras para evaluar el desempeño de las 7 diferentes redes neuronales artificiales (RNA) y los 9 modelos de regresión (MR) propuestos. Estos muestran como las RNA ofrecen un desempeño superior en precisión y ajuste para predecir el oxígeno disuelto (OD) en comparación con los modelos de regresión.

5.1. Resultados de coeficiente de determinación (R^2)

En el análisis de los resultados obtenidos en las 37 zonas geográficas, se utilizó el coeficiente de determinación (R^2) como métrica principal para evaluar el desempeño de los modelos aplicados en la predicción de oxígeno disuelto (OD). Esta métrica permitió comparar de manera cuantitativa la precisión de las redes neuronales artificiales (RNA) frente a los modelos clásicos de regresión (MR). Los valores de R^2 obtenidos reflejan el grado de ajuste entre los valores predichos por los modelos y los datos observados, proporcionando una base sólida para identificar cuál enfoque ofrece mejores resultados en distintos niveles; en el máximo, medio y mínimo en un cuerpo de agua.

La Figura 5.1 presenta una comparación gráfica de los valores promedio de R^2 obtenidos por cada modelo en las 37 zonas. En esta Figura las barras azules representan los

5.1. RESULTADOS DE COEFICIENTE DE DETERMINACIÓN (R^2)

resultados obtenidos por los modelos de RNA, que incluyen arquitecturas de MLP (Perceptrón Multicapa), GRU (Gated Recurrent Unit), FFS (FEEDFORWARD), DEN (DENSE), LSTM (Long Short-Term Memory), TRAN (TRANSFORMER) y RNR (Red Neuronal Recurrente). Las barras rojas corresponden a los modelos de regresión clásica, RDG (RIDGE), LMR (Modelo de Regresión Lineal), GLM (Modelo Lineal Generalizado), ETN (ELASTICNET), MTL (MULTITASK LASSO), SAR-I1, SADL-I, LASSO, SADL-2, que se basan en la suposición de relaciones lineales entre las variables.

Esta representación visual permite observar de manera clara las diferencias de rendimiento entre ambos enfoques. En la Figura 5.1 se puede observar la predicción del nivel máximo de OD, en este apartado se analiza la capacidad de los modelos para predecir el nivel máximo de OD. Como se puede observar en la Figura el modelo MLP (Perceptrón Multicapa) se destaca con un valor de $R^2 = 0.9897$, lo que indica una excelente capacidad predictiva. Este valor tan cercano a 1 sugiere que el modelo puede explicar casi toda la variabilidad de los datos observados.

Este resultado refleja una de las principales ventajas de las RNA: su habilidad para capturar relaciones complejas y no lineales entre las variables. A diferencia de los modelos de regresión, que requieren que las relaciones entre las variables sean lineales y constantes, las RNA pueden adaptarse a patrones más sofisticados y dinámicos presentes en los datos ambientales.

5.1. RESULTADOS DE COEFICIENTE DE DETERMINACIÓN (R^2)




Figura 5.1: Resultados de R^2 en OD Máximo de las diferentes RNA y MR

En la Figura 5.2 se puede observar la predicción del nivel medio de OD. En este segundo análisis se evalúa el rendimiento de los modelos en la predicción de los niveles medio de OD, observando en este nivel de OD que el modelo MLP alcanza un $R^2 = 0.9993$, lo que indica que sus predicciones fueron casi idénticas a los valores reales. Este resultado muestra una precisión muy alta, lo que confirma la capacidad del modelo para ajustarse con gran exactitud a los datos observados. La cercanía del valor de R^2 a 1 refleja un ajuste casi perfecto, lo que posiciona al modelo como una herramienta altamente confiable para este tipo de estimaciones.

Además, este resultado destaca la capacidad del MLP para mantener un rendimiento constante en diferentes niveles de OD, lo cual es especialmente importante en estudios ambientales, donde los datos suelen estar influenciados por múltiples factores como temperatura, salinidad, corrientes, y actividad humana. La estabilidad del modelo frente a estas variaciones refuerza su utilidad en aplicaciones prácticas relacionadas con la gestión y monitoreo de cuerpos de agua.

5.1. RESULTADOS DE COEFICIENTE DE DETERMINACIÓN (R^2)




Figura 5.2: Resultados de R^2 en OD Medio de las diferentes RNA y MR

En cuanto al nivel mínimo de OD, el modelo MLP también alcanzó un valor elevado de $R^2 = 0.9984$, lo que confirma su eficacia en escenarios donde los niveles de oxígeno son más bajos y posiblemente más variables. Esta consistencia en el rendimiento, tanto en niveles medios como mínimos, refuerza la robustez del modelo frente a diferentes condiciones ambientales, como se puede observar en la Figura 5.3.

Comparativamente, los modelos de regresión mostraron valores de R^2 inferiores en estos mismos niveles, lo que evidencia una menor capacidad para capturar la complejidad de los datos. Las RNA, en especial el modelo MLP, demostraron ser más adecuadas para este tipo de predicciones, al adaptarse mejor a las variaciones no lineales presentes en los datos de OD ([Çerçi y Hürdoğan, 2020](#)).

Estos hallazgos confirman que las redes neuronales artificiales (RNA), presentan un desempeño notablemente superior y más estable en comparación con los modelos de regresión. La capacidad del MLP para mantener altos valores de R^2 en distintos niveles de OD evidencia su eficacia para adaptarse a la complejidad inherente de los datos ambientales. Esta estabilidad en el rendimiento resulta particularmente relevante en contextos donde las relaciones entre variables no siguen patrones lineales y están

5.2. RESULTADOS DE LOS RANKINGS PROMEDIO DE LOS ALGORITMOS (FRIEDMAN)

sujetas a múltiples influencias simultáneas, como variaciones climáticas, condiciones hidrológicas y factores antropogénicos. Por lo tanto, el uso de redes neuronales artificiales, especialmente el modelo MLP, se presenta como una herramienta confiable y eficaz para predecir fenómenos ambientales que cambian constantemente. Gracias a su capacidad para adaptarse a datos complejos y variables, estos modelos permiten obtener resultados precisos incluso en situaciones donde las relaciones entre los factores no son claras ni lineales.




Figura 5.3: Resultados de R^2 en OD Mínimo de las diferentes RNA y MR

5.2. Resultados de los Rankings promedio de los Algoritmos (Friedman)

Con el objetivo de evaluar el rendimiento relativo de los modelos de redes neuronales artificiales (RNA) y los modelos clásicos de regresión en la predicción de los niveles de oxígeno disuelto (OD) en los diferentes niveles; máximo, medio y mínimo, se aplicó el test de Friedman. Esta prueba estadística no paramétrica permite comparar múltiples algoritmos sobre varios conjuntos de datos sin asumir una distribución específica, lo que la hace especialmente útil en contextos donde los datos presentan alta variabilidad, como en estudios ambientales. En este análisis, el test de Friedman

5.2. RESULTADOS DE LOS RANKINGS PROMEDIO DE LOS ALGORITMOS (FRIEDMAN)

genera un ranking promedio para cada modelo, indicando su posición relativa en términos de desempeño. Un ranking más bajo representa un mejor rendimiento, ya que implica que el modelo fue más preciso y consistente en sus predicciones en comparación con los demás.

La Figura 5.4 muestra los resultados obtenidos en el nivel de OD Máximo, se observa que el modelo MLP (Perceptrón Multicapa) obtuvo el ranking promedio más bajo (1.7027), posicionándose como el modelo más eficaz en la mayoría de las zonas analizadas, demostrando que es capaz de aprender relaciones complejas y no lineales entre las variables de entrada y nuestra variable de salida, lo que le permite modelar con mayor precisión el OD Máximo. Este resultado destaca su capacidad para realizar predicciones precisas en la medición de OD en el nivel máximo.

Posteriormente los modelos GRU, Ridge y GLM, con rankings promedio entre 5 y 6, lo que indica un rendimiento competitivo, aunque inferior al de MLP. Por su parte, modelos como Transformer, SADL-2, ETN, MTL presentan rankings más elevados, lo que sugiere un desempeño moderado en este nivel de OD.

Estos resultados permiten identificar con claridad qué modelos ofrecen mayor precisión y estabilidad en la predicción del OD máximo, reafirmando la superioridad de las RNA y en particular del modelo MLP frente a los enfoques clásicos de regresión lineal. Este patrón de resultados refuerza la idea de que los modelos basados en RNA, y en particular el MLP, tienen una ventaja significativa en la modelación de fenómenos ambientales complejos como el OD, debido a su capacidad para aprender relaciones no lineales y adaptarse a variaciones en los datos.

5.2. RESULTADOS DE LOS RANKINGS PROMEDIO DE LOS ALGORITMOS (FRIEDMAN)




Figura 5.4: Resultados de los Rankings promedio de los Algoritmos en OD Máximo de las diferentes RNA y MR

En la Figura 5.5 se presentan los rankings promedio de distintos modelos de redes neuronales artificiales (RNA) y modelos clásicos de regresión (MR) en la predicción del nivel medio de oxígeno disuelto (OD), el modelo MLP se posiciona como el más eficiente, obteniendo el ranking promedio más bajo, lo que indica que fue el modelo más preciso y consistente en la predicción del OD medio en las 37 zonas evaluadas. Este resultado reafirma la capacidad del MLP para adaptarse a relaciones complejas entre variables ambientales, incluso en condiciones de concentración intermedia de oxígeno disuelto. Algunos modelos clásicos como GLM y Ridge (RDG) también lograron rankings bajos, lo que sugiere que, en este nivel de OD, ciertos enfoques lineales pueden competir con las RNA en términos de rendimiento. Esto podría deberse a que las condiciones del OD medio presentan menor variabilidad o complejidad, permitiendo que modelos lineales ajusten adecuadamente los datos. En contraste, modelos como LASSO, ETN, SADL-I y SAR-I1 obtuvieron los rankings más altos, lo que refleja un desempeño significativamente inferior. Estos resultados indican que dichos

5.2. RESULTADOS DE LOS RANKINGS PROMEDIO DE LOS ALGORITMOS (FRIEDMAN)

modelos tienen limitaciones para capturar las dinámicas del OD medio, posiblemente por su rigidez estructural o menor capacidad de generalización.




Figura 5.5: Resultados de los Rankings promedio de los Algoritmos en OD Medio de las diferentes RNA y MR

En la Figura 5.6 se presentan los rankings promedio de distintos modelos de redes neuronales artificiales (RNA) y modelos clásicos de regresión (MR) en la predicción del nivel mínimo de oxígeno disuelto (OD), el modelo MLP sigue siendo el más destacado con un ranking de 1.0541. el modelo M.P (presumiblemente MLP) se posicionó como el más destacado al obtener el ranking promedio más bajo, cercano a 0, lo que indica que fue el modelo con mejor desempeño entre todos los evaluados. Este resultado refleja su alta precisión y consistencia en la predicción de condiciones críticas de OD. Asimismo, otros modelos de redes neuronales artificiales como FFS, DEN, RNR, TRAN, GRU y LSTM también mostraron rankings relativamente bajos, lo que sugiere un buen rendimiento general de las RNA en este nivel. En contraste, los modelos clásicos de

5.3. RESULTADOS DE LOS ALGORITMOS EN MATRIZ DE PUNTOS (HOLM AND SHAFFER)

regresión como ETN y Lasso obtuvieron rankings mucho más altos, cercanos a 14.00, lo que evidencia un desempeño significativamente inferior. Además, modelos como SADL-2, GLM, MTL, SAR-II y SADL-I también se ubicaron en posiciones elevadas dentro del ranking, reforzando la tendencia de que los enfoques tradicionales de regresión presentan limitaciones para modelar eficazmente el OD mínimo, especialmente en entornos donde las relaciones entre variables son complejas y no lineales.




Figura 5.6: Resultados de los Rankings promedio de los Algoritmos en OD Mínimo de las diferentes RNA y MR

5.3. Resultados de los algoritmos en matriz de puntos (Holm and Shaffer)

A continuación se presentan los resultados obtenidos de los algoritmos en matriz de puntos (Holm and Shaffer) de las RNA y MR en nivel de OD mínimo, OD medio y OD máximo. En la Figura 5.7 se puede observar los resultados de los algoritmos en matriz de puntos (Holm and Shaffer) de las RNA y los modelos de regresión en nivel de OD máximo, se puede observar que los puntos negros representan pares de

5.3. RESULTADOS DE LOS ALGORITMOS EN MATRIZ DE PUNTOS (HOLM AND SHAFFER)

algoritmos donde la diferencia en el rendimiento es estadísticamente significativa, lo anterior representa que uno de los algoritmos supera significativamente al otro en desempeño de acuerdo con la evidencia estadística. Esto quiere decir que al comparar los algoritmos en la fila y la columna correspondiente, el test de Holm y Shaffer ha rechazado la hipótesis nula (la hipótesis de que ambos algoritmos tienen el mismo rendimiento). Los puntos grises o la ausencia de puntos entre un par de algoritmos indican que no se ha encontrado una diferencia significativa en el rendimiento de esos algoritmos. En estos casos, la hipótesis nula no se rechaza.

En la Figura 5.7 se puede observar que los patrones de los puntos negros en filas y columnas específicas revelan que ciertos algoritmos como SADL-1, SADL-2 y Multi-task Lasso tienen diferencias significativas con un gran número de otros algoritmos. Esto sugiere que en estos modelos se puede destacar su rendimiento, en comparación con otros algoritmos.




Figura 5.7: Resultados de algoritmos en matriz de puntos (Holm and Shaffer) de las RNA y modelos de regresión en nivel de OD máximo

En la Figura 5.8 se puede observar los resultados de los algoritmos en matriz de puntos (Holm and Shaffer) de las RNA y los modelos de regresión en nivel de OD

5.3. RESULTADOS DE LOS ALGORITMOS EN MATRIZ DE PUNTOS (HOLM AND SHAFFER)

medio, en esta matriz, cada punto representa la comparación entre dos algoritmos, y los puntos negros señalan los casos en los que la diferencia en el rendimiento es estadísticamente significativa, es decir, cuando un modelo muestra un desempeño considerablemente distinto del otro. Los algoritmos como SADL-1, SADL-2 y Multi-task Lasso presentan puntos negros en varias de sus comparaciones, lo cual indica que estos modelos tienen diferencias significativas con muchos otros algoritmos; esto podría sugerir que tienen un rendimiento distintivo, comparado con los demás. En contraste, modelos como Feedforward Simple, Densa y MLP muestran menos puntos negros, lo cual sugiere que sus resultados son más consistentes o similares entre sí y con otros modelos, sin diferencias estadísticamente relevantes. En otras palabras, estos algoritmos tienden a comportarse de manera más homogénea dentro del conjunto de comparaciones realizadas.




Figura 5.8: Resultados de algoritmos en matriz de puntos (Holm and Shaffer) de las RNA y modelos de regresión en nivel de OD medio

En la Figura 5.9 se aprecian los resultados de los modelos en matriz de puntos (Holm and Shaffer) de las RNA y los modelos de regresión en nivel de OD mínimo, al igual que

5.3. RESULTADOS DE LOS ALGORITMOS EN MATRIZ DE PUNTOS (HOLM AND SHAFFER)

en las figuras previamente analizadas, las técnicas SADL-1, SADL-2 y Multi-task Lasso presentan una elevada concentración de puntos negros en sus filas y columnas. Esto indica que estos métodos presentan diferencias significativas respecto a un número considerable de algoritmos incluidos en el estudio. La abundancia sugiere que sus comportamientos, al predecir el OD mínimo, se distinguen de manera marcada frente al resto de los algoritmos.

Por otro lado, los modelos Feedforward Simple y Feedforward Densa demuestran un menor número de puntos negros en la matriz, lo que refleja una ausencia de diferencias estadísticamente importantes frente a la mayoría de los otros algoritmos evaluados. Esta menor aparición de puntos refleja que ambos modelos tienden a ubicarse en un nivel de rendimiento más estable y comparable dentro del conjunto general de métodos analizados.




Figura 5.9: Resultados de algoritmos en matriz de puntos (Holm and Shaffer) de las RNA y modelos de regresión en nivel de OD mínimo

5.3. RESULTADOS DE LOS ALGORITMOS EN MATRIZ DE PUNTOS (HOLM AND SHAFFER)

En general, y en concordancia con los resultados presentados anteriormente, se observa en la Figura 5.10 una comparación cualitativa entre los dos modelos con mejor desempeño; el modelo de red neuronal artificial perceptrón multicapa (MLP) y el modelo de regresión lineal múltiple (LRM), evaluados sobre el conjunto de prueba en el escenario representativo del oxígeno disuelto (OD) en el nivel mínimo. En la parte superior se observan los valores reales de OD (línea azul) junto con las predicciones obtenidas (línea roja) del modelo de regresión lineal múltiple (LRM). Se aprecia que, aunque LRM sigue la tendencia general, presenta desviaciones significativas en los picos, lo que evidencia su limitada capacidad para representar la naturaleza no lineal de los datos. En contraste, la parte inferior muestra los valores reales de OD (línea azul) y los estimados por MLP (línea roja), como se observa en esta figura, es evidente que el modelo neuronal MLP supera el desempeño de LRM evidenciando un ajuste más preciso de los valores reales, con respecto a los valores de predicción.




Figura 5.10: Resultados cualitativos de predicción de los dos modelos con mejor desempeño, MLP y LRM, para los niveles mínimo de oxígeno disuelto.

En la Figura 5.11 se puede ver una comparación cualitativa entre los dos modelos con mejor desempeño; el de la red neuronal artificial perceptrón multicapa (MLP) y el modelo de regresión lineal múltiple (LRM), evaluados sobre el conjunto de prueba en

5.3. RESULTADOS DE LOS ALGORITMOS EN MATRIZ DE PUNTOS (HOLM AND SHAFFER)

el escenario representativo del oxígeno disuelto (OD) en el nivel medio.




Figura 5.11: Resultados cualitativos de predicción de los dos modelos con mejor desempeño, MLP y LRM, para los niveles medio de oxígeno disuelto.

En la Figura 5.12 se puede ver una comparación cualitativa entre los dos modelos con mejor desempeño; el modelo de red neuronal artificial perceptrón multicapa (MLP) y el modelo de regresión lineal múltiple (LRM), evaluados sobre el conjunto de prueba en el escenario representativo del oxígeno disuelto (OD) en el nivel máximo.

5.3. RESULTADOS DE LOS ALGORITMOS EN MATRIZ DE PUNTOS (HOLM AND SHAFFER)




Figura 5.12: Resultados cualitativos de predicción de los dos modelos con mejor desempeño, MLP y LRM, para los niveles máximo de oxígeno disuelto.

Los resultados obtenidos por el modelo MLP pueden atribuirse a su capacidad para adaptarse a relaciones complejas en los datos sin requerir conocimiento previo sobre la distribución de los mismos (Haykin, 2016). Además, la capacidad del modelo neuronal artificial para ajustarse a nuevas situaciones no observadas previamente (al transformar el espacio de entrada en otro más adecuado para resolver el problema) demuestra su fortaleza como aproximador universal. A diferencia de otros modelos neuronales analizados, los MLP descomponen los datos de entrada por característica, transformándolos en un nuevo espacio mediante una combinación no lineal de los valores individuales de las características. En contraste, modelos como GRU, LSTM y Transformers procesan los valores de entrada como un solo conjunto, representado frecuentemente como un vector de representaciones de entrada (Ekman, 2021)

Por otro lado, los modelos Densa y Feedforward Simple enfatizan la importancia de seleccionar adecuadamente los componentes de la arquitectura MLP, como la función de activación, el algoritmo de aprendizaje y los hiperparámetros, para lograr resultados favorables. Sin embargo, las arquitecturas de Densa y Feedforward Simple mostraron que necesitan mejorar su arquitectura para obtener mejores resultados para predecir

5.3. RESULTADOS DE LOS ALGORITMOS EN MATRIZ DE PUNTOS (HOLM AND SHAFFER)

el oxígeno disuelto en cuerpos de agua, estas arquitecturas, al ser configuraciones básicas con pocas capas ocultas y un número limitado de neuronas, presentan una capacidad reducida para capturar la complejidad y la naturaleza no lineal de los datos. Además, su desempeño depende en gran medida de la correcta elección de los hiperparámetros como por ejemplo; la tasa de aprendizaje, número de capas ocultas, función de activación, por lo que no producen resultados satisfactorios. Sin embargo, fue esencial probar diversas arquitecturas de RNA y MR para comparar los resultados de la RNA MLP para explorar el potencial de este modelo ([*Hacia un diseño óptimo de la arquitectura Multilayer Feedforward*, 2024](#)).

Capítulo 6

Conclusiones y recomendaciones

6.1. Conclusiones

En esta sección es importante destacar un aspecto clave sobre la disponibilidad y el origen de los datos utilizados, ya que influyó directamente en el desarrollo y los alcances de este estudio. Se empleó un conjunto de datos proveniente de Estados Unidos, obtenido del UCI Machine Learning Repository, debido a que en el Estado de México no se cuenta con análisis equivalentes ni con bases de datos públicas, confiables y sistematizadas que contengan información detallada y continua sobre la calidad de los cuerpos de agua. En particular, variables fisicoquímicas como la temperatura, el pH y la conductividad eléctrica, las cuales influyen directamente en la concentración de oxígeno disuelto (OD), presentan una disponibilidad limitada y heterogénea a nivel regional, lo que dificulta el desarrollo de modelos predictivos robustos a partir de información local.

En este contexto, el uso de un conjunto de datos ampliamente validado y documentado permite el desarrollo, entrenamiento y evaluación de modelos de redes neuronales y regresión bajo un marco metodológico sólido y reproducible. Los resultados obtenidos en el presente estudio pueden servir como un punto de referencia y apoyo metodológico para investigaciones actuales y futuras enfocadas en los cuerpos de agua del Estado de México, contribuyendo a complementar la información local disponible y a fortalecer el análisis de la calidad del agua en la región.

Es importante destacar que, hasta el momento, no se han encontrado trabajos previos en el Estado de México que apliquen este tipo de modelo en cuerpos de agua, por lo que el presente estudio puede considerarse pionero en su enfoque. Asimismo, los resultados obtenidos servirán como referencia inicial y podrán ser aplicados directamente en una investigación que actualmente se está llevando a cabo en cuerpos de agua del Estado de México, con la finalidad de complementar y ampliar el conocimiento existente en la región.

Por otra parte, este estudio demuestra la eficacia de las RNA en la predicción de los niveles de OD en cuerpos de agua, utilizando parámetros fisicoquímicos como la temperatura, el pH y la conductividad eléctrica. Entre los modelos evaluados, el Perceptrón Multicapa (MLP) mostró un rendimiento superior en todos los escenarios de predicción de OD (niveles máximos, medios y mínimos), superando a los modelos tradicionales de regresión. La capacidad del MLP para capturar relaciones complejas y no lineales en los datos de calidad del agua resalta su potencial como una alternativa sólida frente a los métodos estadísticos clásicos.

El análisis del coeficiente de determinación (R^2) confirma que las redes neuronales artificiales (RNA), en particular el modelo MLP, ofrecen un desempeño superior en términos de precisión y ajuste frente a los modelos de regresión (MR) al evaluar los datos de las 37 zonas analizadas. El modelo MLP alcanzó valores de R^2 notablemente altos; 0.9897 en OD máximo, 0.9993 en el medio, y 0.9984 en el mínimo, demostrando su capacidad para adaptarse a relaciones complejas entre las variables. Cabe destacar que el coeficiente de determinación oscilan entre 0 y 1; cuanto más cercano a 1, mayor es la capacidad predictiva y la calidad del ajuste. Los resultados obtenidos reflejan que el MLP logra valores de R^2 notablemente altos, lo que evidencia su capacidad para modelar relaciones no lineales y adaptarse a la complejidad del modelo estudiado.

Las pruebas de significancia estadística (Friedman, Iman-Davenport) confirmaron la superioridad del modelo Perceptrón Multicapa (MLP) frente a otras arquitecturas de redes neuronales artificiales y métodos de regresión en la predicción del oxígeno disuelto (OD) en sus diferentes niveles. El MLP alcanzó los rankings promedio más bajos en todas las pruebas: 1.7027 en OD máximo, 1 en OD medio y 1.0541 en OD

mínimo, posicionándose como el modelo más eficaz y consistente, lo que evidencia su capacidad para aprender relaciones complejas y no lineales entre las variables ambientales y el OD. Entre las variables que influyen en los niveles de oxígeno disuelto (OD) en el cuerpo de agua. En contraste, los modelos lineales como GLM y Ridge mostraron un desempeño aceptable en niveles intermedios, pero su precisión disminuyó significativamente en nivel máximo de OD, confirmando sus limitaciones para capturar la complejidad del fenómeno. Esto sugiere que las RNA son generalmente más adaptables en contextos de predicción compleja, mientras que algunos MR pueden ser útiles en contextos intermedios. Estos hallazgos demuestran que las RNA, y en particular el MLP, ofrecen mayor estabilidad, capacidad de generalización y adaptabilidad frente a la alta variabilidad de los datos ambientales.

Las pruebas *post-hoc* de Holm-Shaffer respaldaron estos hallazgos al identificar diferencias estadísticamente significativas entre el MLP y los demás modelos. La matriz de puntos de Holm y Shaffer permitió analizar la significancia estadística de las diferencias en rendimiento entre varios algoritmos. Los resultados evidenciaron que algunos modelos como SADL-1, SADL-2 y Multi-task Lasso, presentaron un rendimiento significativamente superior, reflejado en la aparición de múltiples puntos negros en la matriz. En esta matriz, cada celda representa la comparación entre dos modelos, y la presencia de puntos negros indica que la diferencia entre ellos es estadísticamente significativa según el nivel de confianza establecido.

6.2. Recomendaciones

Para futuros proyectos, se recomienda generar bases de datos locales mediante campañas sistemáticas de muestreo en los cuerpos de agua del Estado de México, ya que la falta de información regional limita la validación de modelos predictivos. Una vez que se cuente con datos suficientes, se recomienda replicar este estudio para evaluar el desempeño de los modelos en condiciones propias de la región e incorporar variables ambientales adicionales que permitan mejorar la precisión de las predicciones.

Aunque los modelos basados en RNA, especialmente el MLP, mostraron un rendimiento sobresaliente, su desempeño puede depender significativamente de una buena configuración de hiperparámetros (número de capas, neuronas, tasa de aprendizaje, etc.). Se recomienda aplicar técnicas más avanzadas de ajuste para encontrar configuraciones más eficientes y estables. Para optimizar estos hiperparámetros y garantizar resultados más estables, se recomienda aplicar técnicas avanzadas de ajuste, tales como búsqueda aleatoria, optimización bayesiana, algoritmos evolutivos y herramientas especializadas como Keras Tuner u Optuna, complementadas con validación cruzada y estrategias de regularización.

Ya que el MLP dio buenos resultados, puede ser útil comparar su desempeño con modelos más avanzados, como redes neuronales recurrentes (LSTM, GRU) o arquitecturas Transformer. Estas redes pueden capturar relaciones temporales o secuenciales más complejas, lo que podría mejorar la predicción de oxígeno disuelto en contextos dinámicos.

Aunque las RNA demostraron ser superiores, modelos de regresión como Lasso y ElasticNet aún pueden ser útiles en entornos donde se priorice la facilidad de interpretación o cuando se disponga de menos datos. Se sugiere no descartarlos, sino más bien definir en qué contextos específicos podrían ser una mejor opción.

Referencias

- Abundez, I. M., Alejo, R., Primero Primero, F., Granda-Gutiérrez, E. E., Portillo-Rodríguez, O., y Antonio Velázquez, J. A. (2024). Threshold active learning approach for physical violence detection on images obtained from video (frame-level) using pre-trained deep learning neural network models. *Algorithms*, 17(7), 316.
- Aggarwal, C. C. (2023). *Neural networks and deep learning: A textbook* (2nd ed.). Springer. Descargado de <https://doi.org/10.1007/978-3-031-29642-0> doi: 10.1007/978-3-031-29642-0
- Agresti, A. (2018). *An introduction to categorical data analysis*. John Wiley & Sons.
- Alcocer, U. M. R., Tello-Leal, E., y Alvarado, A. B. R. (2018). Modelo basado en redes neuronales recurrentes lstm para la predicción de la siguiente actividad en procesos de negocio (lstm recurrent neural network based-model for the prediction of the next activity in business processes). *Pistas Educativas*, 40(130).
- Areerachakul, S., Junsawang, P., y Pomsathit, A. (2011). Prediction of dissolved oxygen using artificial neural network. En *Int conf comput commun manage* (Vol. 5, pp. 524-528).
- Arnáiz-González, B. (2024). *imandavenporttest: Iman davenport's modification of friedman's test*. <https://rdr.io/github/b0rxa/scmamp/man/imanDavenportTest.html>. (Accessed: 2025-10-17)
- Arreguín-Cortés, F. I., López-Pérez, M., y Cervantes-Jaimes, C. E. (2020). Los retos del agua en México. *Tecnología y ciencias del agua*, 11(2), 341-371.
- Asanza, W. R., y Olivo, B. M. (2018). *Redes neuronales artificiales aplicadas al reconocimiento de patrones*. Universidad Técnica de Machala. Descargado de <https://repositorio.utmachala.edu.ec/handle/48000/12499> (Figura 2.6: Red neuronal multicapa)
- Beltrán-Álvarez, R., Ramírez-Lozano, J. P., y Sánchez-Palacios, J. (2012). Comportamiento de la temperatura y el oxígeno disuelto en la presa picachos, sinaloa, México. *Hidrobiológica*, 22(1), 94-97.
- Bevans, R. (2023). Multiple linear regression. *A Quick Guide (Examples)*.
- Bhogal, R. K., y Singh, A. (2025). A comprehensive review of resnet-18: Architecture and

- applications. En *Advances in data-driven computing and intelligent systems* (pp. 595-607). Springer. doi: 10.1007/978-981-96-4536-7_42
- Bishop, C., y Bishop, H. (2024). *Deep learning: Foundations and concepts*. Springer Nature. Descargado de <https://www.bishopbook.com/> (Incluye explicación detallada del algoritmo de retropropagación y ajuste de pesos y sesgos)
- Bueno, F. (2019). Redes neuronales: entrenamiento y comportamiento. *Journal Name*.
- Bustamante Freire, F. S. (2023). Unidades recurrentes cerradas (gru) vs redes neuronales artificiales en la predicción de la generación eléctrica de la central hidroeléctrica illuchi. *Placeholder Journal*.
- Carrasquilla-Batista, A., Chacón-Rodríguez, A., Núñez-Montero, K., Gómez-Espinoza, O., Valverde, J., y Guerrero-Barrantes, M. (2016). Regresión lineal simple y múltiple: aplicación en la predicción de variables naturales relacionadas con el crecimiento microalgal. *Revista Tecnología en Marcha*, 29, 33-45.
- Carrera, G., y Montes Rojas, G. (2024). *Anticipar el emae para decidir mejor: modelos de nowcasting para el pronóstico de la actividad económica mensual argentina* (Inf. Téc.). Buenos Aires, Argentina: Universidad de Buenos Aires. Descargado de <https://repositorio.uba.ar/handle/123456789/XXXX> (Trabajo final de posgrado)
- Çerçi, K. N., y Hürdoğan, E. (2020). Comparative study of multiple linear regression (mlr) and artificial neural network (ann) techniques to model a solid desiccant wheel. *International communications in heat and mass transfer*, 116, 104713.
- Chaves-Chaves, E. (2024). Aplicación del Índice simplificado de calidad de agua (isqa) en la evaluación de calidad del agua en el río ocloro, san José, costa rica. *Revista Tecnología En Marcha*, 38(1), 59-67. doi: 10.18845/tm.v38i1.7027
- Chollet, F. (2021). *Deep learning with python*. Simon & Schuster.
- Chuchuca Alvarracin, B. I., y Sicha Rodríguez, J. D. (2022). *Desarrollo e implementación de un algoritmo de predicción de consumo de agua potable y visualización de los datos de consumo por usuario y sectores mediante redes neuronales recurrentes dentro del proyecto cedía-tarpuq* (B.S. thesis). Your University Name.
- Cleophas, T. J., Zwinderman, A. H., Cleophas, T. J., y Zwinderman, A. H. (2016). Non-parametric tests for three or more samples (friedman and kruskal-wallis). *Clinical data analysis on a pocket calculator: understanding the scientific methods of*

- statistical reasoning and hypothesis testing*, 193-197.
- Contreras, D. M. (2023). Evaluación de parámetros físico-químicos para determinar la calidad del agua en la laguna de Yuriria. *Jóvenes en la Ciencia*, 10(2), 45-58. Descargado de <https://www.jovenesenlaciencia.ugto.mx/index.php/jovenesenlaciencia/article/view/3990>
- Corona, J. C., Diez, H. G., y Morell, C. (2020). Un estudio empírico del modelo de red neuronal mlp para problemas de predicción con salidas múltiples. *Serie Científica de la Universidad de las Ciencias Informáticas*, 13(6), 1-14.
- DataScientest. (2023). *Prueba de friedman: ¿qué es? ¿cómo se utiliza?* Descargado de <https://datascientest.com/es/prueba-de-friedman-que-es> (Publicado el 25 de febrero de 2023)
- de Arregui, M. (2024). *Técnicas de data cleaning para garantizar datos de calidad*. Descargado de <https://www.obsbusiness.school/blog/tecnicas-de-data-cleaning-para-garantizar-datos-de-calidad> (OBS Business School)
- De Castro, F., y Merchán, M. A. (2016). The major discoveries of Cajal and his disciples: Consolidated milestones for the neuroscience of the 21st century. *Frontiers in Neuroanatomy*, 10, 85. doi: 10.3389/fnana.2016.00085
- de Jesús, J. M., Guadalupe-Ramírez, A., Ambríz-Polo, J. C., y López-González, E. (2023). Algoritmo de aprendizaje eficiente para tratar el problema del desbalance de múltiples clases. *Research in Computing Science*, 147. Descargado de https://rcs.cic.ipn.mx/2018_147_5/Algoritmo%20de%20aprendizaje%20eficiente%20para%20tratar%20el%20problema%20del%20desbalance%20de%20m%C3%BAltiples%20clases.pdf
- Dewangan, S. K., Shrivastava, S. K., Kadri, M. A., Saruta, S., Yadav, S., y Minj, N. (2024). Temperature effect on electrical conductivity (ec) and total dissolved solids (tds) of water: A review. *ResearchGate Preprint*. Descargado de https://www.researchgate.net/publication/371539432_TEMPERATURE_EFFECT_ON_ELECTRICAL_CONDUCTIVITYEC_TOTAL DISSOLVED SOLIDS_TDS_OF_WATER_A_REVIEW (Review of how temperature increases ion mobility and solubility of salts, affecting EC and TDS)
- Dhayalkar, S. R. (2025). Neural networks as universal finite-state machines: A constructive deterministic finite automaton theory. *arXiv preprint arXiv:2505.11694*.

- Descargado de <https://arxiv.org/abs/2505.11694> doi: 10.48550/arXiv.2505.11694
- Dingsen, C. (2024). Regularized machine learning. En *Regression and machine learning for education sciences using r* (pp. 52-70). Routledge. Descargado de <https://doi.org/10.4324/9781003400684-12> (Incluye explicación de Elastic Net, Lasso y Ridge en contextos de regresión regularizada) doi: 10.4324/9781003400684-12
- Domínguez, M. O. (2025). Redes neuronales artificiales. *Ingenio y Conciencia Boletín Científico de la Escuela Superior Ciudad Sahagún*, 12(23), 38-44.
- Dunigan, K., y Ferguson, P. (2024). Doxy: A dissolved oxygen monitoring system. *Sensors*, 24(10), 3253. Descargado de <https://www.mdpi.com/1424-8220/24/10/3253> doi: 10.3390/s24103253
- Díaz, I. (2023). *Contaminación del agua: causas, consecuencias y soluciones*. Descargado de <https://ecologiadigital.bio/que-se-entiende-por-contaminacion-del-agua-y-cuales-son-sus-causas-y-consecuencias/> (Consultado el 7 de marzo de 2024)
- Ekman, M. (2021). *Learning deep learning: Theory and practice of neural networks, computer vision, natural language processing, and transformers using tensor-flow*. Addison-Wesley Professional.
- Estadístico de friedman ajustado por iman-davenport*. (2023). Descargado de <https://1library.co/article/estad%C3%ADstico-de-friedman-ajustado-por-iman-davenport.q2nqx7rq> (1Library.co)
- FasterCapital. (2025). *Transformación de datos: dar forma a los datos para mejores modelos*. Descargado de <https://fastercapital.com/es/contenido/Transformacion-de-datos--dar-forma-a-los-datos-para-mejores-modelos--transformacion-de-datos-en-regresion-lineal-multiple.html> (Publicado el 23 de abril de 2025)
- Fernández, J. A., y López, S. G. (2023). *Keel – descubrimiento de datos de conocimiento*. <https://dasci.es/explora/keel/>. (DaSCI - Universidad de Granada)
- Flores-Asis, R., González-Rosas, M. K., y Rodríguez-Gasga, M. (2024). Redes neuronales artificiales (rna) para la predicción y análisis del patrón de comportamiento de aspirantes a la educación superior. *Research in Computing Science*,

153. Descargado de https://www.rcs.cic.ipn.mx/2024_153_9/Redes%20neuronales%20artificiales%20_RNA_%20para%20la%20prediccion.pdf
- Fotheringham, A. S., Oshan, T. M., y Li, Z. (2023). *Multiscale geographically weighted regression: Theory and practice*. CRC Press. Descargado de <https://doi.org/10.1201/9781003271239> (Incluye fundamentos y aplicaciones de modelos de regresión espacial) doi: 10.1201/9781003271239
- García, J., Leiva-Araos, A., Diaz-Saavedra, E., Moraga, P., Pinto, H., y Yepes, V. (2023). Relevance of machine learning techniques in water infrastructure integrity and quality: A review powered by natural language processing. *Applied Sciences*, 13(22), 12497.
- Garnica Barco, Á. (2021). *Regularización en problemas lineales de regresión: Una visión estadística y económica aplicada a datos de desarrollo humano* (B.S. thesis). Universitat Politècnica de Catalunya.
- Gerber, I. (2025). Attention is not all you need: The importance of feedforward networks in transformer models. *arXiv preprint arXiv:2505.06633*. Descargado de <https://arxiv.org/abs/2505.06633>
- Géron, A. (2019). *Hands-on machine learning with scikit-learn, keras, and tensorflow: Unsupervised learning techniques*. O'Reilly Media, Incorporated.
- Géron, A. (2022). *Hands-on machine learning with scikit-learn, keras, and tensorflow: Concepts, tools, and techniques to build intelligent systems*. O'Reilly Media, Incorporated.
- González, C. J. T., Landassuri-Moreno, V. M., Hernández, J. J. C., y Albino, J. M. F. (2024). Predicción de oxígeno disuelto en acuicultura semi-intensiva con redes neuronales artificiales. *ResearchGate*. Descargado de <https://www.researchgate.net/publication/323467394>
- Goodfellow, I., Bengio, Y., y Courville, A. (2016). *Deep learning*. MIT Press. Descargado de <https://www.deeplearningbook.org/>
- Gudiño-Sosa, L. F., Escalera-Gallardo, C., Cruz-Cárdenas, G., Moncayo-Estrada, R., Silva-García, J. T., Flores-Magallón, R., ... Chávez-Tinoco, M. A. (2023). Evaluación de la calidad del agua en un río subtropical y tributarios utilizando índices fisicoquímicos y macroinvertebrados acuáticos. *Hidrobiológica*, 32(1).

- Descargado de https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0188-88972022000100033 doi: 10.24275/uam/izt/dcbs/hidro/2022v32n1/gudino
- Guerrero, E. E. P. (2024). *Bioestadística avanzada para posgrados cuks – capítulo 13: Pruebas post-hoc*. Descargado de https://bookdown.org/edsaul_perez/bioestadaistica_avanzada/09_Poshoc.html (Universidad de Guadalajara)
- Guo, H., Chen, Z., y Teo, F. Y. (2024, noviembre). Intelligent water quality prediction system with a hybrid cnn-lstm model. *Water Practice & Technology*, 19(11), 4538-4555. (Publicado el 12 de noviembre de 2024)
- Guzmán-Ponce, A., Ferri, C., Sánchez-Garreta, J. S., y Marcial-Romero, J. R. (2022). Comportamiento de algoritmos de sobre-muestreo en big data. *Ideas en Ciencias de la Ingeniería*. Descargado de <https://ideasencienciasingenieria.uaemex.mx/article/download/19810/14772>
- Gülen, K. (2025). *Memoria a largo plazo (lstm)*. Descargado de <https://es.dataconomy.com/2025/05/08/memoria-a-largo-plazo-lstm/> (Dataconomy ES)
- Hacia un diseño óptimo de la arquitectura multilayer feedforward*. (2024). Descargado de <https://repositori.uji.es/items/829587e2-a3c7-44e2-be4b-7abfde15aab4> (Programa de Doctorado en Informática)
- Hastie, T., Tibshirani, R., Friedman, J., y Franklin, J. (2005). The elements of statistical learning: data mining, inference and prediction. *The Mathematical Intelligencer*, 27(2), 83-85.
- Haykin, S. (2016). *Neural networks and learning machines*, 3/e. Pearson Education India.
- Instituto Nacional de Estadística y Geografía (INEGI). (2021). *Estadísticas a propósito del día mundial del agua*. Descargado de <https://www.inegi.org.mx/contenidos/saladeprensa/aproposito/2021/AMBIENTE2021.pdf>
- Islam, M. A., y Biswas, S. C. (2025). *Generalized linear models and extensions*. Springer. Descargado de <https://doi.org/10.1007/978-981-96-4726-2> (Cubre teoría y aplicaciones modernas de GLM, incluyendo extensiones multivariadas y big data) doi: 10.1007/978-981-96-4726-2
- Jater, A. (2022). *Muestreo en chalma*.
- Jater, A. (2025). *Diagrama de flujo para el desarrollo del proyecto*.

- Koncagül, E., Connor, R., y Abete, V. (2024). *Informe mundial de las naciones unidas sobre el desarrollo de los recursos hídricos 2024: Agua para la prosperidad y la paz*. UNESCO - Programa Mundial de Evaluación de los Recursos Hídricos. Descargado de https://unesdoc.unesco.org/ark:/48223/pf0000388952_spa (Informe oficial sobre el estado global del agua y su relación con los ODS)
- Kronberger, G., Burlacu, B., Kommenda, M., Winkler, S. M., y Affenzeller, M. (2024). *Symbolic regression: Evolutionary algorithms for interpretable models*. Springer. (Incluye métodos de regresión, regularización y enfoques interpretables) doi: 10.1007/978-3-031-XXXXX-X
- Kruse, R., Mostaghim, S., Borgelt, C., Braune, C., y Steinbrecher, M. (2022). Multi-layer perceptrons. En *Computational intelligence* (pp. 53-124). Springer. Descargado de https://doi.org/10.1007/978-3-030-42227-1_5 doi: 10.1007/978-3-030-42227-1_5
- Kubitza, F. (2025, junio). El impacto de la calidad del agua en la salud y el rendimiento de los peces y camarones de cultivo, parte 1: oxígeno disuelto y dióxido de carbono. *Responsible Seafood Advocate*. Descargado de <https://www.globalseafood.org/advocate/el-impacto-de-la-calidad-del-agua-en-la-salud-y-el-rendimiento-de-los-peces-y-camarones-de-cultivo-parte-1-oxigeno-disuelto-y-dioxido-de-carbono/>
- Kulisz, M., y Kujawska, J. (2021). Application of artificial neural network (ann) for water quality index (wqi) prediction for the river warta, poland. En *Journal of physics: conference series* (Vol. 2130, p. 012028).
- Larance, S., y McClain, M. E. (2025). Assessing water temperature and dissolved oxygen and their effects on aquatic biodiversity. *Journal of Environmental Science and Technology*, 12(1), 25-38. doi: 10.3390/jes20200125
- Le, D. P. C., Wang, D., y Le, V. (2024). A comprehensive survey of recent transformers in image, video and diffusion models. *Computers, Materials & Continua*, 80(1), 37-60. Descargado de <https://www.techscience.com/cmc/v80n1/57376/html> doi: 10.32604/cmc.2024.050790
- Luna, S. V. G., Guaminga, H. S. M., y Tixi, J. A. M. (2023). Comparación entre modelos de regresión lineal múltiple vs redes neuronales artificiales supervisadas en la predicción de calificaciones ser bachiller 2018-2019 del ecuador. *Revista Iberoamericana*

- na de la Educación*, 7(2), 51-66. Descargado de <https://revista-iberoamericana.consultorioampuero.com/index.php/es/article/download/249/589/1295> doi: 10.31876/rie.v6i4.238
- Malenica, I., Phillips, R. V., Lazzareschi, D., Coyle, J. R., Pirracchio, R., y van der Laan, M. J. (2023). Multi-task highly adaptive lasso. *arXiv preprint arXiv:2301.12029*. Descargado de <https://arxiv.org/abs/2301.12029>
- Manogaran, G., y Lopez, D. (2017). A survey of big data architectures and machine learning algorithms in healthcare. *International Journal of Biomedical Engineering and Technology*, 25(2-4), 182-211.
- Martínez, A., y López, R. (2024). Evaluación integral de la calidad del agua: importancia de parámetros físico-químicos en la gestión sostenible. *Revista Iberoamericana de Recursos Hídricos*, 20(1), 35-50. doi: 10.5678/rirh.v20i1.2024
- Mienye, I. D. (2024). Recurrent neural networks: A comprehensive review of architectures, variants, and applications. *MDPI Information*, 15(9), 517. doi: 10.3390/info15090517
- Miranda-Piña, G., Alejo, R., Rendón-Lara, E., y García, V. (2024). Detection of violent speech against women in mexican tweets using an active learning approach. *IEEE Latin America Transactions*, 22(4), 276-285.
- Montero, L. R., Bastián, J. A., y Sanpablo, A. I. P. (2023, August). Aplicación de redes neuronales artificiales para la clasificación de actividades de la vida diaria en sujetos con enfermedad de párkinson. *Revista Mexicana de Ingeniería Biomédica*, 44(spe1). Descargado de https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0188-95322023000400128 doi: 10.17488/rmib.44.4.9
- Márquez, F. M. (2024). *Comparación entre las redes neuronales artificiales y las biológicas*. Descargado de <https://sujeto.es/comparacion-entre-las-redes-neuronales-artificiales-y-las-biologicas/> (Sujeto Blog)
- OAP, I. (2025). *Transformación de datos para su implementación en machine learning*. Descargado de <https://oap.ingeniariak.eus/2025/02/12/transformacion-de-datos-para-su-implementacion-en-machine-learning/> (Publicado el 12 de febrero de 2025)
- Olabe, X. B. (2025). *Redes neuronales artificiales y sus aplicaciones*. Escuela

- Superior de Ingeniería de Bilbao, EHU. Descargado de https://ocw.ehu.eus/pluginfile.php/40137/mod_resource/content/1/redes_neuro/contenidos/pdf/libro-del-curso.pdf (Figura 2.4: Estructura de la red neuronal artificial recurrente)
- Pajankar, A., y Joshi, A. (2022). Feedforward neural networks. En *Hands-on machine learning with python: Implement neural network solutions with scikit-learn and pytorch* (pp. 227-260). Berkeley, CA: Apress. Descargado de https://doi.org/10.1007/978-1-4842-7921-2_13 doi: 10.1007/978-1-4842-7921-2_13
- Pineda-Ríos, W., Giraldo, R., y Porcu, E. (2019). Functional sar models: With application to spatial econometrics. *Spatial Statistics*, 29, 145-159. Descargado de <https://www.sciencedirect.com/science/article/pii/S2211675318300617> doi: <https://doi.org/10.1016/j.spasta.2018.12.002>
- Ponce, M. J. M. (2024). La neurona: estructura, tipos y funciones. *Revista de Neurociencias Aplicadas*, 12(3), 45-56. Descargado de https://www.researchgate.net/publication/382424367_La_neurona
- Raghavendra, N. (2024). Drinking water contamination and its solving approaches: A comprehensive review of current knowledge and future directions. *Water, Air, & Soil Pollution*, 235. Descargado de <https://doi.org/10.1007/s11270-024-07463-0> doi: 10.1007/s11270-024-07463-0
- Rautaray, S. S., Agrawal, A., y Pandey, A. (2024). Multilayer perceptron based deep learning model for classification of covid-19 from chest x-ray images. En *2024 international conference on computing, communication and networking technologies (icccnt)* (pp. 1-6). IEEE. doi: 10.1109/ICCCNT59416.2024.11168264
- Rios Marin, F., Pena Salamanca, E. J., y Benitez Benitez, R. (2021). Efecto del ph en las tasas de bioacumulación de metales pesados en la macroalga bostrychia calliptera (rhodomelaceae, ceramiales). *Acta Biológica Colombiana*, 26(2), 226-234.
- Rodríguez, D. (2024). *Normalización de datos: Maximizando el rendimiento de los modelos de aprendizaje automático*. Descargado de <https://www.analyticslane.com/2024/03/22/normalizacion-de-datos-maximizando-el-rendimiento-de-los-modelos-de-aprendizaje-automatico/> (Analytics Lane)
- Rodríguez-Sánchez, A. E. (2023). *Redes neuronales artificiales: Principios y aplica-*

- ciones*. Rodríguez Sánchez Editorial. (Incluye diagramas de redes neuronales monocapa y multicapa)
- Rosenblatt, F. (2021). The perceptron: A probabilistic model for information storage and organization in the brain. En *Ideas that created the future*. MIT Press. Descargado de <https://direct.mit.edu/books/edited-volume/5431/chapter/3958515> (Original work published 1958)
- Ruiz, A. I. J., Primero, F. P., Eleuterio, R. A., Martínez, F. J. I., López, F. D. R., y Gutiérrez, E. E. G. (2025). Comparative analysis of artificial neural networks with classical regression models for predicting dissolved oxygen in water. *Nova Scientia*, 17(34).
- Salem, F. M. (2022). Gated rnn: The gated recurrent unit (gru) rnn. En *Recurrent neural networks: From simple to gated architectures* (pp. 85-100). Cham: Springer International Publishing. Descargado de https://doi.org/10.1007/978-3-030-89929-5_5 doi: 10.1007/978-3-030-89929-5_5
- Schmidgall, S., Ziaei, R., Achterberg, J., Kirsch, L., Hajiseyedrazi, S. P., y Eshraghian, J. (2024). Brain-inspired learning in artificial neural networks: A review. *APL Machine Learning*, 2(2), 021501. doi: 10.1063/5.0284616
- Solís-Castro, Y., Zúñiga-Zúñiga, L. A., y Mora-Alvarado, D. (2018). La conductividad como parámetro predictivo de la dureza del agua en pozos y nacientes de costa rica. *Revista Tecnología en Marcha*, 31(1), 35-46.
- TailoredRead. (2025). *Mastering lasso regression: A practical guide to regularization in scikit-learn for ai and machine learning*. TailoredRead Publishing. Descargado de <https://tailoredread.com/book/mastering-lasso-regression-practical-guide-regularization-56d4aa92d82c> (Incluye explicación de regresión regularizada, penalizaciones L1 y L2, y técnicas para evitar sobreajuste)
- Tavera-Quiroz, H., Rosso-Pinto, M., Hernández, G., Pinto, S., y Canales, F. A. (2023). Water quality analysis of a tropical reservoir based on temperature and dissolved oxygen modeling by ce-qual-w2. *Water*, 15(6), 1013. Descargado de <https://www.mdpi.com/2073-4441/15/6/1013> doi: 10.3390/w15061013
- Ubah, J., Orakwe, L., Ogbu, K., Awu, J., Ahaneku, I., y Chukwuma, E. (2021). Forecasting water quality parameters using artificial neural network for irrigation purposes. *Scientific Reports*, 11(1), 24438.

- Walpole, R. E., Myers, R. H., Myers, S. L., y Ye, K. (2024). *Probability and statistics for engineers and scientists* (9.^a ed.). Pearson Education. (Global Edition)
- Yagawa, G., y Oishi, A. (2021). Feedforward neural networks. En *Computational mechanics with neural networks* (pp. 11-23). Springer. doi: 10.1007/978-3-030-66111-3_2
- Yang, F., Moayedi, H., y Mosavi, A. (2021). *Predicting the degree of dissolved oxygen using three types of multi-layer perceptron-based artificial neural networks. sustainability* 2021, 13, 9898. s Note: MDPI stays neutral with regard to jurisdictional claims in published
- Yavuz, V. S. (2025). Impact of temperature and flow rate on oxygen dynamics in river ecosystems. *Environmental Science and Pollution Research*, 32(4), 1234-1245. doi: 10.1007/s11356-025-21987-3
- Zerpa, M. P. (2025). *Inteligencia artificial y big data en el monitoreo de la calidad del agua: Tendencias y desafíos*. Descargado de <https://www.iagua.es/blogs/mixzaida-pena-zerpa/uso-inteligencia-artificial-ia-y-big-data-monitoreo-calidad-agua> (Consultado el 7 de marzo de 2025)
- Zhang, S., Li, J., y Wang, Y. (2024). Enhanced assessment of water quality and pollutant interactions in the minjiang river. *Water*, 16(21), 3061. doi: 10.3390/w16213061
- Zhao, L., Gkountouna, O., y Pfoser, D. (2023). Spatial auto-regressive dependency interpretable learning based on spatial topological constraints. *arXiv preprint arXiv:2309.16951*. Descargado de <https://arxiv.org/pdf/2309.16951> (Incluye SADL-II para aprender independencia condicional y dependencia espacial bajo restricciones topológicas)
- Zhao, L., Gkountouna, O., y Pfoser, D. (2025). Spatial auto-regressive dependency interpretable learning based on spatial topological constraints. *ACM Transactions on Spatial Algorithms and Systems*, 5(3), 1-28. Descargado de <https://doi.org/10.1145/3339823> (Incluye equivalencia convexa y continua para restricciones topológicas espaciales en SADL-II) doi: 10.1145/3339823
- Zhao, Y., y Chen, M. (2025). Prediction of river dissolved oxygen (do) based on multi-source data and various machine learning coupling models. *PLOS ONE*, 20(3), e0319256. Descargado de <https://doi.org/10.1371/journal.pone.0319256> doi:

Referencias

10.1371/journal.pone.0319256

ANEXOS

ANEXO A: ARTÍCULO PUBLICADO

Prediction of dissolved oxygen in water bodies in the State of Mexico using artificial neural networks

Ana Ivette Jater Ruiz ¹  - Francisco Primero Primero ¹  - Roberto Alejo Eleuterio ¹  - Francisco Javier Illescas Martinez ¹  Federico del Razo López ¹  Everardo Efrén Granda Gutierrez ²  

¹ Tecnológico Nacional de México/Instituto Tecnológico de Toluca, Av. Tecnológico S/N, Col. Agrícola Bellavista, C.P. 52149, Metepec, Estado de México. División de Estudios de Posgrado e Investigación;

² Centro Universitario UAEM Atlacomulco, Universidad Autónoma del Estado de México, KM 60 Carretera Toluca-Atlacomulco, Atlacomulco 50450, México;  eegrandag@uaemex.mx

Reception: / Acceptation:

© Nova Scientia, under Creative Commons license

Abstract

Surface waters are currently exposed to pollution, causing the deterioration of these sources. Therefore, it is essential to analyze water quality through different environmental parameters. Among these, Dissolved Oxygen (DO) is a vital parameter for monitoring and maintaining water bodies. Factors such as temperature, pH, and electrical conductivity directly influence dissolved oxygen concentration. In addition, these variables facilitate predictive modeling, which allows optimizing resources and reducing costs associated with continuous monitoring over time. A viable option is to use Artificial Neural Networks (ANN), which have experienced an increase in their use and capacity to classify images and predict trends, among other applications. In this context, they are increasingly being used to predict critical water quality parameters, such as dissolved oxygen. This study compared 7 ANN architectures, showing superiority over 9 classic regression models. For this analysis, data were obtained from the Water Quality Prediction dataset hosted in the UCI Machine Learning Repository, which includes information from 37 geographic areas in the United States. Experimental results demonstrate that a Multi-Layer Perceptron, a type of neural network well-suited for capturing non-linear and complex relationships in data, achieved better performance compared to classical regression models. The MLP's superior results highlight its ability to model the intricate patterns within the dataset, as evaluated using metrics such as the coefficient of determination (R^2).

Keywords: Water quality; Physicochemical parameters; Dissolved Oxygen; Artificial Neural Network; Deep Learning.

1. Introduction

Water pollution arises from two main sources: natural contamination, which involves the transport of suspended and dissolved materials, and anthropogenic contamination, stemming from wastewater discharges, agricultural runoff, and



Article

Prediction of Physicochemical Parameters in Water Bodies Using Artificial Intelligence Techniques

Ana Ivette Jater-Ruiz ¹, Roberto Alejo Eleuterio ², Francisco Javier Illescas ², Laura Cleofas Sánchez, Federico del Razo López, Everardo Efrén Granda Gutierrez

¹ Tecnológico Nacional de México/Instituto Tecnológico de Toluca, Av. Tecnológico S/N, Col. Agrícola Bellavista, C.P. 52149, Metepec, Estado de México. División de Estudios de Posgrado e Investigación

² Centro Universitario UAEM Atlacomulco, Universidad Autónoma del Estado de México, KM 60 Carretera Toluca-Atlacomulco, Atlacomulco 50450, México; eegrandag@uaemex.mx

* Correspondence:

[†] Current address: Affiliation.

Abstract: Water preservation is among today's most urgent environmental challenges. Addressing this issue requires evaluating water quality by analyzing critical physicochemical indicators. This study investigates artificial intelligence applications in water quality assessment, focusing on specific machine learning techniques. A key focus of this work is the demand for a robust, adaptable system to predict water quality in varied environments. The main goal is to review machine learning strategies for estimating water quality, with particular attention to artificial neural networks (ANNs). ANNs are presented as versatile, effective tools, recognized for their adaptability and strong performance in analyzing conditions across diverse aquatic systems. By comparing multiple machine learning approaches, this study emphasizes the essential role of ANNs in driving precise and efficient water quality analysis.

Keywords: artificial neural networks; water; artificial intelligence; physicochemical parameters

1. Introduction

Water quality monitoring is a crucial task for preserving aquatic ecosystems and

ANEXO C: RECONOCIMIENTOS DE CONGRESOS INTERNACIONALES





EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

**EL TECNOLÓGICO NACIONAL DE MÉXICO
A TRAVÉS DEL INSTITUTO TECNOLÓGICO DE TOLUCA**

OTORGA EL PRESENTE

RECONOCIMIENTO

A

**FRANCISCO AGUSTÍN REYES GARCÍA, ANA IVETTE JATER RUIZ,
SONIA MARTÍNEZ GALLEGOS, ESTEFANÍA MARTÍNEZ TAVERA,
JAVIER ILLESCAS**

POR HABER IMPARTIDO LA PONENCIA ORAL:
"ANÁLISIS DE MICROPLÁSTICOS EN CUERPOS DE AGUA"
EN EL MARCO DEL 1ER. CONGRESO INTERNACIONAL DE DIVULGACIÓN DE LA CIENCIA
Y LA INGENIERÍA (CIDICI), QUE SE LLEVÓ A CABO DEL 19 AL 21 DE OCTUBRE DEL PRESENTE,
EN ESTA INSTITUCIÓN.

METEPEC, EDO. DE MÉXICO, OCTUBRE 2022.

"Educación, integridad y ciencia"

MARÍA ELENA ROJAS RAUDA
DIRECTORA DEL INSTITUTO TECNOLÓGICO DE TOLUCA



ANEXO D: DIPLOMADO

**Educación**
Secretaría de Educación Pública

TECNOLÓGICO
NACIONAL DE MÉXICO

EL TECNOLÓGICO NACIONAL DE MÉXICO

OTORGA EL PRESENTE

DIPLOMA

A

ANA IVETTE JATER RUIZ

POR HABER ACREDITADO

EL DIPLOMADO EN AGUA LIMPIA Y SANEAMIENTO, LLEVADO A CABO DEL 08 DE
NOVIEMBRE DEL 2024 AL 24 DE FEBRERO DEL 2025, CON UNA DURACIÓN DE 120
HORAS EN MODALIDAD EN LÍNEA.


SECRETARÍA DE EDUCACIÓN PÚBLICA
TECNOLÓGICO NACIONAL
DE MÉXICO
DIRECCIÓN GENERAL

RAMÓN JIMÉNEZ LÓPEZ
DIRECTOR GENERAL

CIUDAD DE MÉXICO, A 07 DE MARZO DE 2025



Folio: 1aP5rtyb5

ANEXO E: ESTANCIA DE INVESTIGACIÓN



ASUNTO: CARTA DE FINALIZACIÓN
DE ESTANCIA DE INVESTIGACIÓN

DR. JORGE SANCHEZ JAIME
JEFE DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN
DEL INSTITUTO TECNOLÓGICO DE TOLUCA
P R E S E N T E

La que suscribe Dra. Lourdes Loza Hernández, Coordinadora de Estudios Avanzados de la Facultad de Ingeniería de la Universidad Autónoma del Estado de México **HACE CONSTAR** que la **M.C.J.A. ANA IVETTE JATER RUIZ** alumna del programa de **Doctorado en Ciencias Ambientales** del Instituto Tecnológico de Toluca, cumplió satisfactoriamente su estancia de investigación en este organismo académico bajo la asesoría de la Dra. Rosa María Valdovinos Rosas, durante el periodo que comprende del 10 de febrero al 10 de agosto del 2025, desarrollando el proyecto: *"Estimación de oxígeno disuelto a partir de cuatro parámetros fisicoquímicos, en cuerpo de agua en el Estado de México, mediante redes neuronales artificiales"*.

A solicitud de la interesada y para los fines legales que a ella misma convergan, se extiende la presente **CONSTANCIA** en Toluca de Lerdo, Estado de México, a los ocho días del mes de septiembre del año dos mil veinticinco.

ATENTAMENTE
PATRIA, CIENCIA Y TRABAJO

"2025, 195 Años de la Apertura del Instituto Literario en la Ciudad de Toluca"


DRA. LOURDES LOZA HERNÁNDEZ



DIVISIÓN DE ESTUDIOS
AVANZADOS

COORDINADORA DE ESTUDIOS AVANZADOS DE LA FI

c.c.p. Dra. Rosa María Valdovinos Rosas – Profesor de Tiempo Completo de la Facultad de Ingeniería de la UAEMéx.
c.c.p. Archivo.



Facultad de Ingeniería, Cerro de Coatepec S/N, Ciudad Universitaria, Toluca México, Tel. (722) 2-14-06-05 / 2-15-13-51

ANEXO F: CONSTANCIAS DE CURSOS

**Educación**
Secretaría de Educación Pública

TECNOLÓGICO
NACIONAL DE MÉXICO

**EL TECNOLÓGICO NACIONAL DE MÉXICO
A TRAVÉS DEL INSTITUTO TECNOLÓGICO DE TOLUCA**

OTORGA LA PRESENTE

CONSTANCIA

A

ANA IVETTE JATER RUIZ

POR SU DESTACADA PARTICIPACIÓN COMO MODERADORA
DE LA CATEGORÍA BIENES DE CONSUMO EN LA
**CUMBRE NACIONAL DE DESARROLLO TECNOLÓGICO, EMPRENDIMIENTO E INNOVACIÓN,
INNOVATECNM 2025**
ETAPA REGIONAL, REGIÓN 4

CELEBRADO DEL 23 AL 26 DE SEPTIEMBRE
TOLUCA DE LERDO, ESTADO DE MÉXICO A 26 DE SEPTIEMBRE DE 2025


ANDREA YADIRA
ZARATE FUENTES
**SECRETARIA DE EXTENSIÓN
Y VINCULACIÓN**


MARCO ANTONIO
TRUJILLO MARTÍNEZ
**DIRECTOR DE VINCULACIÓN
E INTERCAMBIO ACADÉMICO**



**Innova
TecNM
2025**
REGIÓN 4
INSTITUTO TECNOLÓGICO DE TOLUCA





**EL TECNOLÓGICO NACIONAL DE MÉXICO
A TRAVÉS DEL INSTITUTO TECNOLÓGICO DE PUEBLA
OTORGAN EL PRESENTE**

RECONOCIMIENTO

A

ANA IVETTE JATER RUIZ

**POR SU DESTACADA PARTICIPACIÓN PRESENTANDO EL PROYECTO
APLICACIÓN PARA BANCOS DE CO₂ DE LA CATEGORÍA CAMBIO CLIMÁTICO
EN EL CERTAMEN DE PROYECTOS (NIVEL POSGRADO), DE LA
CUMBRE NACIONAL DE DESARROLLO TECNOLÓGICO, INVESTIGACIÓN E INNOVACIÓN,
INNOVATECNM 2023
ETAPA NACIONAL**

**CELEBRADO DEL 7 AL 10 DE NOVIEMBRE
HERÓICA PUEBLA DE ZARAGOZA, PUEBLA A 10 DE NOVIEMBRE DE 2023**


**MARCO ANTONIO
TRUJILLO MARTÍNEZ**

**DIRECTOR DE VINCULACIÓN
E INTERCAMBIO ACADÉMICO**





EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO



EL TECNOLÓGICO NACIONAL DE MÉXICO
OTORGA EL PRESENTE

RECONOCIMIENTO

A

ANA IVETTE JATER RUIZ

POR SU DESTACADA PARTICIPACIÓN PRESENTANDO
EL PROYECTO APLICACIÓN PARA BANCOS DE CO₂
DE LA CATEGORÍA CAMBIO CLIMÁTICO (NIVEL POSGRADO), EN LA
CUMBRE NACIONAL DE DESARROLLO TECNOLÓGICO, INVESTIGACIÓN E INNOVACIÓN,
INNOVATECNM 2023
ETAPA REGIONAL, REGIÓN 4


MARCO ANTONIO TRUJILLO MARTÍNEZ
DIRECTOR DE VINCULACIÓN
E INTERCAMBIO ACADÉMICO





EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

**EL TECNOLÓGICO NACIONAL DE MÉXICO
A TRAVÉS DEL INSTITUTO TECNOLÓGICO DE TOLUCA**

OTORGA EL PRESENTE

RECONOCIMIENTO

A

**IVAN GAYTÁN AGUILAR,
ANA IVETTE JATER RUIZ,
OCTAVIO VILLEGAS CAMACHO,
KARLA SILVAN DÍAZ**

POR HABER OBTENIDO EL PRIMER LUGAR
EN LA CUMBRE NACIONAL DE DESARROLLO TECNOLÓGICO, INVESTIGACIÓN
E INNOVACIÓN "INNOVATECNM 2023". FASE LOCAL,
CON EL PROYECTO: "APLICACIÓN PARA BANCOS DE CO₂"
EN LA CATEGORÍA: "CAMBIO CLIMÁTICO"
QUE SE LLEVÓ A CABO EL 30 DE MAYO DEL PRESENTE, EN ESTA INSTITUCIÓN.

METEPEC, EDO. DE MÉXICO, MAYO 2023.

Educación, integridad y ciencia



HUGO ERNESTO CUÉLLAR CARREÓN DIRECCIÓN
DIRECTOR DEL INSTITUTO TECNOLÓGICO DE TOLUCA





INSTITUTO AMBIENTAL GIS

Academia de enseñanza a distancia, entrega el presente diploma
de culminación al alumno/a:

ANA IVETTE JATER RUIZ

Por haber asistido y concluido satisfactoriamente
El Desafío SIG desde CERO
Biodiversidad y Medio Ambiente

Introducción al Modelado de Nicho Ecológico y Geoportales
Análisis Visual de Imágenes e Índices Espectrales con Google Earth Engine, ArcGIS, QGIS y R.
Análisis exploratorio de datos (EDA) con R.
Multitemporal de la Deforestación con Imágenes Radar y Google Earth Engine.

Equivalente a 30 horas académicas presenciales

Steven Mora
Representante Legal Instituto
Ambiental GIS
Master of Science
(Geospatial Information
Science & Systems)

13/01/2023
ESCUELA
AMBIENTAL GIS

Orlando Advíncula Zeballos
Docente: Orlando Advíncula
Zeballos
Magister en Ecosistemas y
Recursos Acuáticos



Universidad Autónoma del Estado de México

La Secretaría de Investigación y Estudios Avanzados

Otorga la presente

Constancia

a la

MCIA Ana Ivette Jater Ruiz

Por su asistencia al **Taller. "Redacción de textos científicos"**,
modalidad virtual.

Toluca, México, 25 de marzo de 2022.

Patria, Ciencia y Trabajo

"2022, Celebración de los 195 Años de la Apertura de las Clases en el Instituto Literario"

Doctora en Ciencias Sociales
Martha Patricia Zarza Delgado

Secretaría de Investigación y Estudios Avanzados

ADMINISTRACIÓN
UNIVERSITARIA
2021-2025

SIEA



Universidad Autónoma del Estado de México

La Secretaría de Investigación y Estudios Avanzados

Otorga la presente

Constancia

a la

MCIA Ana Ivette Jater Ruiz

Por su asistencia al **Taller. "Uso de herramientas para artículos científicos"**, modalidad virtual.

Toluca, México, 24 de marzo de 2022.

Patria, Ciencia y Trabajo

"2022, Celebración de los 195 Años de la Apertura de las Clases en el Instituto Literario"



Doctora en Ciencias Sociales
Martha Patricia Zarza Delgado

Secretaría de Investigación y Estudios Avanzados

ADMINISTRACIÓN
UNIVERSITARIA
2021-2025

SIEA



CCIQS
UAEM-UNAM



otorga la presente

CONSTANCIA

a: Ana Ivette Jater Ruiz

Por su asistencia al curso en línea : **"Electrospinning, una herramienta versátil para la obtención de materiales avanzados"**, realizado los días 6, 7 y 8 de julio de 2022, mediante la plataforma zoom, con una duración de 9 horas.

Toluca, Estado de México, a 8 de julio de 2022

Dra. Dora Alicia Solís Casados
COORDINADORA
CCIQS UAEM-UNAM





EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



**TECNOLÓGICO
NACIONAL DE MÉXICO**

EL TECNOLÓGICO NACIONAL DE MÉXICO
A TRAVÉS DEL INSTITUTO TECNOLÓGICO DE GUSTAVO A. MADERO II

OTORGA LA PRESENTE

CONSTANCIA

A

Ana Ivette Jater Ruiz

POR SU VALIOSA PARTICIPACIÓN Y ACREDITACIÓN DEL
"TALLER 2. INVESTIGAR, PUBLICAR Y PROTECCIÓN DE PRODUCTOS DERIVADOS DE LA
CIENCIA"
EN EL MARCO DEL "PROGRAMA DE INVESTIGACIÓN E INNOVACIÓN TECNOLÓGICA, PIIT DEL
ITGAM II"

Llevado a cabo del 02 al 05 de febrero del 2021, con una duración de 30 horas.

El Bien, La Verdad Y La Belleza, Desarrollo De La Humanidad

Excelencia en Educación Tecnológica®

ING. OSCAR CASTELLANOS HERNÁNDEZ

DIRECTOR

TNM_034_06_2021_05

CIUDAD DE MÉXICO A 16 DE MARZO DEL 2021.



ANEXOS

ANEXO A: ARTÍCULO PUBLICADO

Prediction of dissolved oxygen in water bodies in the State of Mexico using artificial neural networks

Ana Ivette Jater Ruiz ¹  - Francisco Primero Primero ¹  - Roberto Alejo Eleuterio ¹  - Francisco Javier Illescas Martinez ¹  Federico del Razo López ¹  Everardo Efrén Granda Gutierrez ²  

¹ Tecnológico Nacional de México/Instituto Tecnológico de Toluca, Av. Tecnológico S/N, Col. Agrícola Bellavista, C.P. 52149, Metepec, Estado de México. División de Estudios de Posgrado e Investigación;

² Centro Universitario UAEM Atlacomulco, Universidad Autónoma del Estado de México, KM 60 Carretera Toluca-Atlacomulco, Atlacomulco 50450, México;  eegrandag@uaemex.mx

Reception: / Acceptation:

© Nova Scientia, under Creative Commons license

Abstract

Surface waters are currently exposed to pollution, causing the deterioration of these sources. Therefore, it is essential to analyze water quality through different environmental parameters. Among these, Dissolved Oxygen (DO) is a vital parameter for monitoring and maintaining water bodies. Factors such as temperature, pH, and electrical conductivity directly influence dissolved oxygen concentration. In addition, these variables facilitate predictive modeling, which allows optimizing resources and reducing costs associated with continuous monitoring over time. A viable option is to use Artificial Neural Networks (ANN), which have experienced an increase in their use and capacity to classify images and predict trends, among other applications. In this context, they are increasingly being used to predict critical water quality parameters, such as dissolved oxygen. This study compared 7 ANN architectures, showing superiority over 9 classic regression models. For this analysis, data were obtained from the Water Quality Prediction dataset hosted in the UCI Machine Learning Repository, which includes information from 37 geographic areas in the United States. Experimental results demonstrate that a Multi-Layer Perceptron, a type of neural network well-suited for capturing non-linear and complex relationships in data, achieved better performance compared to classical regression models. The MLP's superior results highlight its ability to model the intricate patterns within the dataset, as evaluated using metrics such as the coefficient of determination (R^2).

Keywords: Water quality; Physicochemical parameters; Dissolved Oxygen; Artificial Neural Network; Deep Learning.

1. Introduction

Water pollution arises from two main sources: natural contamination, which involves the transport of suspended and dissolved materials, and anthropogenic contamination, stemming from wastewater discharges, agricultural runoff, and



Article

Prediction of Physicochemical Parameters in Water Bodies Using Artificial Intelligence Techniques

Ana Ivette Jater-Ruiz ¹, Roberto Alejo Eleuterio ², Francisco Javier Illescas ², Laura Cleofas Sánchez, Federico del Razo López, Everardo Efrén Granda Gutierrez

¹ Tecnológico Nacional de México/Instituto Tecnológico de Toluca, Av. Tecnológico S/N, Col. Agrícola Bellavista, C.P. 52149, Metepec, Estado de México. División de Estudios de Posgrado e Investigación

² Centro Universitario UAEM Atlacomulco, Universidad Autónoma del Estado de México, KM 60 Carretera Toluca-Atacomulco, Atlacomulco 50450, México; eegrandag@uaemex.mx

* Correspondence:

[†] Current address: Affiliation.

Abstract: Water preservation is among today's most urgent environmental challenges. Addressing this issue requires evaluating water quality by analyzing critical physicochemical indicators. This study investigates artificial intelligence applications in water quality assessment, focusing on specific machine learning techniques. A key focus of this work is the demand for a robust, adaptable system to predict water quality in varied environments. The main goal is to review machine learning strategies for estimating water quality, with particular attention to artificial neural networks (ANNs). ANNs are presented as versatile, effective tools, recognized for their adaptability and strong performance in analyzing conditions across diverse aquatic systems. By comparing multiple machine learning approaches, this study emphasizes the essential role of ANNs in driving precise and efficient water quality analysis.

Keywords: artificial neural networks; water; artificial intelligence; physicochemical parameters

1. Introduction

Water quality monitoring is a crucial task for preserving aquatic ecosystems and

ANEXO C: RECONOCIMIENTOS DE CONGRESOS INTERNACIONALES

**EDUCACIÓN**
SECRETARÍA DE EDUCACIÓN PÚBLICA

**TECNOLÓGICO
NACIONAL DE MÉXICO**

**EL TECNOLÓGICO NACIONAL DE MÉXICO
A TRAVÉS DEL INSTITUTO TECNOLÓGICO DE TOLUCA**

OTORGA EL PRESENTE

RECONOCIMIENTO

A

**ANA IVETTE JATER RUIZ
FRANCISCO JAVIER ILLESCAS MARTÍNEZ**

POR HABER IMPARTIDO LA PONENCIA ORAL:
"APLICACIÓN DE REDES NEURONALES PARA DETERMINAR PARÁMETROS
FISICOQUÍMICOS EN UN CUERPO DE AGUA EN EL ESTADO DE MÉXICO"
EN EL MARCO DEL 2DO. CONGRESO INTERNACIONAL DE DIVULGACIÓN DE LA CIENCIA
Y LA INGENIERÍA (CIDICI 2023), QUE SE LLEVÓ A CABO DEL 25 AL 27 DE OCTUBRE
DEL PRESENTE, EN ESTA INSTITUCIÓN.
METEPEC, EDO. DE MÉXICO. OCTUBRE 2023.
"Educación, integridad y ciencia"

**DIRECCIÓN**
HUGO ERNESTO CUÉLLAR CARREÓN
DIRECTOR DEL INSTITUTO TECNOLÓGICO DE TOLUCA







EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

**EL TECNOLÓGICO NACIONAL DE MÉXICO
A TRAVÉS DEL INSTITUTO TECNOLÓGICO DE TOLUCA**

OTORGA EL PRESENTE

RECONOCIMIENTO

A


**FRANCISCO AGUSTÍN REYES GARCÍA, ANA IVETTE JATER RUIZ,
SONIA MARTÍNEZ GALLEGOS, ESTEFANÍA MARTÍNEZ TAVERA,
JAVIER ILLESCAS**

POR HABER IMPARTIDO LA PONENCIA ORAL:
"ANÁLISIS DE MICROPLÁSTICOS EN CUERPOS DE AGUA"
EN EL MARCO DEL 1ER. CONGRESO INTERNACIONAL DE DIVULGACIÓN DE LA CIENCIA
Y LA INGENIERÍA (CIDICI), QUE SE LLEVÓ A CABO DEL 19 AL 21 DE OCTUBRE DEL PRESENTE,
EN ESTA INSTITUCIÓN.

METEPEC, EDO. DE MÉXICO, OCTUBRE 2022.

"Educación, integridad y ciencia"

MARÍA ELENA ROJAS RAUDA
DIRECTORA DEL INSTITUTO TECNOLÓGICO DE TOLUCA



ANEXO D: DIPLOMADO

**Educación**
Secretaría de Educación Pública

TECNOLÓGICO
NACIONAL DE MÉXICO

EL TECNOLÓGICO NACIONAL DE MÉXICO

OTORGA EL PRESENTE

DIPLOMA

A

ANA IVETTE JATER RUIZ

POR HABER ACREDITADO

EL DIPLOMADO EN AGUA LIMPIA Y SANEAMIENTO, LLEVADO A CABO DEL 08 DE
NOVIEMBRE DEL 2024 AL 24 DE FEBRERO DEL 2025, CON UNA DURACIÓN DE 120
HORAS EN MODALIDAD EN LÍNEA.


SECRETARÍA DE EDUCACIÓN PÚBLICA
TECNOLÓGICO NACIONAL
DE MÉXICO
DIRECCIÓN GENERAL


RAMÓN JIMÉNEZ LÓPEZ
DIRECTOR GENERAL

CIUDAD DE MÉXICO, A 07 DE MARZO DE 2025


Folio: LuAPhtyG6

ANEXO E: ESTANCIA DE INVESTIGACIÓN



Universidad Autónoma del Estado de México

ASUNTO: CARTA DE FINALIZACIÓN
DE ESTANCIA DE INVESTIGACIÓN

DR. JORGE SANCHEZ JAIME
JEFE DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN
DEL INSTITUTO TECNOLÓGICO DE TOLUCA
P R E S E N T E

La que suscribe Dra. Lourdes Loza Hernández, Coordinadora de Estudios Avanzados de la Facultad de Ingeniería de la Universidad Autónoma del Estado de México **HACE CONSTAR** que la **M.C.J.A. ANA IVETTE JATER RUIZ** alumna del programa de **Doctorado en Ciencias Ambientales** del Instituto Tecnológico de Toluca, cumplió satisfactoriamente su estancia de investigación en este organismo académico bajo la asesoría de la Dra. Rosa María Valdovinos Rosas, durante el periodo que comprende del 10 de febrero al 10 de agosto del 2025, desarrollando el proyecto: *"Estimación de oxígeno disuelto a partir de cuatro parámetros físicoquímicos, en cuerpo de agua en el Estado de México, mediante redes neuronales artificiales"*.

A solicitud de la interesada y para los fines legales que a ella misma convengan, se extiende la presente **CONSTANCIA** en Toluca de Lerdo, Estado de México, a los ocho días del mes de septiembre del año dos mil veinticinco.

ATENTAMENTE

PATRIA, CIENCIA Y TRABAJO

"2025, 195 Años de la Apertura del Instituto Literario en la Ciudad de Toluca"



DRA. LOURDES LOZA HERNÁNDEZ

COORDINACIÓN DE ESTUDIOS
AVANZADOS

COORDINADORA DE ESTUDIOS AVANZADOS DE LA FI

c.c.p. Dra. Rosa María Valdovinos Rosas – Profesor de Tiempo Completo de la Facultad de Ingeniería de la UAEMéx.
c.c.p. Archivo.



Facultad de Ingeniería, Correo de Costepec S/N, Ciudad Universitaria, Toluca México, Tel. (722) 2-14-00-00 / 2-15-13-01

ANEXO F: CONSTANCIAS DE CURSOS





**EL TECNOLÓGICO NACIONAL DE MÉXICO
A TRAVÉS DEL INSTITUTO TECNOLÓGICO DE PUEBLA
OTORGAN EL PRESENTE**

RECONOCIMIENTO

A


ANA IVETTE JATER RUIZ

**POR SU DESTACADA PARTICIPACIÓN PRESENTANDO EL PROYECTO
APLICACIÓN PARA BANCOS DE CO₂, DE LA CATEGORÍA CAMBIO CLIMÁTICO
EN EL CERTAMEN DE PROYECTOS (NIVEL POSGRADO), DE LA
CUMBRE NACIONAL DE DESARROLLO TECNOLÓGICO, INVESTIGACIÓN E INNOVACIÓN,
INNOVATECNM 2023
ETAPA NACIONAL**

**CELEBRADO DEL 7 AL 10 DE NOVIEMBRE
HERÓICA PUEBLA DE ZARAGOZA, PUEBLA A 10 DE NOVIEMBRE DE 2023**


**MARCO ANTONIO
TRUJILLO MARTÍNEZ**

**DIRECTOR DE VINCULACIÓN
E INTERCAMBIO ACADÉMICO**





EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO



EL TECNOLÓGICO NACIONAL DE MÉXICO
OTORGA EL PRESENTE


RECONOCIMIENTO

A

ANA IVETTE JATER RUIZ

POR SU DESTACADA PARTICIPACIÓN PRESENTANDO
EL PROYECTO APLICACIÓN PARA BANCOS DE CO₂
DE LA CATEGORÍA CAMBIO CLIMÁTICO (NIVEL POSGRADO), EN LA
CUMBRE NACIONAL DE DESARROLLO TECNOLÓGICO, INVESTIGACIÓN E INNOVACIÓN,
INNOVATECNM 2023
ETAPA REGIONAL, REGIÓN 4

MARCO ANTONIO TRUJILLO MARTÍNEZ
DIRECTOR DE VINCULACIÓN
E INTERCAMBIO ACADÉMICO





EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

**EL TECNOLÓGICO NACIONAL DE MÉXICO
A TRAVÉS DEL INSTITUTO TECNOLÓGICO DE TOLUCA**

OTORGA EL PRESENTE

RECONOCIMIENTO

A

**IVAN GAYTÁN AGUILAR,
ANA IVETTE JATER RUIZ,
OCTAVIO VILLEGAS CAMACHO,
KARLA SILVAN DÍAZ**


POR HABER OBTENIDO EL PRIMER LUGAR
EN LA CUMBRE NACIONAL DE DESARROLLO TECNOLÓGICO, INVESTIGACIÓN
E INNOVACIÓN "INNOVATECNM 2023". FASE LOCAL,
CON EL PROYECTO: "APLICACIÓN PARA BANCOS DE CO₂"
EN LA CATEGORÍA: "CAMBIO CLIMÁTICO"
QUE SE LLEVÓ A CABO EL 30 DE MAYO DEL PRESENTE, EN ESTA INSTITUCIÓN

METEPEC, EDO. DE MÉXICO, MAYO 2023.

"Educación, integridad y ciencia"



HUGO ERNESTO CUÉLLAR CARREÓN DIRECCIÓN
DIRECTOR DEL INSTITUTO TECNOLÓGICO DE TOLUCA





INSTITUTO AMBIENTAL GIS

Academia de enseñanza a distancia, entrega el presente diploma
de culminación al alumno/a:

ANA IVETTE JATER RUIZ

Por haber asistido y concluido satisfactoriamente
El Desafío SIG desde CERO
Biodiversidad y Medio Ambiente

Introducción al Modelado de Nicho Ecológico y Geoportales
Análisis Visual de Imágenes e Índices Espectrales con Google Earth Engine, ArcGIS, QGIS y R.
Análisis exploratorio de datos (EDA) con R.
Multitemporal de la Deforestación con Imágenes Radar y Google Earth Engine.

Equivalente a 30 horas académicas presenciales

Steven Mora
Representante Legal Instituto
Ambiental GIS
Master of Science
(Geographical Information
Science & Systems)

13/01/2023
ESCUELA
AMBIENTAL GIS

Orlando Advíncula Zeballos
Docente: Orlando Advíncula
Zeballos
Magister en Ecosistemas y
Recursos Acuáticos



Universidad Autónoma del Estado de México

La Secretaría de Investigación y Estudios Avanzados

Otorga la presente

Constancia

a la

MCIA Ana Ivette Jater Ruiz

Por su asistencia al **Taller. "Redacción de textos científicos"**,
modalidad virtual.

Toluca, México, 25 de marzo de 2022.

Patria, Ciencia y Trabajo

"2022, Celebración de los 195 Años de la Apertura de las Clases en el Instituto Literario"



Doctora en Ciencias Sociales
Martha Patricia Zarza Delgado

Secretaria de Investigación y Estudios Avanzados

ADMINISTRACIÓN
UNIVERSITARIA
2021-2025

SIEA



Universidad Autónoma del Estado de México

La Secretaría de Investigación y Estudios Avanzados

Otorga la presente

Constancia

a la

MCIA Ana Ivette Jater Ruiz

Por su asistencia al **Taller. “Uso de herramientas para artículos científicos”**, modalidad virtual.

Toluca, México, 24 de marzo de 2022.

Patria, Ciencia y Trabajo

“2022, Celebración de los 195 Años de la Apertura de las Clases en el Instituto Literario”



Doctora en Ciencias Sociales
Martha Patricia Zarza Delgado

Secretaría de Investigación y Estudios Avanzados

ADMINISTRACIÓN
UNIVERSITARIA
2021-2025

SIEA



CCIQS
UAEM-UNAM



otorga la presente


CONSTANCIA

a: Ana Ivette Jater Ruiz

Por su asistencia al curso en línea : **"Electrospinning, una herramienta versátil para la obtención de materiales avanzados"**, realizado los días 6, 7 y 8 de julio de 2022, mediante la plataforma zoom, con una duración de 9 horas.

Toluca, Estado de México, a 8 de julio de 2022


Dra. Dora Alicia Solís Casados
COORDINADORA
CCIQS UAEM-UNAM





EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



**TECNOLÓGICO
NACIONAL DE MÉXICO**

EL TECNOLÓGICO NACIONAL DE MÉXICO
A TRAVÉS DEL INSTITUTO TECNOLÓGICO DE GUSTAVO A. MADERO II

OTORGA LA PRESENTE

CONSTANCIA

A

Ana Ivette Jater Ruiz

POR SU VALIOSA PARTICIPACIÓN Y ACREDITACIÓN DEL
"TALLER 2. INVESTIGAR, PUBLICAR Y PROTECCIÓN DE PRODUCTOS DERIVADOS DE LA
CIENCIA"
EN EL MARCO DEL "PROGRAMA DE INVESTIGACIÓN E INNOVACIÓN TECNOLÓGICA, PIIT DEL
ITGAM II"

Llevado a cabo del 02 al 05 de febrero del 2021, con una duración de 30 horas.

El Bien, La Verdad Y La Belleza, Desarrollo De La Humanidad

Excelencia en Educación Tecnológica®

ING. OSCAR CASTELLANOS HERNÁNDEZ

DIRECTOR

TNM_034_06_2021_05

CIUDAD DE MÉXICO A 16 DE MARZO DEL 2021.

