





Estimación de la Demanda Bioquímica de Oxígeno (DBO₅) en aguas residuales de las empresas de jeans de la ciudad de Pelileo utilizando redes neuronales artificiales

*Estimation of the Biochemical Oxygen Demand (DBO₅),
in wastewater of the jeans companies of the city of Pelileo
using artificial neural networks*

- ¹ Yesenia Esthelfania Pillapa Vargas  <https://orcid.org/0000-0001-9357-7914>
Universidad Técnica de Ambato, Facultad de Ciencia e Ingeniería en Alimentos y Biotecnología. Ambato-Ecuador,
ypillapa2034@uta.edu.ec
- ² Manolo Alexander Córdova Suárez  <https://orcid.org/0000-0001-6786-7926>
Universidad Nacional de Chimborazo, Facultad de Ingeniería, Riobamba-Ecuador
manolo.cordova@unach.edu.ec
- ³ Daniel Alfonso Cabrera Valle 
Universidad Técnica de Ambato, Facultad de Ciencia e Ingeniería en Alimentos y Biotecnología. Ambato-Ecuador
da.cabrera@uta.edu.ec



Artículo de Investigación Científica y Tecnológica

Enviado: 18/05/2022

Revisado: 27/06/2022

Aceptado: 01/07/2022

Publicado: 30/07/2022

DOI: <https://doi.org/10.33262/concienciadigital.v5i3.1.2320>

Cítese: Pillapa Vargas, Y. E., Córdova Suárez, M. A., & Cabrera Valle, D. A. (2022). Estimación de la Demanda Bioquímica de Oxígeno (DBO₅) en aguas residuales de las empresas de jeans de la ciudad de Pelileo utilizando redes neuronales artificiales. *Conciencia Digital*, 5(3.1), 406-423. <https://doi.org/10.33262/concienciadigital.v5i3.1.2320>



CONCIENCIA DIGITAL, es una revista multidisciplinar, **trimestral**, que se publicará en soporte electrónico tiene como **misión** contribuir a la formación de profesionales competentes con visión humanística y crítica que sean capaces de exponer sus resultados investigativos y científicos en la misma medida que se promueva mediante su intervención cambios positivos en la sociedad. <https://concienciadigital.org>

La revista es editada por la Editorial Ciencia Digital (Editorial de prestigio registrada en la Cámara Ecuatoriana de Libro con No de Afiliación 663) www.celibro.org.ec

Esta revista está protegida bajo una licencia Creative Commons Attribution Non Commercial No Derivatives 4.0 International. Copia de la licencia: <http://creativecommons.org/licenses/by-nc-nd/4.0/>

Palabras claves:

DBO5, aguas residuales, inteligencia artificial, redes neuronales artificiales, red feed-forward backpropagation, jeans.

Keywords:

DBO5, wastewater, artificial intelligence, artificial neural networks, red feedforward backpropagation, jeans.

Resumen

Introducción. Dentro de la inteligencia artificial, el uso de redes neuronales artificiales toma cada vez más importancia. **Objetivo.** Estimar el error de la Demanda Bioquímica de Oxígeno en aguas residuales de las empresas de jeans de la ciudad de Pelileo utilizando redes neuronales. **Métodos.** En primer lugar, se desarrolló una base de datos conformada por 6 parámetros físicos, 9 parámetros químicos y una variable de salida. Estas variables se seleccionaron mediante la Norma TUSLA y fueron recopiladas del catastro del GAD Pelileo de los años 2017-2018 y de un laboratorio de análisis de aguas certificado. A continuación, se utilizó el software Matlab con el diseño de la red neuronal artificial *feed forward backpropagation* con la capa de entrada de 15 variables. La primera capa oculta tuvo diez neuronas, la segunda capa sumatoria con una neurona y la capa de salida con la variable de respuesta correspondiente a la estimación de la Demanda Bioquímica de Oxígeno con el algoritmo de aprendizaje de Levenberg-Marquardt. **Resultados.** Se obtuvo valores del coeficiente de correlación, del error estimado de la red, y de la comparación de la Prueba Tukey, tales como: 0.98081; 0.8890; 0.9833. Estas cifras revelan una concordancia entre los valores estimados por la red y los valores reales. Finalmente, los resultados demostraron que la Demanda Bioquímica de Oxígeno se estimó numéricamente en aguas residuales a través de los modelos neuronales. Este tipo de modelo de neuronas representa sólo una parte de la función matemática que la red construye a partir del conjunto de observaciones.

Abstract

Introduction. Within artificial intelligence, the use of artificial neural networks is becoming increasingly important. **Objective.** Estimate the error of the Biochemical Oxygen Demand in wastewater from laundries of jeans of the city of Pelileo using neural networks. **Methods.** First, a database consisting of six physical parameters, nine chemical parameters and an output variable was developed. These variables were selected using the TUSLA Standard and were compiled from the cadastre of the GAD Pelileo of the years 2017-2018 and a certified water analysis laboratory. Next, the Matlab software was used with the design of the Artificial Neural Network FeedForward Backpropagation with the input layer of fifteen variables. The first hidden layer had ten neurons, the second

summatory layer with one neuron and the output layer with the response variable corresponding to the estimation of the Biochemical Oxygen Demand with the Levenberg-Marquardt learning algorithm. **Results.** Values of the correlation coefficient, the estimated network error, and the comparison of the Tukey Test were obtained, such as: 0.98081; 0.8890; 0.9833. These figures reveal a concordance between the values estimated by the network and the actual values. Finally, the results showed that Biochemical Oxygen Demand was estimated numerically in wastewater through neural models. This type of model of neurons represents only part of the mathematical function that the network builds from the set of observations.

Introducción

En los últimos años, el tema de la contaminación ambiental ha recibido más atención debido al aumento de los riesgos de los agentes contaminantes en todo el mundo (Maina et al., 2017). Sin embargo, la producción de muchas sustancias que no pueden ser asimiladas por el ecosistema, el daño al medio ambiente y a la salud es cada vez más evidente, traduciéndose en un aumento del consumo de energía y recursos, estos residuos peligrosos se generan con el desarrollo de agricultura, textiles, servicios e incluso actividades domésticas. De hecho, debido al progreso de la economía mundial, la cantidad de residuos va en aumento (Sigcha & Jordán, 2018; Programa Mundial de Evaluación de los Recursos Hídricos de las Naciones Unidas [WWAP], 2017).

Según la United Nations Climate Change News (2018), el sector industrial textil genera el 20% del desperdicio total de agua a nivel mundial a causa de los productos de teñido y acabado. El 10% por las emisiones globales de carbono, considerando que se requiere de un promedio de más de 7.500 litros de agua para producir unos jeans, que es la misma cantidad de agua que la persona promedio bebe en siete años, por ende, la industria textil es el segundo contaminante del mundo (Conferencia de la ONU sobre Comercio y Desarrollo [UNCTAD], 2019).

La industria textil y de confecciones del país es una de las principales consumidoras de agua, energía y productos químicos en la producción, lo que a su vez genera grandes cantidades de aguas residuales (Samanta et al., 2019). La contaminación de aguas residuales de impresión y teñido de textiles es causada por impurezas o residuos en las materias primas, y muchos productos químicos no se absorben completamente en la tela. Estas sustancias se liberan al agua junto con otros contaminantes. Estas aguas residuales, contienen altas concentraciones de pigmentos, contaminantes orgánicos, compuestos

tóxicos, inhibidores, cloro y tensioactivos, siendo de esta manera parte de la degradación ambiental, generando impactos ambientales relacionados con las aguas residuales que produce y la carga química que contiene (Ministerio del Ambiente, 2015; Romero et al., 2016).

El Cantón Pelileo es el principal productor de jeans del país. Con una producción del 70% a escala nacional y el 30% restante se vende en Cuenca, Quito, Guayaquil y otras ciudades (GAD Pelileo, 2019). Según la encuesta de producción en la provincia de Tungurahua, en la ciudad de Pelileo existe unas 1.100 fábricas textiles y 46 lavanderías de jeans. Por su parte, las industrias textiles y de jeans de Pelileo se han convertido en un sector económico representativo de la sociedad. Sin embargo, está catalogada como una actividad muy contaminante por su altísimo consumo de agua, debido a que cada prenda tratada requiere una media de 80 litros de agua y utiliza alrededor de 8.000 productos químicos en diversos procesos (Kant, 2012; Luongo, 2015). Se ha verificado que las aguas residuales de salida provienen principalmente de las siguientes etapas: desgasificación (15%), desengrasado (20%), blanqueo (45%) y lavado (30%). Durante este proceso, los productos químicos como: colorantes, ácidos, bases, sales se eliminan y pasan a formar parte de las aguas residuales finales (Choudhury, 2017; Kishor et al., 2021).

Para el análisis de la calidad del agua es necesario considerar aspectos físicos, químicos y microbiológicos (Quintero & Cardona, 2012). Los métodos de tratamiento ineficaces de las aguas residuales descargadas por las empresas de estampado y teñido de textiles han causado diversos grados de contaminación en los ecosistemas; por esta razón la norma ambiental del Texto Unificado de la Legislación Secundaria del Ministerio del Ambiente en el Libro XI (TULSMA), establece los límites de descarga para los sistemas de alcantarillado público, requiriendo medir una variedad de parámetros que incluyen: demanda bioquímica de oxígeno (DBO_5), DQO, pH, grasa, nitrógeno, fósforo, sulfato, sólidos suspendidos y más. Estas sustancias similares se encuentran en la composición de las aguas residuales de la industria textil y se analizan mediante diferentes métodos físicos y químicos (Norma de Calidad Ambiental y Descarga de Efluentes, 2011).

El desarrollo industrial textil en la Ciudad de Pelileo ha generado un incremento en el número de las lavadoras de jeans, causando problemas de contaminación del agua del sector. Desde 2018, los organismos de control vienen monitoreando la generación de residuos sólidos, líquidos y gaseosos contaminantes, minimizándolos como lo exige la legislación vigente, pero con un alto costo para las empresas (GAD Pelileo, 2019).

De esta manera, se busca interactuar las Redes Neuronales Artificiales con los parámetros de calidad de agua relacionados. Estas redes neuronales son definidas como un sistema que permite establecer una relación entre las entradas y la salida, inspiradas en el sistema nervioso de un ser vivo, tratando de imitar el comportamiento del cerebro, y

diferenciándose de la computación tradicional (McCulloch & Pitts, 1990). Estas redes neuronales artificiales son similares a un cerebro y, por lo tanto, exhiben algunas propiedades similares como: aprendizaje adaptativo, autoorganización, tolerancia a fallos, operación en tiempo y la fácil inserción en la tecnología existente. Generalmente, la red neuronal artificial consta de 3 etapas: la primera involucra el diseño, donde se elige el tipo de red neuronal, la cantidad de neuronas que generara, la función de activación definida y el algoritmo de aprendizaje. La fase de entrenamiento presenta una serie de entradas y salidas a la red neuronal, de las cuales aprende mediante el uso del algoritmo de entrenamiento (Barthakur et al., 2012). Luego, la entrada relevante se alimenta a la red, donde la red genera una salida basada en lo que aprendió durante la fase de entrenamiento. Por último, se especifica una serie de parámetros: el número de capas, número de neuronas en la capa de entrada, número de neuronas de las capas intermedias y número de neuronas en la capa de salida (Quiñones et al., 2020).

El modelo neuronal artificial es un diseño realizado partir de métodos numéricos, permitiendo estimar el valor DBO_5 , en tiempo real, a partir de variables cualitativas y cuantitativas; demostrando grandes ventajas como: la reducción del tiempo y los costos económicos. De acuerdo con la norma americana, este parámetro tarda cinco días y, por lo general, requiere la experiencia y las habilidades del personal de laboratorio (INEN, 2013). La estimación de la Demanda Bioquímica de Oxígeno (DBO_5) es uno de los factores más importantes para controlar la calidad del agua residual en empresas textiles. Este parámetro mide el contenido de carga orgánica en el paso de desgasificación, donde contribuye con alrededor del 50%. Especialmente por la adición de químicos y colorantes naturales al agua de prueba, el agotamiento del oxígeno disuelto en el tanque receptor y la muerte de animales acuáticos por falta de oxígeno (Raffo & Ruiz, 2014).

La presente investigación planea realizar una simulación a partir del modelo neuronal artificial basado en una red neuronal; correspondiente al tipo de perceptrón multicapa de la red neuronal artificial supervisada con el entrenamiento del algoritmo Levenberg-Marquardt para evaluar la estimación de error de la Demanda Bioquímica de Oxígeno con la recolección de datos de la salida del proceso productivo por parte de las empresas del Jeans de la Ciudad de Pelileo y hacer una comparación con los valores estimados de la red neuronal con los valores reales (valores de análisis experimentales) aplicando la prueba de Tukey.

Metodología

Se elaboró una base de datos clasificando las variables cualitativas y cuantitativas utilizadas para predecir el comportamiento de la variable dependiente (error de medición de DBO_5) y de las variables independientes relacionadas con el número de interacciones y observaciones, estimadas mediante un modelo de Red Neuronal Artificial de RetroPropagación (RNARP) seguido del análisis correspondiente (Pascal, 2019).

Área de Estudio

El estudio se llevó a cabo en las aguas residuales de las empresas del jean de la ciudad de Pelileo, conocida como la “Ciudad Azul” por la presencia de la industria del Jean, ubicada en la Provincia de Tungurahua (Tungurahua Turismo, 2021). La información es recolectada de 30 empresas que fueron seleccionados del catastro de GAD Pelileo de los años 2017-2018 juntamente con el aporte de un laboratorio de análisis de agua certificado. Se mantiene la confidencialidad de la información de las empresas.

Estimación de las variables de entrada y variable de salida

Para la matriz de datos se utilizaron 6 parámetros físicos (temperatura, humedad relativa, presión atmosférica, concentración de sólidos suspendidos, sólidos sedimentales, sólidos totales) y 9 parámetros químicos (potencial de hidrógeno, sulfuros, sulfatos, nitrógeno total, DQO, fenoles, tensioactivos, fosforo total, aceites y grasas). Un total de 15 parámetros fisicoquímicos utilizados como variables de entrada y un parámetro químico como variable de salida, para la elaboración del modelo. Los datos estimados se reportan utilizando la normativa sobre descarga de aguas residuales al sistema de alcantarillado público, obtenida en el Anexo VI de la Norma TUSLA del Ministerio del Ambiente (Gilpavas et al., 2018; Norma de Calidad Ambiental y Descarga de Efluentes, 2011).

Elaboración del modelo neuronal de DBO₅

El modelo neuronal para la predicción de la demanda bioquímica de oxígeno se elaboró a partir de una red Feed Forward Backpropagation. Se utilizó la DBO₅ como variable de salida y los parámetros físicos y químicos mencionados anteriormente como variables de entrada. La selección de estos parámetros se realizó con base en el efecto que causan sobre la DBO₅ y teniendo en cuenta la frecuencia de su uso en estudios previos.

Por su parte, el código para el entramiento del Perceptrón de Multicapa (MLP) se elaboró a partir del modelo desarrollado por Payal et al. (2015). Este modelo, es entrenado por medio del número de capas ocultas y el número de neuronas ocultas. Además, requiere definir un algoritmo para el entrenamiento de la red, este permite acelerar el proceso de aprendizaje del MLP, un número de épocas definidas como la cantidad de veces que se aplica el algoritmo de entrenamiento al conjunto de datos y un indicador de desempeño por medio del cual la red ajusta las predicciones a las observaciones (Rumelhart & Hintont, 1986; Vališ et al., 2020). Finalmente, se codifica el algoritmo en el lenguaje de programación M, propio de la herramienta de programación MATLAB y en él se utiliza las herramientas incluidas en el Neural Network Toolbox para el mismo programa.


En la figura 1 incluye el diseño del modelo neuronal de una red neuronal artificial conformada por 1 capa de entrada, 1 capa oculta, 1 capa sumatoria y 1 capa de salida. En este modelo, el número de neuronas de la capa de entrada (15 neuronas), correspondió al

número de variables utilizadas como entradas. Para el entrenamiento, se usó un número de 1000 épocas y el coeficiente de correlación como indicador de desempeño de la red neuronal.

El modelo neuronal fue evaluado por medio del algoritmo de Levenberg-Marquardt, para acelerar el proceso y diseñar el aprendizaje a través de segundas derivadas, donde, el peso se ajusta rápidamente, evitando cálculos matriciales (Dongardive & Abraham, 2017). Dicho código, la instrucción *trainlm* escrita, se encuentran conectadas a una arquitectura de Perceptrón de Multicapa (MLP) (Ebtehaj & Bonakdari, 2016).

Figura 1

Diseño de la red Neuronal Artificial Feed Forward Backpropagation



Nota: Descripción del diseño de la red empleada para la estimación de error de la DBO₅.

Perfiles de entrada y salida

Se generó una matriz de entrada de entrenamiento (SampleIn= Matriz 15x30 double). Las 15 filas corresponden las variables responsables y las 30 columnas representan las 30 empresas como se muestra en la tabla 1.

Tabla 1

Matriz de entrada de entrenamiento

Dimensión	Código	Parámetro
FÍSICOS	H	Potencial de Hidrógeno
	A	Temperatura °C
	B	Humedad relativa %
	C	Presión atmosférica (Pascal)
QUÍMICOS	D	Sólidos Totales
	F	sólidos sedimentales
	G	Sólidos Suspendidos
	I	Sulfuros
	J	Sulfatos

Tabla 1

Matriz de entrada de entrenamiento (continuación)

Dimensión	Código	Parámetro
QUÍMICOS	K	Nitrógeno Total
	L	DQO
	M	Fenoles
	N	Tensioactivos
	Ñ	Fosforo total
	O	Aceites y Grasas

Nota: Matriz de entrenamiento con la codificación de variables y empresas. Obtenidas del catastro de GAD Pelileo de los años 2017-2018 juntamente con el aporte de un laboratorio de análisis de agua certificado.

Análisis estadístico

Para verificar la efectividad del modelo neuronal como método de estimación de la DBO₅, se aplicó la Prueba de Tukey con la ayuda del programa estadístico InfoStat, para comparar los valores estimados de la red neuronal con los valores reales

Resultados

Las simulaciones se realizaron utilizando muestras de aguas residuales de la matriz de datos recopilados, consiguiendo entrenar la red y comprobar el error de medida de DBO₅, entre los valores estimados por la red neuronal y los valores reales.

Tabla 2

Resultados de la simulación de la Red Neuronal Artificial


Ítem	Detalle
Tipo de entrenamiento	Descenso de gradiente con última incorporación en la décima épocas Entrenamiento óptimo
Valor de coeficiente de correlación	0.98081

Nota: Se considera que menos épocas generará errores en la red, mientras que más épocas llegarán al entrenamiento.

En la figura 2 se observa el coeficiente de correlación obtenido en la capa de salida de la red neuronal y la estructura de la red neuronal artificial Feed Forward Backpropagation, entrenada con el algoritmo de Levenberg-Marquardt.

Figura 2

Valor de correlación obtenido




Nota: Se observa la concordancia entre los valores reales y las estimaciones realizadas por la red.

En la figura 3 se observa el resultado de la Comparación entre los valores reales y calculados de la Demanda Bioquímica de Oxígeno.

Figura 3

Comparación de Valores Reales vs Valores obtenidos por la Red Neuronal



Nota. Los puntos rojos representan los valores obtenidos por la red neuronal y los puntos azules los valores medidos.

Pronóstico de la red neuronal

En la tabla 3 se evidencia los valores reales obtenidos al medir la variable de la DBO₅ en las empresas 1 y 2.

Tabla 3

Medición real y valor pronosticado para la variable en relación con Sólidos Totales

Parámetro	Empresa 1	Empresa 2	Empresa 3	Empresa 4
Temperatura °C	15	16	15	16
Humedad relativa %	86	82	86	82
Presión atmosférica (Pascal)	103,1	103	103,1	103
Sólidos Totales	1352	1420	1000	1000
sólidos sedimentales	0,2	1,5	0,2	1,5
Sólidos Suspendidos	50	50	50	50
Potencial de Hidrógeno	7,04	7,29	7,04	7,29
Sulfuros	0,13	0,19	0,13	0,19
sulfatos	110	120	110	120
Nitrógeno Total	8,51	9,26	8,51	9,26
DQO	131	165	131	165
Fenoles	0,022	0,026	0,022	0,026
Tensioactivos	0,120	0,110	0,120	0,110
Fosforo total	1,7	1,7	1,7	1,7
Aceites y Grasas	2,2	2	2,2	2
DBO5	65	70	60,135	67,8202

Nota: Descripción de valores reales y pronosticados de las variables influyentes en las empresas 1 y 2 del Jean. La Matriz de Prueba (Test1=15x1 Matriz double) predice un valor de DBO₅ de 60,135 mg/l; y la Matriz de Prueba (Test2=Matriz 15x1 double) pronostica un valor de DBO₅ de 67,8202 mg/ml.

Comparación de valores medidos por la Red Neuronal vs Valores Reales

La figura 4 muestra los resultados del Análisis de Varianza y la Prueba de Tukey.

Figura 4

Resultados del Análisis de Varianza y Prueba de Tukey

Cuadro de Análisis de la Varianza (SC tipo III)					
F.V.	SC	gl	CM	F	p-valor
Modelo	1,79	1	1,79	4,4E-04	0,9833
METODOS	1,79	1	1,79	4,4E-04	0,9833
Error	233912,92	58	4032,98		
Total	233914,71	59			

Test: Tukey Alfa=0,05 DMS=32,82239					
Error: 4032,9813 gl: 58					
METODOS	Medias	n	E.E.		
laboratorio	104,50	30	11,59	A	
RED	104,85	30	11,59	A	


Medias con una letra común no son significativamente diferentes (p > 0,05)

Nota: Datos de Análisis de Varianza y Prueba de Tukey obtenidos del programa estadístico InfoStat. Se evidencia que la red neuronal es capaz de capturar la relación entre las variables de entrada y salida.

La figura 5 se muestra los resultados de la prueba Tukey entre los valores de los datos de laboratorio y los de la res neuronal artificial.

Figura 5

Interacción con Tukey entre los valores de laboratorio vs la red neuronal artificial



Nota: la relación entre la respuesta esperada y la red neuronal. Encontrando un grupo homogéneo (A), con un nivel de cumplimiento de 98,33%. Ideal para diagnosticar la salida estimada de la Demanda Bioquímica de Oxígeno por el proceso de las empresas de Jean.

En la figura 6 se observa el resultado de la prueba t para una media entre el valor real y el valor calculado por la red. Donde el valor p es igual a 0,8890 siendo este el valor del error estimado por la red neuronal.

Figura 6

Prueba t para una media

Variable	n	Media	DE	LI(95)	LS(95)	T	p(Bilateral)
ERROR	30	-0,35	13,43	-5,36	4,67	-0,14	0,8890

Nota: entre el valor real y el valor calculado por la red. Durante este período de entrenamiento, la solución se optimiza varias veces para reducir los errores de la red en el conjunto de datos de entrada.

Discusión

En la tabla 2 se muestran los resultados de la simulación de la Red Neuronal, que contiene dos capas ocultas con un entrenamiento por descenso de gradiente, con la última incorporación en la décima época o epoch. Seguidamente, en la figura 3 se evidencia la estructura de la red neuronal artificial Feed Forward Backpropagation, entrenada con el algoritmo de Levenberg-Marquardt. De acuerdo con Singh et al. (2009), es el algoritmo más apropiado para efectuar estimaciones de la DBO₅.

El valor de correlación obtenido en la simulación se asemeja a los datos de Meza & González (2020) y González & García (2020), lo que demuestra un alto rendimiento del algoritmo de Levenberg-Marquardt. Este algoritmo muestra concordancia entre los valores reales y las estimaciones realizadas por la red (coeficiente de correlación de 0.9808).

En la figura 4 se muestra la comparación entre los valores reales y calculados por la red neuronal, evidenciando el menor cambio en sus estimaciones (Vijayashanthar et al., 2018). Asimismo, se describe mediante puntos de color rojo los valores obtenidos por la red neuronal y mediante puntos azules los valores medidos. Claramente se puede observar un buen seguimiento de datos de la red neuronal con un vector de error denominado RNDBO5_errors (Matriz 30x1).

La tabla 3 describe los valores reales y sugeridos para evaluar sólidos totales en relación con la DBO₅. Estos valores fueron simulados en una red neuronal artificial pre entrenada para estimar el error de la Demanda Bioquímica de Oxígeno en las empresas 1 y 2. De esta manera, se puede hacer la misma estimación para cualquier empresa, o si es necesario, cambiar los valores de las variables de entrada al sistema. En base a los valores

pronosticados de las empresas 1 y 2 de la tabla 3, la Matriz de Prueba (Test1=15x1 Matriz double) predice un valor de DBO_5 de 60,135 mg/l; y la Matriz de Prueba (Test2=Matriz 15x1 double) pronostica un valor de DBO_5 de 67,8202 mg/ml; dichos datos obtenidos estipulan un pronóstico de decrecimiento de la DBO_5 . Con un error cercano al vector de error de la red neuronal, en relación con el parámetro de Sólidos Totales. De acuerdo con la referencia bibliográfica, los valores estimados se encuentran dentro del límite máximo permisible (Norma de Calidad Ambiental y Descarga de Efluentes, 2011).

Con el análisis estadístico realizado, en la figura 5 muestra los resultados del Análisis de Varianza y la Prueba de Tukey. Se comparan los valores obtenidos en la simulación con valores de laboratorio con un índice de confianza del 95%. Afirmando que no existe una diferencia estadísticamente significativa; por lo tanto, se puede concluir que la red neuronal es capaz de capturar la relación entre las variables de entrada y salida.

Además, se observó que el número de neuronas y la capa oculta son independientes de la DBO_5 . Por lo que el modelo neuronal no utiliza las ecuaciones que describen el proceso de la DBO_5 en sus cálculos. En este tipo de modelo, las neuronas representan solo una parte de la función matemática que la red construye a partir del conjunto de observaciones (Baldiris et al., 2017; Gulyani et al., 2015).

Finalmente, el modelo neuronal tiene las ventajas de precisión, rentabilidad, velocidad de monitoreo, reconocimiento de patrones complejos, captura de comportamiento no lineal. Lo que demuestra que la red neuronal es una herramienta efectiva para modelar la Demanda Bioquímica de Oxígeno.

Conclusiones

- Se demostró que el aprendizaje de un modelo neuronal artificial basado en una red neuronal multicapa se puede utilizar para la estimación de error de la Demanda Bioquímica de Oxígeno en aguas residuales de las empresas del Jean. La red neuronal feedforward-backpropagation alcanzó un alto desempeño al ser entrenada con el algoritmo de Levenberg-Marquardt ($R > 0,98081$). Usando una matriz de 27 neuronas que constó de cuatro capas: una de entrada, dos ocultas y una salida.
- Los modelos neuronales artificiales en este tipo de redes neuronales son suficientes para realizar estimaciones sugeridas en función de indicadores de desempeño y relación entre el valor estimado y real. Las similitudes son suficientes para estimar la propuesta, dando un valor de 0.8890 entre el error estimado de la red y los valores reales.
- Se comparó entre los valores estimados por la Red Neuronal y los valores reales. Esto se muestra, cuando los datos se recopilan mediante la prueba de Tukey con un 95% de confianza. El valor de confiabilidad es del 98,33% de las respuestas

obtenidas de la red neuronal artificial y el valor real en el laboratorio. Las afirmaciones de que las medias son iguales, no estadísticamente diferentes; son ideales para el diagnóstico de la Demanda Bioquímica de Oxígeno y el cumplimiento por parte de las empresas para la descarga de aguas residuales en los sistemas de alcantarillado.

- En la actualidad, las redes neuronales poseen un amplio campo de investigación, lo que se fomenta la innovación tecnológica continua con este trabajo, especialmente la aplicación de técnicas informáticas RNA a futuros trabajos que impliquen riesgo o incertidumbre, ya que pueden verse como una alternativa a los sistemas tradicionales.

Referencias Bibliográficas

- Baldiris, I., Acosta, J. C., Martinez, C. E., Sanchez, J., Castro, I., & Severiche, C. (2017). Multivariate analysis of surface water quality of the Bay of Cartagena (Colombia) period 2001-2017. *International Journal of ChemTech Research*, 10(15), 421–432.
- Barthakur, M., Thakuria, T., & Sarma, K. K. (2012). Artificial Neural Network (ANN) Based Object Recognition Using Multiple Feature Sets. *Studies in Computational Intelligence*, 395, 127–135. https://doi.org/10.1007/978-3-642-25507-6_11
- Choudhury, A. (2017). Sustainable chemical technologies for textile production. In *Sustainable Fibres and Textiles* (pp. 267–322). Elsevier Ltd. <https://doi.org/10.1016/B978-0-08-102041-8.00010-X>
- Conferencia de la ONU sobre Comercio y Desarrollo [UNCTAD]. (2019). Environmental analysis of textile products. *Clothing and Textiles Research Journal*, 24(3), 248–261.
- Dongardive, J., & Abraham, S. (2017). Reaching optimized parameter set protein secondary structure prediction using neural network. *Neural Computing and Applications*, 28(8), 1947–1974. <https://doi.org/10.1007/s00521-015-2150-2>
- Ebtehaj, I., & Bonakdari, H. (2016). Bed load sediment transport estimation in a clean pipe using multilayer perceptron with different training algorithms. *KSCE Journal of Civil Engineering*, 20(2), 581–589. <https://doi.org/10.1007/s12205-015-0630-7>
- GAD Pelileo. (2019). *Actualización del plan de desarrollo y ordenamiento territorial del cantón San Pedro de Pelileo*. GADM de Pelileo. http://app.sni.gob.ec/sni-link/sni/PORTAL_SNI/data_sigad_plus/sigadplusdocumentofinal/1860000640001_ACTUALPDYOT2015_15-03-2015_21-58-23.pdf
- Gilpavas, E., Arbeláez, E., Medina, J., & Gómez, C. (2018). Tratamiento de aguas

- residuales de la industria textil mediante coagulación química acoplada a procesos fenton intensificados con ultrasonido de baja frecuencia. *Revista Contaminación Ambiente*, 34(1), 157–161. <https://doi.org/10.20937/RICA.2018.34.01.14>
- González, L., & García, J. (2020). Elaboration of an artificial neural model for the estimation of dosifications in the wastewater treatment. *Elsevier*, 84(1), 3–17. <https://doi.org/10.23850/22565035.1636>
- Gulyani, B. B., Mangai, A. J., & Fathima, A. (2015). An approach for predicting river water quality using data mining technique. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9165, 233–243. https://doi.org/10.1007/978-3-319-20910-4_17
- INEN. (2013). 1985-04 0. In *Aguas. Demanda Bioquímica De Oxígeno (DBO5)*. INEN 1202.
- Kant, R. (2012). Textile dyeing industry an environmental hazard. *Natural Science*, 4(1), 22–26. <https://doi.org/10.4236/ns.2012.41004>
- Kishor, R., Purchase, D., Saratale, G. D., Saratale, R. G., Ferreira, L. F. R., Bilal, M., Chandra, R., & Bharagava, R. N. (2021). Ecotoxicological and health concerns of persistent coloring pollutants of textile industry wastewater and treatment approaches for environmental safety. *Journal of Environmental Chemical Engineering*, 9(2), 105012. <https://doi.org/10.1016/j.jece.2020.105012>
- Luongo, G. (2015). *Chemicals in textiles A potential source for human exposure and environmental pollution* [Stockholm University]. <https://www.diva-portal.org/smash/get/diva2:850089/FULLTEXT02.pdf>
- Maina, S., Kachrimanidou, V., & Koutinas, A. (2017). A roadmap towards a circular and sustainable bioeconomy through waste valorization. *Current Opinion in Green and Sustainable Chemistry*, 8, 18–23. <https://doi.org/10.1016/J.COGSC.2017.07.007>
- Mcculloch, W. S., & Pitts, W. (1990). A logical calculus nervous activity. *Bulletin of Mathematical Biology*, 52(1), 99–115.
- Meza, J., & González, L. (2020). Elaboración de un modelo neuronal artificial para la estimación de la Demanda Bioquímica de Oxígeno en aguas marinas. *Revista de Investigación Agraria y Ambiental.*, 11(2), 1–10. <https://doi.org/https://doi.org/10.22490/21456453.3441>
- Ministerio del Ambiente. (2015). *Registro Oficial Año II No 316, Acuerdo No 61 Reforma del Libro VI del Texto Unificado de Legislación Secundaria*. Tribunal Constitucional de La República Del Ecuador.

https://www.gob.ec/sites/default/files/regulations/2018-09/Documento_acuerdo-ministerial-061.pdf

Norma de Calidad Ambiental y Descarga de Efluentes. (2011). Norma de Calidad Ambiental y de descarga de efluentes: Recurso Agua. In *TULAS Texto unificado de legislación secundaria del Ministerio del Ambiente* (pp. 286–339).

Pascal, Á. (2019). *Predicción del comportamiento de la dbo 5, dco, sst, n.*

Payal, A., Rai, C. S., & Reddy, B. V. R. (2015). Analysis of Some Feedforward Artificial Neural Network Training Algorithms for Developing Localization Framework in Wireless Sensor Networks. *Wireless Personal Communications*, 82(4), 2519–2536. <https://doi.org/10.1007/s11277-015-2362-x>

Programa Mundial de Evaluación de los Recursos Hídricos de las Naciones Unidas [WWAP]. (2017). *AGUAS RESIDUALES*. www.unesco.org/open-access/terms-use-ccbysa-en

Quiñones, L., Ochoa, L., Kemper, N., Torres, O., Correa, J., & Soto, J. (2020). Artificial neural network to estimate an index of water quality. *Scielo*, 11, 109–120. <https://doi.org/10.29019/enfoque.v11n2.633>

Quintero, L., & Cardona, S. (2012). Evaluación del tratamiento biológico para remoción de color índigo de agua residual industrial textil por un consorcio microbiano en lecho fluidizado. *Gestión y Ambiente*, 14(2), 105–113.

Raffo, E., & Ruiz, E. (2014). Caracterización de las aguas residuales y la demanda bioquímica de oxígeno. *Journal of the American Chemical Society*, 17, 71–80. <https://doi.org/10.1021/ja00334a047>

Romero, T. de J., Rodríguez, H., & Mosqueda, A. (2016). Characterization of wastewater generated in a Cuban textile industry. *Scielo*. http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1680-03382016000300004

Rumelhart, D. E., & Hintont, G. E. (1986). Learning Representations by Back-Propagating Errors. *Cognitive Modeling*, 323(2), 3–6. <https://doi.org/10.7551/mitpress/1888.003.0013>

Samanta, K. K., Pandit, P., Samanta, P., & Basak, S. (2019). Water consumption in textile processing and sustainable approaches for its conservation. In *Water in Textiles and Fashion* (pp. 41–59). Elsevier Ltd. <https://doi.org/10.1016/b978-0-08-102633-5.00003-8>

Sigcha, B., & Jordán, E. (2018). *Producción más limpia en el proceso de confección de*

tela en la industria Textiles Jhonatex. 1–8.
[https://redi.uta.edu.ec/bitstream/123456789/67271/1/SIGCHA_PACHA_BYRON_GENARO - 2018.pdf](https://redi.uta.edu.ec/bitstream/123456789/67271/1/SIGCHA_PACHA_BYRON_GENARO_-_2018.pdf)

Singh, K. P., Basant, A., Malik, A., & Jain, G. (2009). Artificial neural network modeling of the river water quality-A case study. *Ecological Modelling*, 220(6), 888–895. <https://doi.org/10.1016/j.ecolmodel.2009.01.004>

Tungurahua Turismo. (2021). *Pelileo turismo*. <https://tungurahuatourismo.com/es-es/tungurahua/pelileo/ciudades/pelileo-turismo-aa562e1d1>

United Nations Climate Change News. (2018, September 18). *UN Helps Fashion Industry Shift to Low Carbon | UNFCCC*. <https://unfccc.int/news/un-helps-fashion-industry-shift-to-low-carbon>

Vališ, D., Hasilová, K., Forbelská, M., & Vintř, Z. (2020). Reliability modelling and analysis of water distribution network based on backpropagation recursive processes with real field data. *Measurement*, 149, 107026. <https://doi.org/10.1016/J.MEASUREMENT.2019.107026>

Vijayashanthar, V., Qiao, J., Zhu, Z., Entwistle, P., & Yu, G. (2018). Modeling Fecal Indicator Bacteria in Urban Waterways Using Artificial Neural Networks. *Journal of Environmental Engineering*, 144(6). [https://doi.org/10.1061/\(asce\)ee.1943-7870.0001377](https://doi.org/10.1061/(asce)ee.1943-7870.0001377)

El artículo que se publica es de exclusiva responsabilidad de los autores y no necesariamente reflejan el pensamiento de la **Revista Conciencia Digital**.



El artículo queda en propiedad de la revista y, por tanto, su publicación parcial y/o total en otro medio tiene que ser autorizado por el director de la **Revista Conciencia Digital**.



Indexaciones

