



UNIVERSIDAD TÉCNICA DE AMBATO
FACULTAD DE CIENCIA E INGENIERÍA EN ALIMENTOS Y
BIOTECNOLOGÍA
CARRERA DE INGENIERÍA BIOQUÍMICA



Tema: Estimación de la Demanda Bioquímica de Oxígeno (DBO_5) en aguas residuales de las empresas de jeans de la ciudad de Pelileo utilizando redes neuronales artificiales.

Trabajo de Titulación, Modalidad Proyecto de Investigación, previo a la obtención de título de Ingeniera Bioquímica, otorgado por la Universidad Técnica de Ambato, a través de la Facultad de Ciencia e Ingeniería en Alimentos y Biotecnología

Autor: Yesenia Esthefania Pillapa Vargas

Tutor: Ing., Daniel Alfonso Cabrera Valle

Ambato – Ecuador

Marzo -2022

APROBACIÓN DEL TUTOR

Ing. M.Sc. Daniel Alfonso Cabrera Valle

Certifica:

Que el presente trabajo de titulación ha sido prolijamente revisado. Por lo tanto, autorizo la presentación de este Trabajo de Titulación bajo la Modalidad Proyecto de Investigación, el mismo que responde las normas establecidas en el reglamento de Títulos y Grados de la Facultad de Ciencia e Ingeniería en Alimentos y Biotecnología.

Ambato, 9 de febrero de 2022

.....
Ing. M.Sc. Daniel Alfonso Cabrera Valle

C.I. 180256159-5

TUTOR

DECLARACIÓN DE AUTENTICIDAD

Yo, Yesenia Esthefania Pillapa Vargas, manifiesto que los resultados obtenidos en el presente trabajo de titulación, modalidad Proyecto de Investigación, previo a la obtención del título de Ingeniera Bioquímica son absolutamente originales, auténticos y personales a excepción de las citas bibliográficas.



.....
Yesenia Esthefania Pillapa Vargas

C.I. 150090203-4

AUTORA

APROBACIÓN DE LOS MIEMBROS DEL TRIBUNAL DE GRADO

Los suscritos Profesores Calificadores, aprueban el presente Trabajo de Titulación, modalidad Proyecto de Investigación, el mismo que ha sido elaborado de conformidad con las disposiciones emitidas por la Facultad de Ciencia e Ingeniería en Alimentos y Biotecnología de la Universidad Técnica de Ambato.

Para constancia firman:

Dr. Orestes Darío López Hernández
C.I. 175478486-4
Presidente del Tribunal

Mg., Dolores del Rocío Robalino Martínez
C.I. 180176948-8
Calificador 1

M.Sc. Jeanette Verónica Carrera Cevallos
C.I. 171619227-1
Calificador 2

Ambato, 10 de marzo de 2022

DERECHOS DE AUTOR

Autorizo a la Universidad Técnica de Ambato, para que haga de este Trabajo de Titulación o parte de él, como documento disponible para su lectura, consulta y procesos de investigación, según las normas de la Institución.

Cedo los Derechos en línea patrimoniales de mi Trabajo de Titulación, con fines de difusión pública, además apruebo la reproducción de este, dentro de las regulaciones de la Universidad, siempre y cuando esta reproducción no suponga una ganancia económica y se realice respetando mis derechos de autor.



.....
Yesenia Esthefania Pillapa Vargas

C.I. 150090203-4

AUTORA

DEDICATORIA

El presente proyecto lo dedico a Dios, el mismo que con sus bendiciones me ha permitido culminar mi carrera universitaria, y ser mi apoyo y fortaleza en momentos de dificultad y de debilidad. Demostrándome lo hermosa que es la vida y lo justa que puede llegar a ser.

A mis padres Luis Pillapa y Silvia Vargas, que son mi motor de vida, quienes con su cariño, apoyo y comprensión supieron guiarme por el camino de la perseverancia y educarme con valores de humildad, responsabilidad, respeto, sencillez y, sobre todo, comprender que cada día que pasa es una lección de vida.

A mis hermanos Jefferson Alexander y Elvis Andrés, quienes están a mi lado en los buenos y malos momentos brindándome su cariño, su fortaleza para continuar y ser su ejemplo a seguir.

A mi primo Leonardo Pillapa, me enseñó que la vida está llena de retos, pero nada es imposible cuando uno se lo propone. "Si tienes suerte, un primo estará allí desde el principio."
Susan Bolch

A mi ahijada Karla Doménica, quien con su inocencia y carisma me enseñó asumir una gran responsabilidad de ser como una madre para ella.

A mis abuelitos Natividad Cando "mi fuente de sabiduría", Gonzalo Pillapa y Delia Tuza "mi fuente de música y fortaleza". Estas personas son como las luces de un paisaje. Siempre están en el lugar correcto, en el momento justo, listos para ayudarnos cuando los necesitamos".

Con mucho cariño....

AGRADECIMIENTO

Debo expresar mi más sincero agradecimiento primero a Dios por darme la bendición, la sabiduría y la fortaleza de culminar una etapa más de mi vida.

A mis padres por ser mi pilar fundamental que gracias a su amor, apoyo y empuje han sabido alentarme para cumplir con éxito esta etapa. El mejor legado que ellos pueden dejarme como herencia es el estudio y trazar mi propio camino y recorrerlo con mis propios pies sin dudar de mi capacidad.

Mi profundo agradecimiento a los Ingenieros Daniel Cabrera, Manolo Córdova, Patricio Encalada por haberme brindado la oportunidad de recurrir a su amistad, apoyo, capacidad y conocimiento, así como han tenido la paciencia del mundo para guiarme durante el desarrollo de este proyecto, docentes con excelente calidad humana, profesional y ética

A mis amistades Walter Torres, Javier Ojeda, Erika Puco, Santiago Pimbo, Enrique Rivera, Alexis Gómez, Denise Loza, Alex Guerrero quienes sin esperar nada a cambio compartieron su conocimiento, alegrías, tristezas y su apoyo moral durante este camino lleno de obstáculos y retos. Gracias por apoyarme cuando más los necesite, por extenderme su mano en momentos difíciles y por el amor brindado cada día, siempre los llevo en mi corazón.

A los docentes Mirari A, Homero V, Alex A, Omar G, Deysi P, Dolores R, Yoel H, Geovanny V, Carlos R, Carolina G, Patricia A, Lander P, Orestes L, Fernando A, Jorge B con sus conocimientos académicos, enseñanzas, lecciones, exigencias fueron parte de mi formación académica y profesional. Siempre recordare con estimación y respeto aquellos docentes brillantes, que con gratitud tocaron mis sentimientos, infundiendo valor y confianza para afrontar mi gran sueño. Sin dejar de lado a Don Maury, Don Javi, a todos los conserjes, Doña Mericita, las srtas. de la biblioteca y a todos quienes conforman la FACULTAD DE CIENCIA E INGENIERÍA EN ALIMENTOS Y BIOTECNOLOGÍA, personas tan increíbles que jamás olvidare sus consejos y palabras de ánimos siempre enfocados en Dios.

En general quiero agradecer a todos que de una u otra manera supieron guiarme y enseñarme que las lágrimas derramadas, las noches sin dormir, entre otras, hay que afrontarlos con valor; haciendo de mí una persona perseverante y optimista, siendo de mi etapa universitaria un camino lleno de sorpresas, vivencias, experiencias que nunca olvidaré y prevalecerán en mi corazón.

ÍNDICE CONTENIDOS

PORTADA	i
APROBACIÓN DEL TUTOR.....	ii
DECLARACIÓN DE AUTENTICIDAD.....	iii
APROBACIÓN DE LOS MIEMBROS DEL TRIBUNAL DE GRADO	iv
DERECHOS DE AUTOR	v
DEDICATORIA	vi
AGRADECIMIENTO	vii
RESUMEN.....	xiv
CAPÍTULO I. MARCO TEÓRICO.....	1
1.1 Antecedentes investigativos	1
1.2 Redes Neuronales Artificiales	17
1.3 Modelamiento de la Red Neuronal Artificial	20
1.3.1 Arquitectura de la red neuronal	20
1.3.2 Diseño de la red Neuronal	22
1.3.3 Fase aprendizaje de la red neuronal	23
1.3.4 Programación de la Red Neuronal.....	24
1.5 Modelos de Red Neuronal.....	26
1.5.1 Perceptrón Simple.....	26
1.5.1.1 Función escalón	28
1.5.2 Red retropropagación o backpropagation.....	29
1.5.2.1 Función sigmoideal	30
1.5.3 Conexión de redes hacia delante o feedforward	31
1.5.4 Conexión de redes hacia atrás o feedback	31
1.5.5 Algoritmo de Levenberg- Marquardt.....	31
1.6 Herramienta de aplicación.....	32
1.6.1 Lenguaje Matlab	32
1.7 Objetivos	33
1.8 Variables.....	34
CAPÍTULO II. METODOLOGÍA.....	35

2.1 Enfoque	35
2.2 Materiales	35
2.3 Métodos	36
2.3.1 Modalidad de investigación.....	36
2.4 Descripción de la zona de estudio	36
2.5 Población	37
2.6 Recolección de la información	37
2.7 Estimación de las variables de entrada y variable de salida.....	39
2.8 Elaboración del modelo neuronal artificial	40
2.8.2 Perfiles de entrada y salida	41
2.8.3 Retropropagación de la red neuronal artificial	42
2.8.4 Entrenamiento de la red neuronal	42
2.8.5 Diseño de código en Matlab	42
2.9 Prueba de Tukey	43
CAPÍTULO III. RESULTADOS Y DISCUSIÓN.....	44
3.1 Análisis y discusión de resultados.....	44
3.1.1 Pronóstico de la red neuronal.....	49
3.1.2 Comparación de valores medidos por la Red Neuronal vs Valores Reales.....	51
CAPÍTULO IV. CONCLUSIONES	55
4.1 Conclusiones	55
4.2 Recomendaciones	56
REFERENCIAS BIBLIOGRÁFICAS.....	58
ANEXOS	69

ÍNDICE DE TABLAS

Tabla 1. Codificación de variables.....	38
Tabla 2. Codificación de las lavanderías	39
Tabla 3. Inicialización de Variables.....	41
Tabla 4. Resultados de la simulación de la Red Neuronal Artificial	45
Tabla 5. Medición real de la variable de impacto	49
Tabla 6. Valor pronosticado para la variable de impacto en relación a Sólidos Totales ..	50

ÍNDICE DE FIGURAS

Figura 1	18
<i>Neurona Biológica vs Neurona Artificial</i>	18
Figura 2	21
<i>Arquitectura de una red neuronal</i>	21
Figura 3	26
<i>Estructura de la Red Neuronal Artificial con la función Tang-Sigmoid</i>	26
Figura 4	27
<i>Perceptrón Simple</i>	27
Figura 5	28
<i>Función de activación escalón</i>	28
Figura 6	29
<i>Perceptrón Multicapa</i>	29
Figura 7	30
<i>Función sigmoideal</i>	30
Figura 8	37
<i>Mapa de Ubicación Geográfica del Cantón Pelileo</i>	37
Figura 9	40
<i>Diseño de la red Neuronal Artificial Feed Forward Backpropagation</i>	40
Figura 10	45
<i>Descenso de la gradiente de error</i>	45
Figura 11	46
<i>Valor de correlación obtenido</i>	46
Figura 12	47
<i>Valor de la Demanda Bioquímica de Oxígeno medido</i>	47
Figura 13	47
<i>Valor de la Demanda Bioquímica de Oxígeno estimado por la Red Neuronal Artificial</i>	47
Figura 14	48
<i>Comparación de Valores Reales vs Valores obtenidos por la Red Neuronal.</i>	48
<i>Resultados del Análisis de Varianza y Prueba de Tukey</i>	52

Figura 16	53
<i>Interacción con Tukey entre los valores de laboratorio vs la red neuronal artificial.....</i>	<i>53</i>
Figura 17	53
<i>Prueba t para una media</i>	<i>53</i>
Figura 18	70
<i>Matriz de datos reales de 30 empresas de Jeans.....</i>	<i>70</i>
Figura 19	71
<i>Importación de la matriz de datos a Matlab.....</i>	<i>71</i>
Figura 20	72
<i>Propiedades de la Red Neuronal</i>	<i>72</i>
Figura 21	73
<i>Programación para obtención de las gráficas</i>	<i>73</i>
Figura 22	74
<i>Programa estadístico InfoStat</i>	<i>74</i>

ÍNDICE DE ECUACIONES

Ecuación 1. Backpropagation	23
Ecuación 2. Respuesta de la neurona artificial	24
Ecuación 3. Activación Tan-Sigmoid	25

RESUMEN

Dentro de la inteligencia artificial, el uso de redes neuronales artificiales toma cada vez más importancia. Este estudio busca 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.

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. 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 representan sólo una parte de la función matemática que la red construye a partir del conjunto de observaciones.

Palabras Claves: DBO₅, aguas residuales, inteligencia artificial, redes neuronales artificiales, red feed-forward backpropagation, jeans

ABSTRAC

Within artificial intelligence, the use of artificial neural networks is becoming increasingly important. This study seeks to estimate the error of the Biochemical Oxygen Demand in wastewater from laundries of jeans of the city of Pelileo using neural networks.

First, a database consisting of 6 physical parameters, 9 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 15 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. 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.

Keywords: DBO₅, wastewater, artificial intelligence, artificial neural networks, red feed-forward backpropagation, jeans

CAPÍTULO I. MARCO TEÓRICO

1.1 Antecedentes investigativos

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**). Debido a 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, tema ambiental muy importante. De hecho, debido al progreso de la economía mundial, la cantidad de residuos va en aumento. (**Sigcha & Jordán, 2018; WWAP- Programa Mundial de Evaluación de los Recursos Hídricos de las Naciones Unidas, 2017**).

En (**2018**), según un informe presentado por la Organización de las Naciones Unidas, “se espera que la escasez de agua aumente considerablemente para 2050. En 2010, el 27% de la población mundial vivía en áreas con escasez de agua y su número podría llegar a 4800 y 5000 millones de personas”. La contaminación del agua en general es responsabilidad del ser humano, ya sea de manera directa o indirecta, por sustancias o energías que producen efectos nocivos, como riesgos en la salud humana, obstaculización de actividades acuáticas y deterioro de la calidad de agua asociado al proceso de consumo humano, ya sea industrial, agrícola o recreativo (**Blatt et al., 2020; Lafi et al., 2018**)

Uno de los principales consumidores de agua es la industria, que produce residuos de diversa calidad según el destino. Por otro lado, **Organización de las Naciones Unidas (2019)** menciona que el 70% de los residuos generados por la fabricación son vertidos al agua sin control ni regulación. Gran parte de esto no se trata, por lo que el agua dulce se degrada con productos químicos, lo que afecta no solo al medio ambiente, a la población, sino a ecosistemas completos. En los últimos años, este aspecto negativo ha desarrollado alternativas a las formas tradicionales de producción para obtener productos textiles menos contaminantes.

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)**. En cuanto a los datos de la UNCTAD, la industria textil utiliza 93 mil millones de metros cúbicos de agua cada año, esta cantidad es suficiente para satisfacer las necesidades de 5 millones de personas. Cada año se desechan al mar medio millón de toneladas de microfibras, lo que presenta un equivalente a 3 millones de barriles de petróleo (**Niinimäki et al., 2020; Organización de las Naciones Unidas, 2019**). Por tanto, la producción textil global per cápita, por ejemplo, ha aumentado de 5,9 kg a 13 kg por año durante el período de 1975 al 2018. Del mismo modo, el consumo global ha elevado a un estimado de 62 millones de toneladas de textiles por año, y se prevé que alcance los 102 millones de toneladas para el 2030 (**Global Fashion Agenda & The Boston Consulting Group, 2018**).

En Ecuador, mediante el Decreto Ejecutivo No. 357, publicado en el Registro oficial No. 205 del 2 de junio de 2010 se establecen nueve zonas administrativas de planificación. Cabe recalcar que la Zona tres, abarca las provincias de Tungurahua, Cotopaxi, Chimborazo y Pastaza. Tungurahua es una de las provincias más extensa del país, tiene una superficie de 44.899 km², que equivale el 18% del territorio ecuatoriano (**LEXIS SA, 2016**). Existen varias actividades económicas que se desarrollan en la Zona de Planificación 3, las principales son agropecuaria, manufacturera, servicios y transporte. Específicamente, la industria agropecuaria corresponde al sector primario ocupando el 44% de la población económicamente activa (PEA) y aporta el 12% del Producto Interno Bruto (PIB). Seguidamente, la producción manufacturera pertenece al sector secundario con una participación del 12% de la Población Económicamente Activa y contribuye el 25% del Producto Interno Bruto. Luego, los servicios corresponden al sector terciario representando al comercio con un valor del 13% Producto Interno Bruto y Población Económicamente Activa. Finalmente, el transporte corresponde el 10% del Producto Interno Bruto y 4% del Población Económicamente Activa; convirtiéndose estas actividades económicas en un importante nodo comercial a escala nacional (**SENPLADES, 2019**).

Por otro lado, la Zona de Planificación 3 muestra la diversidad de industrias, tales como: fabricación de automóviles, metalurgia, curtidos, textil, etc. La zona produce una gran cantidad de diversos desechos. También se requiere un manejo estricto de los desechos antes mencionados, lo que obliga a los gobiernos descentralizados a fortalecer las políticas, normas y leyes para lograr la plena integración de los sistemas de salud, seguridad, calidad y medio ambiente.

De acuerdo a los datos del **Instituto de Estadísticas y Censos (2020)**, la industria textil es una de las principales industrias del país. Ocupa el tercer lugar en manufactura, contribuyendo con el 7% del producto interno bruto (PIB) del país. Asimismo, la industria textil es una de las más importantes del país. Es la segunda mayor fuente de empleo, con cerca de 170.000 empleados directos, lo que representa el 21% de la industria manufacturera nacional. 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 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 y tienen un impacto negativo en el medio ambiente, como ríos, arroyos, acequias y especialmente en los sistemas de aguas residuales. Por lo tanto, las aguas residuales de la industria textil contienen altas concentraciones de pigmentos, contaminantes orgánicos, compuestos tóxicos, inhibidores, cloro y tensioactivos. Por lo tanto, la industria textil es una de las principales contribuyentes a la degradación ambiental, lo que genera impactos ambientales relacionados con las aguas residuales que produce y la carga química que contiene. (**Peces, 2020; Romero et al., 2016**). Como afirma el **Ministerio del Ambiente (2015)** “el impacto ambiental se refiere a todos los cambios en la actividad económica, ya sean positivos, negativos, neutrales, directos, indirectos, debido a efectos acumulativos o retardados que producen cambios medibles y demostrables en el medio ambiente, tales como: sus componentes, interacciones y relaciones y otras características inherentes en sistemas naturales”

Desde este punto de vista, el impacto ambiental de la industria en el medio ambiente ha provocado mayor contaminación por vertido de aguas residuales. Las lavanderías textiles son sospechosas de tener muchos contaminantes; especialmente en el proceso de lavado utilizan una variedad de materias primas, reactivos y métodos de producción (**Piontek &**

Müller, 2018). Las aguas residuales que se producen provienen principalmente de la alta concentración de sólidos disueltos en el agua, la concentración de metales pesados y la presencia de colorantes. Asimismo, los tintes textiles son muy estables y provocan una coloración intensa, afectando la fotosíntesis y la autodepuración. La interferencia con la liberación de moléculas tóxicas de la degradación del tinte causa problemas ambientales, por lo que esta agua se utiliza para regar cultivos, animales y humanos (**Gavril & Hodson, 2007**).

Comparado con el Cantón Pelileo, se caracteriza por un importante desarrollo económico en torno a la industria textil especializada en la producción y lavado de jeans. Ser una de las mejores líneas de producción. Pelileo es el principal productor de jeans del país, el 70% de su producción se produce a nivel 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 región de Pelileo existen 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, cada prenda tratada requiere una media de 80 litros de agua y trata 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, existen varias métricas a medir, como temperatura, sólidos en suspensión, conductividad, acidez, alcalinidad, DBO₅, DQO, metales, bacterias, hongos y virus. **(Quintero & Cardona, 2012)**. Los métodos de tratamiento ineficaces de las aguas residuales descargadas por las empresas de estampado y teñido de textiles causan diversos grados de contaminación en los ecosistemas; problemas similares deben abordarse satisfactoriamente mediante tecnologías limpias y marcos normativos estrictos **(López & Crespi, 2015)**. 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)**.

Por otro lado, el control de calidad del agua cumple con la norma ambiental del Texto Unificado de la Legislación Secundaria del Ministerio del Ambiente en el Libro XI (TULSMA). Establecer límites de descarga para los sistemas de alcantarillado público requiere medir una variedad de parámetros, que incluyen: demanda bioquímica de oxígeno (DBO₅), DQO, pH, grasa, nitrógeno, fósforo, sulfato, sólidos suspendidos y más. Sustancias similares entran 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)**

Sin embargo, el método estándar para la determinación de la DBO del agua se llama DBO₅. 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)**. Uno de los factores más importantes es la estimación de la Demanda Bioquímica de Oxígeno (DBO₅) 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).**

Por otro lado, existen varios parámetros físicos y químicos que retienen las aguas residuales de la industria textil relacionándose con la Demanda Bioquímica de Oxígeno. Entre los principales se menciona: parámetros físicos como: temperatura, humedad relativa, presión atmosférica, concentración de sólidos suspendidos, sólidos sedimentales y sólidos totales. Los parámetros químicos tales como: potencial de hidrógeno, tensioactivos, demanda química de oxígeno, fenoles, sulfuros, sulfatos, nitrógeno total, fósforo, aceites y grasas.

Personalmente, en cuanto a parámetros físicos, la descripción es la siguiente. La concentración de sólidos en suspensión es atraída a la planta de tratamiento, afectando el rendimiento de filtración por su alto nivel. De esta forma, el contenido de color es un parámetro que no representa un límite permisible en la normativa, sin embargo, se reduce el uso de medidas terapéuticas por el impacto visual. Este parámetro es un indicador del envejecimiento de las aguas residuales, causado por la presencia de sólidos en suspensión, coloides y sustancias en solución. **(Barrios et al., 2015).**

Los sólidos sedimentales son aquellos que tienden a sedimentar al fondo de un recipiente cónico durante 60 minutos. Los sólidos totales son obtenidos como residuos después de bajar la temperatura del agua hasta que se evapore, relacionándose con la cantidad de

materia orgánica (**Brito, 2000**). La temperatura, este parámetro es importante porque mucho de los sistemas de procesamiento incluyen procesos biológicos que afectan directamente las reacciones químicas y su velocidad de reacción; incrementando la solubilidad de las sales al cambiar el pH y conductividad (**López & Crespi, 2015**). La turbidez es influenciada por la presencia de colorantes aplicados en el proceso de teñido textil y se correlaciona con un mayor registro de color. La conductividad depende de la naturaleza de los iones, de temperatura y viscosidad de la solución, donde la alta conductividad puede ser un indicador de presencia de sales. Es así como, el valor de medición de la conductividad es utilizado como parámetro sustituto de la concentración de sólidos disueltos totales (**Grobbelaar, 2009**). Dentro de los parámetros físicos, el oxígeno disuelto bajo limita la capacidad de autopurificación de los cuerpos de agua, demandando de un pretratamiento para descargar en ríos y embalses. Por ello, la concentración de OD es una función de la temperatura, presión atmosférica y salinidad. Donde, la determinación de Oxígeno Disuelto es la base para calcular la Demanda Bioquímica de Oxígeno y evaluar la condición de oxígeno de los cuerpos de agua, requiriendo en los procesos anaeróbicos concentraciones de Oxígeno Disuelto superiores a 0,5 mg/l.

Por otra parte, los parámetros químicos se encuentran definidos por los componentes orgánicos e inorgánicos. El Potencial de Hidrógeno es considerado un factor importante dentro de los compuestos químicos empleados en el proceso de teñido, los mismos que pueden ocasionar variaciones e incumplimiento con lo establecido en la normativa; mostrando la concentración de iones de hidrogeno presentes en el agua, es decir, más ácida o básica (**Chakraborty, 2010**). Algo semejante ocurre con la alcalinidad, esta se encuentra afectada por el pH, la composición general del agua, temperatura y la fuerza iónica. En efecto, la concentración de la Demanda Química de Oxígeno representa un valor de toda la materia orgánica e inorgánica presente en solución o suspensión que pueden oxidarse químicamente por la acción de agentes oxidantes; siendo un factor

suficientemente rápido para determinar el grado de contaminación del agua (**Hussain et al., 2004; Khosravanipour Mostafazadeh et al., 2019**). Los tensioactivos tienen propiedades dispersantes y emulsionantes, permitiendo que las prendas sean más susceptibles a las manchas; a fin de generar problemas operativos en los sistemas de depuración.

Los metales pesados son formados en el proceso de teñido como: arsénico, cadmio, cromo, cobalto, cobre, manganeso, mercurio, níquel, plata, titanio, zinc, estaño y plomo. Por ejemplo, el cobre es uno de los minerales más comunes en los tintes y es conocido por sus efectos negativos en plantas y microorganismos, lo que resulta en una reducción de la fertilidad del suelo. Estos generalmente tienen baja solubilidad en agua, por lo que la concentración de minerales en el agua depende de los parámetros como el pH, potencial REDOX, el contenido de materia orgánica y metal presente. Se ha considerado que para los tintes que tienen metales como parte integral de la molécula, el contenido mineral es importante para su rendimiento como colorante textil (**Bae et al., 2006**).

Los aceites y grasas son compuestos conocidos como grasas de hexano, ya que están combinados de carbono, hidrogeno y oxígeno que flotan en el agua residual causando problemas de mantenimiento e interfiriendo con la actividad biológica. Son difíciles de biodegradar y una elevada concentración de cargas de aceites y grasas emulsificantes, pueden causar problemas en la planta de tratamiento. Los fenoles constituyen la materia orgánica que tienden a resistir los métodos de proceso tradicionales. Al respecto de los aniones tóxicos como los sulfuros presentes en algunos colorantes. Estos se forman cuando el sulfuro de hidrogeno es producido por la reducción anaeróbica del sulfato, combinándose con metales divalentes como el hierro que pueden estar presente en las aguas residuales (**Braga & Varesche, 2014**).

En cambio, el nitrógeno total incluye el nitrógeno que forma parte de los compuestos de la muestra y puede identificarse como tal. El nitrógeno total tiene una reserva para convertirse en formas más accesibles para la cadena trófica, y, por lo tanto, es importante en los procesos de eutrofización. El nitrógeno orgánico se puede convertir en amoníaco por las bacterias saprofitas, siendo una fuente energética para las bacterias autótrofas convirtiéndose en iones nitrito y nitrato, estas especies requieren 4,5 veces más oxígeno que el que requiere el amoníaco, afectando de esta manera los niveles de oxígeno disuelto (**Ramos et al., 2021**).

Además, el fósforo total es esencial para el crecimiento de algas y otros organismos biológicos, debido a brotes nocivos de algas que aparecen en la superficie del agua. Actualmente existe interés en controlar las cantidades de compuestos de fósforo en aguas superficiales provenientes de desechos industriales y agrícolas. Por ejemplo, el contenido de fósforo total en las aguas residuales municipales puede variar entre 4 a 15 mg/l. Finalmente, los solventes clorados provienen de lavado y la limpieza de máquinas. Se cree que los biocidas como el pentafluorofenol provienen de fibras de lana contaminada.

Como resultado, el rediseño de las redes neuronales artificiales se puede transferir a áreas específicas, tales como: la química, bioquímica, ecología acuática, automatización de procesos, recursos hídricos y las ciencias ambientales. Su creciente popularidad se debe principalmente a la flexibilidad de la estructura y algoritmo de aprendizaje, así como a su simplicidad y facilidad de implementación. Permite resolver problemas complejos y en muchos casos brindar soluciones adecuadas (**Lastre et al., 2014**). Desde la perspectiva de **Tanzifi et al., (2017)** sugieren que el modelado y la simulación pueden evitar múltiples pruebas empíricas en el proceso, lo que puede llevar mucho tiempo, derrochar reactivos y retrasar el análisis. Por esta razón, las redes neuronales artificiales (ANN) son una de las

herramientas más poderosas para predecir la contaminación de las aguas residuales permitiendo describir lo siguiente:

Prado et al., (2013) en el artículo denominado “Applying of a Neural Network in Effluent Treatment Simulation as an Environmental Solution for Textile Industry” realiza una simulación de la biodegradación de pigmentos en el proceso textil empleando una red neuronal multicapa, desarrollando un dispositivo 2^{4-1} para el estudio del efecto de la concentración de colorante (0.01 – 0.18 g/L), glucosa (0.66-2.43% p/v), microorganismos (0.16 – 1.84 ml/L) y pH (5.3 – 8.7) sobre el índice de biodegradación del colorante, encontrando las mejores condiciones con 0,15 g/L de colorante, pH 8 , microorganismos 1.5ml/L y 1 g/100mL de glucosa, logrando un índice de biodegradación del colorante de 96%, demostrando que la red neuronal cognitiva de múltiples capas es eficaz para la simulación de la biodegradación del tinte en condiciones reducidas del conjunto de datos.

Hamid (2014) en el artículo denominado “Evaluation of multivariate linear regression and artificial neural networks in prediction of water quality parameters” examina la eficacia de los modelos de regresión lineal multivariante (MLR) y de redes neuronales artificiales (ANN) para predecir dos parámetros clave de calidad de agua en las plantas de tratamiento de aguas residuales. La Demanda Bioquímica de Oxígeno (DBO) y la Demanda Química de Oxígeno (DQO), así como los indicadores de materia orgánica siendo parámetros representativos de la calidad de aguas residuales. El rendimiento de los modelos ANN se evalúan mediante coeficiente de correlación (R) y el error cuadrático medio (RMSE) y los valores sesgos. Los valores de DBO y DQO calculados por el método de ANN y análisis de regresión coincidieron estrechamente con sus respectivos valores medidos. Además, realizan un estudio comparativo entre los dos métodos ANN y el MLR, obteniendo que la predicción es más apropiada al aplicar el modelo ANN, donde los índices comparativos

de ANN optimizados con valores de entrada para temperatura (T), pH, sólidos suspendidos totales (TSS), sólidos totales (TS) para la predicción de DBO como RMSE =25,1 mg/L, R= 49,4 mg/L, y para DQO como RMSE= 49,4 mg/L, R=0,81. Demostrando que el modelo ANN se puede utilizar con éxito para estimar la DBO y la DQO en la entrada de plantas de tratamiento de aguas residuales.

Cúrvelo et al.,(2015) en el artículo denominado “Simulation of biodegradation process of wastewater from meat industry by means of a multilayer perceptron artificial neural network”, manipulan papaína que está contenida en el látex de la papaya (*Carica papaya*) para reducir la concentración de proteínas de los efluentes de los mataderos, los mismos que se encuentran a una temperatura de 25-30°C y con un pH de 5-7, revelando que la papaína reduce los niveles de la proteína del 82% al 92% dentro de un periodo de tiempo de 30 y 40 horas posteriores al procedimiento. Emplean el modelo de Red Neuronal Artificial Perceptrón Multicapa en la simulación de la variación de la concentración de proteínas en función del tiempo, y la determinación del tiempo de finalización del proceso de concentración de proteínas, así como los parámetros óptimos del proceso de biodegradación de proteínas de las aguas residuales de mataderos; explicando que las simulaciones realizadas mediante modelo de Red Neuronal Artificial en condiciones ideales a un pH 5, una temperatura de 30°C y un tiempo de 35 h, predicen que la concentración de proteína disminuye en un 91%.

Ahmed, (2017) en el artículo mencionado “ Prediction of dissolved oxygen in Surma River by biochemical oxygen demand and chemical oxygen demand using the artificial neural networks (ANNs) desarrollan un modelo red neuronal y una función de base, utilizando datos experimentales recopilados durante un estudio de tres años en el Río Surma, Bangladesh. Los resultados obtenidos muestran que el modelo de red neuronal de función

de base radial preparado por Demanda Bioquímica de Oxígeno y Demanda Química de Oxígeno proporciona valores altos en el coeficiente de correlación (R) y el coeficiente de eficiencia (E), además de un valor bajo de errores cuadráticos medios (MSE). Confirmando que el Oxígeno Disuelto se predice con una precisión aceptable a partir de un pequeño conjunto de variables utilizando el modelo de red neuronal de alimentación directa y la red neuronal de función de base radial. Finalmente, el resultado obtenido se aplica a estimaciones de Oxígeno Disuelto de energía que se utilizan en sistema de gestión y tratamiento de aguas, siendo este parámetro importante para los cuerpos de agua.

Vijayashanthar et al., (2018) en el artículo mencionado “ Modeling fecal Indicator Bacteria in Urban Waterways Using Artificial Neural Networks” desarrollan un modelo predictivo para pronosticar la concentración de Bacterias Indicadoras Fecales en una vía fluvial urbana del Rio Chicago, utilizando redes neuronales artificiales mediante el uso del algoritmo de optimizador de propagación cuadrática media original (RMSprop). Para el análisis seleccionan ocho variables de entrada, de las variables propuestas originalmente como: temperatura del agua, turbiedad, precipitación diaria acumulada, de dos y siete días, descarga de flujo de río, distancia de la planta de recuperación de agua corriente arriba y el número de canales combinado con el alcantarillado aguas arriba. Adicionalmente, las plantas de recuperación de agua y los sistemas de desbordamiento demuestran ser importantes contribuyentes a la contaminación microbiana en el sistema de vías fluviales urbanas y son considerados en el modelo de Red Neuronal Artificial. Como resultado, el modelo desarrollado tiene una precisión del 86,5% para predecir si la concentración de coliformes en las heces se encuentra por encima o por debajo del límite especificado.

Valdivieso (2019), en el proyecto de investigación “ Optimización de biopolímeros en el proceso de coagulación- floculación para el tratamiento de lixiviados en la Ciudad de

Cuenca mediante el uso de redes Neuronales” utilizan un modelo computacional permitiendo reducir las operaciones de los ensayos de jarras en el laboratorio y la optimización de los recursos. Los resultados de efectividad de la aplicación de biopolímeros en el tratamiento de lixiviados logrados mediante la experimentación en laboratorio, son tomados como variables de entrada para la Red Neuronal Artificial para la estimación de los datos en forma predictiva; logrando establecer la dosis óptima para el tratamiento de lixiviados, dado que el tiempo utilizado para la determinación de las dosis de cloruro férrico y almidón mediante el método de Jarras en laboratorio es muy alto, por esta razón se estima que la red ayuda a disminuir el tiempo de las operaciones en los laboratorios. A través de la red se ingresan datos de diferentes escenarios o datos de la muestra de estudio prediciendo la dosis requerida para las variables de entrada. Finalmente, la aplicación de coagulación-floculación reduce los valores de turbidez en el lixiviado.

González & García (2020) en el artículo denominado “Elaboration of an artificial neural model for the estimation of turbidity and proposition of dosifications in the waswater treatmen”, se enfocan en la estimación del valor de la turbiedad de las aguas residuales de la industria avícola, utilizando el modelo neuronal artificial basado en redes de multicapa Feedforward-backpropagation. Los resultados de este proceso muestran que para los dos estudios de caso (sin catalizador y con catalizador), en el diseño con dos capas ocultas y el método de aprendizaje Levenberg-Marquardt. Se logra obtener un buen rendimiento, son más completos y fiables con un valor de Regresión lineal de ($R > 0,99$), infiriendo que las redes neuronales artificiales son utilizadas de manera confiable como herramienta de predicción. El uso de estas redes neuronales en esta aplicación permite reducir el número de ensayos de Pruebas de Jarras, lo que se traduce en ahorros de recursos de tiempo, floculación y coagulación, al centralizar la porción de prueba en un número reducido de ensayos en torno a la estimación óptima de coagulante y floculante.

Brocardo de León et al., (2020) en el artículo denominado “ Artificial Network for prediction of color absorption from an industrial textile effluent using modified sugarcane bagasse: characterization, kinetics and isotherm” se realizan experimentos por lotes sobre el efecto del pH de las aguas residuales, el tiempo de contacto entre el absorbente, la dosis de absorbente, el tamaño de la partícula y la concentración del color de las aguas residuales en el proceso de absorción; sin embargo las mejores condiciones operativas se encuentran en medios ácidos utilizando bagazo de caña de azúcar modificado químicamente (SBM) con un tamaño de 0.7 mm y una dosis de 0.6 g-1. Se emplea el modelo de red neuronal multicapa con cinco entradas y una salida, entrenada con ocho neuronas en la capa oculta. Finalmente, se realiza una comparación entre los datos experimentales y el modelo de red neuronal artificial predictivo demostrando que los resultados del rechazo de color se ajustan al modelo computacional con un coeficiente de determinación (R^2) de 0,928 y un error cuadrático medio (MSE) de 0.013; realizando ajustes no lineales en modelos isotérmico y de absorción. Finalmente, la absorción de bagazo de caña de azúcar modificado químicamente ha demostrado ser un método prometedor para el tratamiento de aguas residuales de teñido textil y el modelo de red neuronal artificial desarrollado es utilizado con éxito para hacer predicciones sobre el color final de las aguas residuales.

En el artículo denominado “Artificial neural network to estimate an index of water quality”, describe el diseño, entrenamiento y uso de un modelo de red neuronal de tres capas para calcular índice de calidad de agua donde constó de dieciséis puntos de muestreo del río Utcubamba, y sus afluentes. Utilizaron el software Matlab y el RNA unidireccional denominado perceptrón de tres capas: la capa de entrada incluye seis parámetros físico-químicos como: Oxígeno Disuelto, Demanda Bioquímica de Oxígeno, nitratos, coliformes fecales, pH y turbidez, una capa oculta y un índice de calidad de agua en la capa de salida; donde se encontró que el diseño óptimo del RNA fue 6-12-1 y los porcentajes para los grupos de entrenamiento, validación y prueba fueron 70%, 10% y 20%. Como resultado

evalúan el rendimiento mediante el error cuadrático y el coeficiente de correlación, dando correlaciones superiores a 0,94 en los valores medidos y citados (**Quiñones et al., 2020**)

Meza & González, (2020) en el artículo denominado “ Developmet o fan artificial neural network model for estimation of bod in seawaters” utilizan modelos de redes neuronales artificiales para estimar la DBO en el agua de mar, manejando un diseño de perceptrón multicapa, utilizando 3 capas de 20 neuronas cada una, en sus cuatro etapas de aprendizaje tales como: entrenamiento, validación y prueba; demostrando un alto rendimiento con el algoritmo de Levenberg-Marquardt. El mismo que proporciona valores altos del coeficiente de correlación tales como: 0.937; 0.951; 0.953 y 0.941; estas cifras muestran una concordancia entre los datos observados y las estimaciones realizadas por la red. Finalmente, los resultados obtenidos demuestran que la Demanda Bioquímica de oxígeno se puede estimar numéricamente en aguas marinas a través de modelos neuronales artificiales.

De esta manera, se busca determinar que las Redes Neuronales Artificiales son una forma atractiva de buscar interacciones entre los parámetros relacionados. Estas redes mapean un conjunto de patrones de salida después de crear un subconjunto de datos de proceso conocido como conjunto de entrenamiento y pueden realizar relaciones no lineales entre los parámetros del sistema (**Matich, 2017**). Por lo tanto, en el próximo capítulo se hace énfasis a los resultados obtenidos de la red neuronal, sacando los mismos resultados del contexto de investigación.

1.2 Redes Neuronales Artificiales

El primer estudio de red neuronal se remonta a principios del siglo XIX, pero el estudio de las redes neuronales no se estandarizó hasta las décadas de 1940 y 1950 y la investigación de redes neuronales cobró impulso con el movimiento de correlación. Este movimiento apoya la hipótesis de que el secreto del aprendizaje y del conocimiento se encuentra en axiomas o hechos indiscutibles. Además, el conocimiento independiente de la estructura que rige los símbolos, y representaciones del conocimiento es producido por el estrato más simple de inteligencia: el cerebro, especialmente sus neuronas y las múltiples conexiones entre ellas (**Mcculloch & Pitts, 1990**).

Las redes neuronales artificiales (R.N.A) son similares a un cerebro y, por lo tanto, exhiben algunas de propiedades similares al aprendizaje. Generalizar de casos antiguos a casos nuevos y excluir características básicas proporciona información irrelevante, entre otros. Todas estas características le confieren ventajas como:

- Aprendizaje adaptativo: la capacidad de aprender a realizar tareas en base a un entrenamiento previo.
- Autoorganización: cada red neuronal crea su propia organización basada en la formación inicial.
- Tolerancia a fallos: la destrucción parcial de la red neuronal artificial se reduce a la degradación estructural, cualquiera que sea la amplitud de una red en particular puede seguir trabajando.
- Operación en tiempo: los cálculos neuronales se pueden realizar en paralelo, ya que estos dispositivos especiales están hechos para lograrlo.


- Fácil inserción en la tecnología existente: puede tener chips en la red neuronal personalizados que puedan integrarse en el sistema.

En primer lugar, una red neuronal es un sistema de mapeo no lineal basado en el sistema nervioso de humanos y animales. En este sentido, quiere decir, que la red neuronal artificial está inspirada en una red neuronal biológica, compuesta por elementos como: un cuerpo celular, una rama principal el axón y varias ramas cortas denominadas dendritas, estas funciones son similares a las neuronas biológicas en sus funciones más comunes.

Estas se organizan de manera similar a las neuronas biológicas , como se muestra en la figura 1 (Caicedo & López, 2017). Las redes neuronales artificiales tienen una amplia gama de propiedades cerebrales, por ejemplo: aprender de la experiencia, generalizar ejemplos anteriores en ejemplos nuevos y abstraer las características principales de una serie de datos. Es decir, a cada conexión se le asocia un peso que representa la información que utilizan las neuronas para resolver un problema en particular.

Figura 1

Neurona Biológica vs Neurona Artificial



Nota: Semejanza entre una neurona biológica un modelo de red neuronal artificial (MAGIQUO DATA LIVE, 2019).

Por otro lado, las redes neuronales son herramientas poderosas para el reconocimiento y clasificación de patrones. Se utiliza en la predicción de problemas de ingeniería como alternativa en sistemas complejos, caracterizados por factores en sistemas de aproximación estadística no lineal o en sistemas que brindan soluciones computacionales basadas en algoritmos complejos y comprensivos (**Barthakur et al., 2012**).

Sin embargo, las redes neuronales (perceptrones) existen desde la década de 1940, y se han convertido en una parte importante de la inteligencia artificial en los últimos tiempos. Esto se debe al advenimiento de una técnica conocida como **retropropagación**. Esta tecnología permite que las redes ajusten los niveles de neuronas ocultas en situaciones en las que la salida no coincide con lo que esperaba el creador (**Pino et al., 2001**).

Estas, a su vez, incluyen variables cuantitativas y cualitativas, que consisten en una gran cantidad de procesadores simples unidos entre sí por conexiones ponderadas. Las unidades de procesamiento son neuronas, cada una de las cuales recibe entradas de otros nodos y produce salidas estándar simples basadas en información local, interna o proveniente de conexiones (**Araghinejad, 2014**). A su vez, se desarrollan como generalizaciones de modelos matemáticos del conocimiento humano o de la neurociencia, a partir de las siguientes consideraciones:

Primero, la información se procesa en muchos elementos simples llamados neuronas. Luego, las señales se transmiten entre neuronas mediante interconexión. Entonces, cada enlace conectado tiene un peso multiplicado por la señal enviada en una red neuronal típica. Finalmente, cada neurona aplica una función de activación (generalmente no lineal)

a la entrada de la red, es decir, la suma ponderada de las señales de entrada para determinar su señal de salida (**Serrano et al., 2010**).

1.3 Modelamiento de la Red Neuronal Artificial

Cuando se utiliza una Red Neuronal Artificial se tienen en cuenta tres etapas: la primera etapa involucra el diseño donde se elige el tipo de red neuronal (arquitectura), la cantidad de neuronas que generará, la función de activación definida para la función y el algoritmo de aprendizaje (**Caicedo & López, 2017**). 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.

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. Finalmente, 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.

1.3.1 Arquitectura de la red neuronal

Las neuronas se distribuyen en una red neuronal artificial que forma ciertos niveles de neuronas. En cualquier caso, si un grupo de neuronas artificiales recibe el mismo tipo de


información al mismo tiempo, se denomina capa. En la red, se pueden distinguir tres tipos de niveles:

- Entrada: todas las neuronas reciben información directamente de fuentes externas a la red.
- Oculta: pertenece a un grupo de neuronas dentro de la red y no tiene conexión directa con el exterior, donde el número de niveles ocultos puede ser de 0 o más. En general, las neuronas de cada nivel oculto comparten el mismo tipo de información, lo que se denomina como capa oculta. Además, en las capas ocultas se conectan entre sí de varias maneras, cuyo número determina las estructuras de la red neuronal
- Salida: un grupo de neuronas que transmiten información que la red procesa hacia el exterior.

Los diferentes modelos de la red existente están determinados por los diferentes métodos de distribución, conectividad y correlación entre los tres tipos de capas junto con el tipo de neuronas que las componen. La figura 2 muestra la arquitectura en capas de una red neuronal artificial con varios niveles.

Figura 2

Arquitectura de una red neuronal



Nota: Arquitectura unidireccional con cuatro capas de neuronas: una capa de entrada, dos capas ocultas y una capa de salida (Torres & Naveiro, 2019).

Las redes neuronales pueden trabajar con datos cambiantes y solo se requiere la máxima cantidad de información durante la fase de entrenamiento. Por lo tanto, cuando se ingresan datos a la red, se entrenará en una tarea específica y su rendimiento es relativo, lo que le permite identificar patrones desconocidos de manera rápida y sencilla, lo que reduce el tiempo para estimar parámetros (**Zavala et al., 2018**).

1.3.2 Diseño de la red Neuronal

Después de que se crea la red. Una red neuronal entrenada tiene en cuenta los siguientes parámetros: tipo de algoritmo, número de épocas y error máximo. El algoritmo comienza leyendo las matrices de entradas y las respuestas apropiadas de la Red Neuronal Artificial. Luego, los vectores de entrada y respuesta se normalizan usando el valor máximo de cada matriz para mejorar el entrenamiento de la red neuronal artificial. Después de normalizar la matriz de datos, se diseña una red neuronal artificial. El algoritmo utilizado para crear una muestra de este tipo se denomina *backpropagation* y se basa en una combinación de descenso de gradiente. Este método ajusta los pesos de la red neuronal en función de la tasa de error obtenida en las iteraciones, y el ajuste fino de los pesos le permite reducir la tasa de error y hacer que el modelo sea más confiable al aumentar la eficiencia computacional (**Sheela & Deepa, 2014**).

El algoritmo de *Backpropagation* es una regla de aprendizaje implementada en modelos de red con más de dos niveles. Una característica importante de este algoritmo es la representación interna del conocimiento que puede organizarse en la capa intermedia de neuronas para obtener cualquier relación entre las entradas y salidas de la red (**Hilera & Martínez, 1995**). Como se muestra en la ecuación 1, el número de capas secundarias

elegidas por prueba y error, el número de neuronas internas que cooperan durante el entrenamiento con pesos, es una parte en seis. Un tipo en el que se utiliza un algoritmo de retropropagación para formar una red multicapa.

$$e_{inst(n)} = \frac{1}{2} \sum_{j \in C} e_j^2(n)$$

Ecuación 1. Backpropagation

C: vector de neuronas de la capa de salida

n: número de muestras en las que se ha entrenado la red neuronal artificial

En el algoritmo de aprendizaje supervisado por descenso de gradiente, hay dos etapas: primero, se aplica el modelo de entrada, se pasa a través de las diferentes capas que compone la red hasta generar su salida. Luego, esta salida se compara con la salida deseada y se calcula el error generado por cada neurona de salida. Estos errores luego se propagan desde la capa de salida a todas las neuronas en las capas intermedias. Finalmente, cada neurona recibe un error proporcional a su contribución al error general de la red en función del error recibido y los pesos sinápticos se ajustan para cada neurona (**Villada et al., 2016**).

1.3.3 Fase aprendizaje de la red neuronal

A partir del conjunto de pesos de sinapsis, el proceso de aprendizaje define un conjunto de pesos que permiten a la red realizar correctamente una determinada tarea una tarea. Durante este proceso, la solución se prueba varias veces hasta que se alcanza un nivel de rendimiento suficientemente bueno (**Prieto et al., 2013**).

El proceso de aprendizaje de la red se divide en tres grupos según las características:

- a) Aprendizaje supervisado: se representa a la red un conjunto de patrones de entrada junto con la salida deseada. Los pesos se cambian en proporción al error que ocurre entre la salida real y la salida deseada.
- b) Aprendizaje no supervisado: en este punto no existe información sobre la salida esperada, por lo que los pesos deben ajustarse de acuerdo con la relación que existe entre los datos de entrada.
- c) Aprendizaje reforzado: se ubica entre los dos esquemas anteriores, porque un conjunto de gráficos de entrada se presenta a la red y se indica a la red si la salida lograda es correcta o no (**Morera, 2017**).

1.3.4 Programación de la Red Neuronal

Mediante el uso de la plataforma Matlab, se generan diferentes configuraciones para obtener una generalización de la red neuronal con la menor cantidad de error. Las neuronas están formadas por programación y modelos matemáticos que trabajan en grupo y al mismo tiempo procesan los datos de entrada. Para resumir el uso de funciones de activación no lineales, se describe la ecuación 2.

$$y = \left(\sum_k w_n x_n \right)$$

Ecuación 2. Respuesta de la neurona artificial

Donde:

x_n : Señal de salida de otros nodos de entradas.

w_n : Pesos de cada conexión

y : Función no lineal

Para facilitar la aproximación, se utiliza la función de activación Tan-Sigmoide. Esta función es una gran alternativa a la función Gaussiana, que da la sumade los pesos de cada neurona. De todos modos, al decidir sobre este tipo de problema, como se puede ver en la ecuación 3.

$$\mathbf{tansig}(x, y) = \frac{2}{1 + e^{2(x+y)}} - 1$$

Ecuación 3. Activación Tan-Sigmoid

Donde:

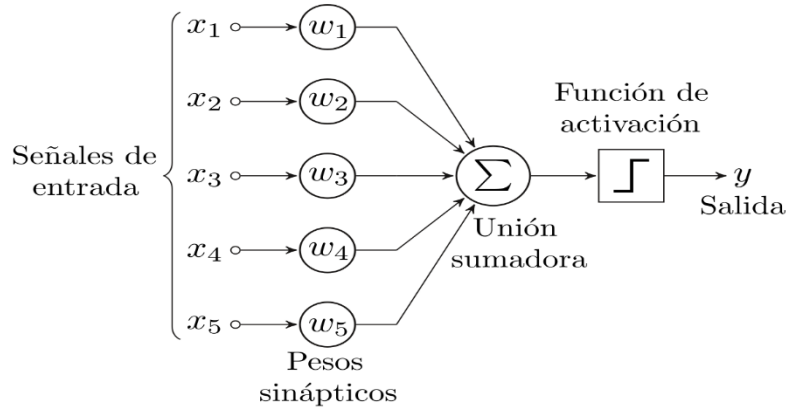
x: Vector de entrada, para el caso de estudio.

y: parámetros de la función, para el caso de estudio de estimación de error.

La red neuronal de la figura 3 contiene un modelo de aprendizaje supervisado en la red Perceptrón. Esta red utiliza una función multicapa, en la que las capas secundarias procesan un vector complejo: entrada, $x(n)$ con la función Tan-Sigmoid como activación no lineal de neuronas. En la primera columna del perceptrón, que es idéntica como la primera categoría del perceptrón, toma tres decisiones muy simples, a saber, el cálculo de la prueba de entrada. En el segundo nivel, cada uno de estos perceptores toma una decisión equilibrando el resultado del primer nivel de decisión. Asimismo, la segunda capa de percepción sensorial toma decisiones en un nivel más complejo y abstracto que la percepción de la primera capa. Finalmente, el perceptrón de la tercera capa toma decisiones más complejas, por lo que una red de perceptrones de varias capas puede participar en procesos de toma de decisiones complejas.

Figura 3

Estructura de la Red Neuronal Artificial con la función Tang-Sigmoid



Nota: Se utiliza la función de activación Tan-Sigmoid que da paso a la sumatorio de los pesos de cada neurona.

Para que el modelo de predicción de la Red Neuronal de Retro propagación de funcione correctamente, las variables cualitativas y cuantitativas utilizadas en la condición de estimación son similares.

Luego se menciona los modelos más importantes de las redes neuronales unidireccionales organizadas por capas. El objetivo es resolver el problema del aprendizaje supervisado mediante la instrucción de modelos estándar de redes neuronales de reconocimiento de patrones.

1.5 Modelos de Red Neuronal


1.5.1 Perceptrón Simple

Es un modelo unidireccional que consta de dos capas de neuronas, una de entrada y otra de salida la misma que opera en una percepción simple. Este modelo consta de n neuronas

de entradas y m neuronas de salida; además solo puede distinguir patrones de discriminación simples y linealmente separables (**Rosenblatt, 1962**). Las neuronas de entrada están separadas y la función de activación de la neurona de la capa de salida es de tipo escalonado como se muestra en la figura 4.

Figura 4

Perceptrón Simple



Nota: Arquitectura (lado izquierdo) y función de transferencia (lado derecho) de un perceptrón simple Fuente: (**Zilouchian, 2001**).

La figura 4 muestra que el perceptrón tiene siete entradas $X_1, X_2, X_3, X_4, X_5, X_6, X_7$. En general, las entradas pueden variar. Rosenblatt sugirió una regla simple para calcular el resultado. Proporciona pesos, W_1, W_2, \dots, W_n , número reales que representan el significado de la entrada a la salida. La salida de la neurona está determinada por la suma ponderada $\sum_j W_j X_j$, que es lo mismo que los pesos; donde, el umbral es un parámetro de la neurona representado por un número real. Se debe tomar en cuenta que cuando la salida de una unidad de procesamiento es 1 se dice que esta activa o en ejecución y tiene un estado 1, mientras que, si su salida es 0, se dice que ha dejado de funcionar o apagado, el estado representa 0.


Este es un método de detección de error y corrección. Sólo aprende, es decir, modifica los pesos, cuando se equivoca (**Minsky & Papert, 2017**).

1.5.1.1 Función escalón

Esta función se asocia a una neurona binaria cuando la entrada total es mayor o igual al umbral de la neurona, es decir, la activación es 1, si es menor la activación es 0 o -1. En la figura 5 de la izquierda se observa que la salida de una neurona cuando esta activada es 1 y cuando no lo está, la salida es cero. Luego en la misma figura de la derecha se observa que cuando la red está habilitada la salida es 1 y cuando la salida de la neurona no está habilitada tiene un valor -1.

Figura 5

Función de activación escalón




Nota: El perceptrón comprueba si las entradas ponderadas son mayor o menor que un cierto umbral y genera una salida. Fuente: (**Ponce, 2011**)

1.5.2 Red retropropagación o backpropagation

Se basa en reglas de aprendizaje que solo se pueden aplicar a modelos de red multicapa. Una característica fundamental de este tipo de red, consta de tres capas: la primera, una capa de entrada A_i , con m neuronas. Una capa de salida C_k con p neuronas y al menos una capa de oculta B_i con n neuronas. Donde cada neurona de una capa, excepto la entrada recibe entradas de todas las neuronas de la capa interior y envía su salida a todas las neuronas de la posterior a excepción de la capa de salida. (Funahashi, 1989). De esta manera la representación interna del conocimiento que puede organizar en la capa o capas intermedias logran una coincidencia entre las entradas y salidas del algoritmo como se ilustra en la figura 6 (Rumelhart & Hintont, 1986; Vališ et al., 2020).

Figura 6

Perceptrón Multicapa



Nota: Arquitectura del perceptrón las entradas se muestran a la izquierda y a la derecha se encuentran las unidades de salida de la unidad procesadora. Fuente: (Zilouchian, 2001).


Este tipo de red es importante porque involucra la auto ponderación de las neuronas en las capas intermedias para ver la relación entre un conjunto de patrones de datos y la salida correspondiente. (García et al., 2010).

1.5.2.1 Función sigmoideal

Con la función de activación sigmoidea, el valor dado está cerca de uno de los valores asintóticos, por lo que el valor de salida está en la región sigmoidea. Cuando la pendiente es alta, esta función tiende hacia la función de clasificación como muestra en la Figura 7. Es importante recordar que la función seno siempre es derivada positiva y tiende a cero para valores grandes positivos o negativos, y también asume su valor máximo cuando $x=0$. Esto permite el uso de reglas de aprendizaje de funciones escalonadas, con la ventaja de que la derivada se determine sobre el período de tiempo (Ponce, 2011).

Figura 7

Función sigmoideal



Nota: Análisis de la función de activación sigmoideal de acuerdo a los criterios mencionados en la descripción. Fuente: (Ponce, 2011).

1.5.3 Conexión de redes hacia delante o feedforward

Son conexiones que van hacia delante y son unidireccionales. Dependiendo de cuántas capas tengan, pueden ser de una o varias capas. Esta etapa comienza cuando aparece un patrón en la capa de entrada. Las unidades de entrada reciben el valor y calculan el valor de activación o el valor de salida de la primera capa, luego las otras capas realizan la etapa de propagación hacia delante estableciendo el nivel de activación de las otras capas. Lo mismo se aplica en el desarrollo de este proyecto de investigación actual, ya que la red neuronal que se utilizará es una red neuronal multicapa (**Basogain et al., 2017**).

1.5.4 Conexión de redes hacia atrás o feedback

Las redes feedback poseen conexiones laterales y hacia atrás. Junto con el algoritmo de propagación hacia atrás conocido como backpropagation, el error se propaga de manera inversa al funcionamiento normal de la red, de esta forma el algoritmo detecta errores en el proceso de aprendizaje de las capas de entrada más profundas. Con base en este cálculo de error, el peso de cada categoría se actualiza de acuerdo con la diferencia entre la salida real y la salida deseada.

1.5.5 Algoritmo de Levenberg- Marquardt

Es una técnica que utiliza la llamada matriz Hessiana para mejorar la red. Las entradas de esta matriz son las derivadas cuadráticas de la función de error con respecto a los pesos.

Está diseñado para realizar el aprendizaje de la segunda derivada sin estimación de la Matriz Hessiana. Si la función error se considera como una especie de MSE o RMSE de suma cuadrada, entonces la matriz Hessiana puede considerarse una aproximación como la matriz Jacobiana, que contiene las primeras derivadas de los errores de red asociados con los pesos. El algoritmo de Levenberg-Marquardt ajusta rápidamente los pesos entre otros métodos (**Dongardive & Abraham, 2017**). El parámetro escalar que controla el comportamiento del algoritmo es cero. El algoritmo sigue el método de Newton, utiliza la aproximación de la matriz Hessiana y si el valor del parámetro escalar es muy alto, entonces el algoritmo de Levenberg-Marquardt una regla delta general con baja tasa de aprendizaje y representa la homogeneidad de la matriz (**Akinola & Oyabugbe, 2015; Ebtehaj & Bonakdari, 2016**).

1.6 Herramienta de aplicación

1.6.1 Lenguaje Matlab

Matlab es un lenguaje técnico para aplicaciones informáticas que integran computación, visualización y programación en un entorno fácil de usar, donde las soluciones se expresan en notación matemática.

Toolboxes, la caja de herramientas incluida con MATLAB, contiene muchos modelos matemáticos, incluidas representaciones. En esta herramienta se encuentra Neural Network relacionada con los tipos de redes neuronales. Contiene demos y paneles de control para administrar nuevas redes con parámetros relativos, que son muy útiles para trabajar con una red neuronal artificial. (**Matlab, 2021**)

Gracias a estos antecedentes por la edición de libros, artículos técnicos y científicos y norma de calidad de agua. Se 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. Estimando el 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 del Cantón de Pelileo, fijando criterios adecuados para el desarrollo de este trabajo de acuerdo con los objetivos planteados.

1.7 Objetivos

Objetivo General

Evaluar la estimación de error de la Demanda Bioquímica de Oxígeno en aguas residuales de las empresas del Jeans de la Ciudad de Pelileo utilizando redes neuronales artificiales.

Objetivos Específicos

- Desarrollar una base de datos mediante la clasificación de variables cualitativas y cuantitativas, para la estimación de la DBO_5 en las aguas residuales pertenecientes a las industrias del Jeans.
- Diseñar un modelo basado en la Red Neuronal Artificial que estime el valor de DBO_5 a la salida del proceso de producción en las industrias del Jeans empleando el software Matlab.
- Comparar los valores estimados de la Red Neuronal con los valores reales, aplicando la prueba de TUKEY para la DBO_5 en aguas residuales pertenecientes a las industrias del Jeans.

1.8 Variables

Variable dependiente: La Demanda Bioquímica de Oxígeno (DBO5).

Variables independientes: Parámetros fisicoquímicos de las aguas residuales de las industrias del Jeans.

CAPÍTULO II. METODOLOGÍA

2.1 Enfoque

El presente proyecto de investigación adopta enfoques cualitativos y cuantitativos, con un diseño teórico-fundamentado. Se elabora una base de datos clasificando las variables cualitativas y cuantitativas utilizadas para predecir el comportamiento de la variable dependiente (error de medición de DBO₅) 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. Comparación entre estimaciones de una Red Neuronal y valores reales de aguas residuales de las empresas de Jean (**Pascal, 2019**).

2.2 Materiales

Para desarrollar este proyecto se utilizó una computadora, en la cual se realizó través de una red wifi, para acceder de manera confiable y segura a bases de datos, tales como: eLibro, Scopus, Dialnet, Springer; junto con la Biblioteca Virtual de la Universidad Técnica de Ambato como sistema de recursos. Se realiza una búsqueda bibliográfica y se utiliza la plataforma de programación Matlab para el diseño de redes neuronales.

2.3 Métodos

2.3.1 Modalidad de investigación

Para respaldar este proyecto, es importante realizar una investigación sistemática basada en fuentes de información válidas y coherentes, como libros, revistas, artículos científicos, actas de congresos y Normas Técnicas Ecuatorianas en Calidad de Agua; como referencia en la construcción de una teoría que se relacione con la estimación de la Demanda Bioquímica Oxígeno para las aguas residuales por las empresas del jean y el uso de redes neuronales artificiales publicada en los últimos cinco años. **(Bilińska & Gmurek, 2021)**.


2.4 Descripción de la zona de estudio

El área de estudio está compuesta por el Cantón San Pedro de Pelileo ubicado en la provincia de Tungurahua, con una extensión de 202 km² y una población de 56.573 habitantes; limita al norte con el Cantón Pillaro, al sur con la provincia de Chimborazo, al este con los Cantones de Baños y Patate, y al Oeste con los Cantones Ambato, Cevallos y Quero.

Su cabecera cantonal, es la ciudad de Pelileo, conocida como la “Ciudad Azul” por la presencia de la industria del Jean y se encuentra bañada por los ríos Patate y sus afluentes: Panchalika al Este y el Río Chambo al Sur **(Tungurahua Turismo, 2021)**

Figura 8

Mapa de Ubicación Geográfica del Cantón Pelileo



Nota. El gráfico representa la ubicación de las empresas de lavado y tinturado de telas tipo jean dentro del Cantón Pelileo. Tomado de la Universidad Nacional de Chimborazo. Fuente: (Chuqui & Sánchez, 2018).

2.5 Población

Según el Catastro 2017-2018 del GAD de Pelileo, existe aproximadamente 46 lavanderías, por lo que no es necesario calcular la muestra.

2.6 Recolección de la información

La información es recolecta por las empresas del Jean, donde se recogen datos cualitativos y cuantitativos para su posterior clasificación y formación de redes. Estos códigos se

identifican mediante una serie de números (1,2,3...N) manteniendo la confidencialidad de la información de las empresas. Las variables de entrada se especifican en caracteres alfabéticos (A, B, C, D...N) de acuerdo con el modelo propuesto, lo que contribuye a la estimación del error de la Demanda Bioquímica de Oxígeno como se muestra en la Tabla 1 y la Tabla 2.

Tabla 1.

Codificación de variables

PARÁMETRO	VARIABLE	CÓDIGO
FÍSICOS		A
		B
		C
		D
		F
		G
		H
QUÍMICOS		I
		J
		K
		L
		M
		N
		Ñ
		O
	DB05	SALIDA

Nota: Codificación de variables utilizadas para la red neuronal artificial.

Fuente: Elaboración propia.

Tabla 2.

Codificación de las lavanderías

Empresa	Código
	1
	2
	3
	4
	N

Nota: Codificación de las empresas utilizadas para la red neuronal artificial obtenidas del catastro de GAD Pelileo de los años 2017-2018 juntamente con el aporte de un laboratorio de análisis de agua certificado.

2.7 Estimación de las variables de entrada y variable de salida

Para la matriz de datos, 6 parámetros físicos como: temperatura, humedad relativa, presión atmosférica, concentración de sólidos suspendidos, sólidos sedimentales, sólidos totales y 9 parámetros químicos como: potencial de hidrógeno, sulfuros, sulfatos, nitrógeno total, DQO, fenoles, tensioactivos, fosforo total, aceites y grasas; obtenido de catastro de GAD Pelileo de los años 2017-2018 con el aporte de un laboratorio de análisis de agua certificado. 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 (Ver Anexo1) (**Norma de Calidad Ambiental y Descarga de Efluentes, 2011**).

Datos de 30 empresas seleccionadas para este proyecto. Los mismos elementos se utilizan como puntos de partida para el modelo de datos importados para el entrenamiento de redes (Ver Anexo 2) (**Gilpavas et al., 2018**).

2.8 Elaboración del modelo neuronal artificial


El modelo neuronal para la predicción de DBO_5 fue desarrollado por una red Feed Forward Backpropagation. Se utilizó la DBO_5 como variable de salida y los parámetros físicos y químicos mencionados anteriormente como variables de entrada. Estos parámetros fueron seleccionados en base a su efecto sobre el proceso de la DBO_5 y teniendo en cuenta su frecuencia de uso en estudios previos.

2.8.1 Diseño red neuronal artificial

En la figura 9 incluye el diseño de la capa de entrada con 15 variables: la primera capa oculta con 10 neuronas, la segunda capa sumatoria con 1 neurona y una capa de salida con la variable de respuesta correspondiente a las necesidades de generación estimadas. Según el algoritmo de Levenberg-Marquardt.

Figura 9

Diseño de la red Neuronal Artificial Feed Forward Backpropagation



Nota: Descripción del diseño de la red utilizada para la estimación de error de la DBO_5

Fuente: Elaboración propia.

2.8.2 Perfiles de entrada y salida

En este estudio, 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 3.

Se ha configurado un perfil de salida de entrenamiento (SampleOut= matriz de 15x1 double). Las 15 filas representan las variables y la columna la estimación de DBO₅ como se muestra en la Tabla 1.

Tabla 3.

Inicialización de Variables

FÍSICOS	A	Temperatura °C
	B	Humedad relativa %
	C	Presión atmosférica (Pascal)
	D	Sólidos Totales
	F	sólidos sedimentales
	G	Sólidos Suspendidos
	QUÍMICOS	H
I		Sulfuros
J		sulfatos
K		Nitrógeno Total
L		DQO
M		Fenoles
N		Tensioactivos
Ñ		Fosforo total
O		Aceites y Grasas

Nota: Descripción de variables utilizadas para la red neuronal artificial.

Fuente: Elaboración propia.

A continuación, se crea una Matriz de Prueba (Probe=Matriz 15x1 double) y una Matriz de Prueba (Test1=Matriz 15x1 double), donde las sumas de las empresas 1 y 2 se disminuye del valor real de la predicción de salida de DBO₅. Cabe señalar que todas las muestras de entrada y salida, están escaladas y tienen el mismo valor real que se ingresó en el Matlab (Ver en el Anexo 2).

2.8.3 Retropropagación de la red neuronal artificial

Se utilizó un algoritmo llamado Levenberg-Marquardt para acelerar el proceso y diseñar el aprendizaje a través de segundas derivadas. El peso se ajuste rápidamente, evitando cálculos matriciales. Dicho código, la instrucción *trainlm* escrita, conectadas a una arquitectura de Perceptrón de Multicapa (MLP) y calcula los valores de DBO₅ (Ver Anexo 4) (Payal et al., 2015).

2.8.4 Entrenamiento de la red neuronal

Se estiman 1000 veces de entrenamiento o épocas hasta alcanzar un valor de error mínimo cercano a $1e^{-07}$ en cada intervalo de entrenamiento.

2.8.5 Diseño de código en Matlab

Para verificar y monitorear los resultados, se genera el siguiente código utilizando las herramientas disponibles en Matlab para hacer coincidir los resultados obtenidos de la red neuronal con los valores reales (Ver Anexo 5).

2.9 Prueba de Tukey

Comparar la eficacia del modelo como método de estimación del error DBO_5 . Se aplica la prueba de Tukey con la ayuda del programa estadístico InfoStat, para comparar los valores estimados de la red neuronal con los valores reales (Ver Anexo 6)

CAPÍTULO III. RESULTADOS Y DISCUSIÓN

3.1 Análisis y discusión de resultados

Para el análisis y discusión de los resultados, se considera que la muestra estimada debe ser realista y grande; a fin de establecer un proceso en el que todos los parámetros utilizados sean válidos. 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 DBO_5 , entre los valores estimados por la red neuronal y los valores reales.

En la Tabla 4 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. Epoch es el número de veces que se aplica el algoritmo de entrenamiento al conjunto de datos, con el objetivo de realizar un entrenamiento de 10 épocas para lograr un entrenamiento óptimo. Es importante señalar que menos épocas generará errores en la red, mientras que más épocas llegarán al entrenamiento. 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.

Tabla 4.

Resultados de la simulación de la Red Neuronal Artificial

ÍTEM	DETALLE
Tipo de entrenamiento	Descenso de gradiente 10 épocas de entrenamiento
Valor de coeficiente de correlación	0.98081


Nota: Se detalla los resultados obtenidos en el proceso de simulación de la Red Neuronal.

Fuente: Elaboración propia.

En la Figura 10, a medida que aumenta el número de épocas, el gradiente de error tiende a cero por lo que los datos no están muy dispersos.

Figura 10

Descenso de la gradiente de error



Nota: Se observa que el entrenamiento 10 épocas, el gradiente de error tiende a cero.


Fuente: Elaboración propia.

En la Figura 11 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)**, lo que demuestra un alto rendimiento con el 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).

Figura 11

Valor de correlación obtenido




Nota: Coeficiente de correlación obtenido en la capa de salida de la red neuronal.

Fuente: Elaboración propia.

En la Figuras 12 y 13 se muestra la comparación entre los valores reales y calculados por la red neuronal. Se evidencia el menor cambio en sus estimaciones. La Figura 14 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).

Figura 12


Valor de la Demanda Bioquímica de Oxígeno medido



Nota: Los puntos azules representan el valor de DBO₅ obtenido de las empresas del Jeans de la Ciudad de Pelileo. **Fuente:** Elaboración propia.

Figura 13


Valor de la Demanda Bioquímica de Oxígeno estimado por la Red Neuronal Artificial



Nota: Los puntos azules representan el valor de DBO₅ calculado por la red neuronal. **Fuente:** Elaboración propia.

Figura 14

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. **Fuente:** Elaboración propia.

3.1.1 Pronóstico de la red neuronal

En la Tabla 5 se observan los valores reales obtenidos al medir la variable de la DBO5 en las empresas 1 y 2.

Tabla 5.

Medición real de la variable de impacto

		Empresa 1	Empresa 2	
FÍSICOS	A	Temperatura °C	15	16
	B	Humedad relativa %	86	82
	C	Presión atmosférica (Pascal)	103,1	103
	D	Sólidos Totales	1352	1420
	F	sólidos sedimentales	0,2	1,5
	G	Sólidos Suspendidos	50	50
	QUÍMICOS	H	Potencial de Hidrógeno	7,04
I		Sulfuros	0,13	0,19
J		sulfatos	110	120
K		Nitrógeno Total	8,51	9,26
L		DQO	131	165
M		Fenoles	0,022	0,026
N		Tensioactivos	0,120	0,110
Ñ		Fosforo total	1,7	1,7
O		Aceites y Grasas	2,2	2
Salida Real	DBO5	65	70	

Nota: Descripción de valores reales de las variables influyentes en las empresas 1 y 2 del Jeans. **Fuente:** Elaboración propia.

La Tabla 6 describe los valores sugeridos para evaluar sólidos totales en relación a la DBO₅. Estos valores fueron simulados en una red neuronal artificial preentrenada para estimar el error de la Demanda Bioquímica de Oxígeno en las empresas 1 y 2. De esta manera, se pueda hacer la misma estimación para cualquier empresa, o si es necesario, cambiar los valores de las variables de entrada al sistema.

Tabla 6.

Valor pronosticado para la variable de impacto en relación a Sólidos Totales

			Empresa 1	Empresa 2
FÍSICOS	A	Temperatura °C	15	16
	B	Humedad relativa %	86	82
	C	Presión atmosférica (Pascal)	103,1	103
	D	Sólidos Totales	1000	1000
	F	sólidos sedimentales	0,2	1,5
	G	Sólidos Suspendidos	50	50
	QUÍMICOS	H	Potencial de Hidrógeno	7,04
I		Sulfuros	0,13	0,19
J		sulfatos	110	120
K		Nitrógeno Total	8,51	9,26
L		DQO	131	165
M		Fenoles	0,022	0,026
N		Tensioactivos	0,120	0,110
Ñ		Fosforo total	1,7	1,7
O		Aceites y Grasas	2,2	2
Salida Real		DBO₅	60,135	67,8202

Nota: Descripción de valores pronosticados de las variables influyentes en las empresas 1 y 2 del Jeans. **Fuente:** Elaboración propia.

En base a los valores pronosticados de las empresas 1 y 2 de la Tabla 6, 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.

Los datos obtenidos por las empresas 1 y 2 estipulan un pronóstico de decrecimiento del DBO₅. Con un error cercano al vector de error de la red neuronal, en relación al parámetro de Sólidos Totales. De acuerdo con la referencia bibliográfica, los valores estimados se encuentran dentro del límite máximo permisible (Ver Anexo 1).

3.1.2 Comparación de valores medidos por la Red Neuronal vs Valores Reales.

La figura 15 muestra los resultados del Análisis de Varianza y la Prueba de Tukey. Se compararon los valores obtenidos en la simulación con valores de laboratorio y se obtuvo un índice de confianza del 95%. Entonces, 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.

El modelo neuronal tiene las ventajas de precisión, rentabilidad, velocidad de monitoreo, reconocimiento de patrones complejos, captura de comportamiento no lineal, etc., lo que demuestra que la red neuronal es una herramienta efectiva para modelar la Demanda Bioquímica de Oxígeno (**Li & Zhang, 2020; Roshni & Kuruvila, 2017**).

Figura 15

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			
<i>Error: 4032,9813 gl: 58</i>			
METODOS	Medias	n	E.E.
laboratorio	104,50	30	11,59 A
RED	104,85	30	11,59 A

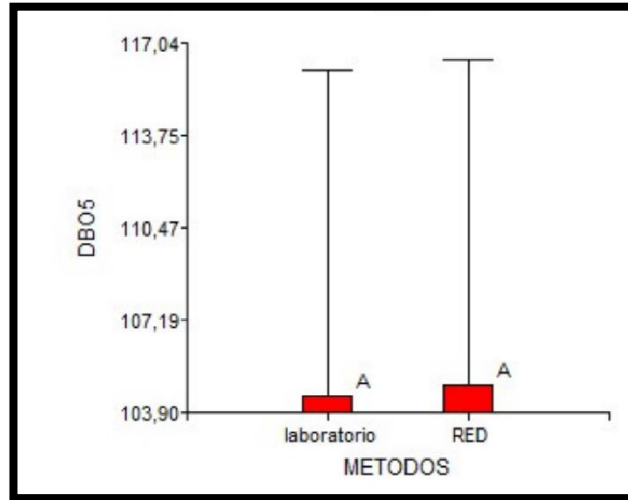
Medias con una letra común no son significativamente diferentes (p > 0,05)

Nota: Datos obtenidos de Análisis de Varianza y Prueba de Tukey mediante el programa estadístico InfoStat. **Fuente:** Elaboración propia.

Las Figuras 15 y 16 muestran la relación entre la respuesta esperada y la red neuronal. Asimismo, comparten la misma letra de grupo (A) y tienen un valor p de 0,9833. Esto da como resultado un valor de confianza del 98,33%, que es ideal para diagnosticar la salida estimada de la Demanda Bioquímica de Oxígeno por el proceso de las empresas de Jean.

Figura 16

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



Nota: Descripción de valores reales vs valores estimados, donde se encontró un grupo homogéneo (A), con un nivel de cumplimiento de 98,33%. **Fuente:** Elaboración propia.

La Figura 17 muestra que el valor p es igual a 0,8890, lo que da el valor del error estimado por la red neuronal, entre el valor real y el valor de la red.

Figura 17

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: Detalle del valor de estimación de error de la Red Neuronal Artificial. **Fuente:** Elaboración propia.

Finalmente, a pesar de estos resultados excelentes, se observó que el número de neuronas y la capa oculta son independientes de la DBO₅. Porque el modelo neuronal no utiliza las ecuaciones que describen el proceso de la DBO₅ 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**).

CAPÍTULO IV. CONCLUSIONES

4.1 Conclusiones

Este trabajo de investigación muestra que el aprendizaje de un modelo neuronal artificial basado en una red neuronal multicapa feedforward-backpropagation utilizada para la estimación de error de la Demanda Bioquímica de Oxígeno puede reducir la cantidad de pruebas en laboratorio. Ahorrando así recursos como: tiempo, reactivos y la parte económica; enfocando la parte experimental a un número reducido de pruebas. En cualquier caso, 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.

La matriz de datos se desarrolló para identificar las variables de entrada como parámetros físicos y químicos. Están relacionados a la Demanda Bioquímica de Oxígeno y se seleccionan en función de su efecto sobre el proceso de la DBO₅. Teniendo en cuenta la frecuencia de uso en estudios previos, sustentando así que la red neuronal artificial es una herramienta adecuada de predicción global.

Se ha demostrado que un modelo diseñado con una red neuronal puede utilizarse para estimar la Demanda Bioquímica de Oxígeno en aguas residuales de empresas de Jeans. La Red Neuronal Feed Forward Backpropagation, un perceptrón multicapa, fue predicha por el valor del programa MATLAB. Logró un alto rendimiento con mínima dispersión entre los datos, combinado con el algoritmo de Levenberg-Marquardt ($R > 0,98081$). Usando una matriz de 27 neuronas que consta de cuatro capas: una de entrada, dos ocultas y una

salida. En el caso del entrenamiento optimiza la afinación de los parámetros óptimos para 10 épocas por descenso de gradiente. Observando que el porcentaje de error tiende a cero. Permite que la red demuestre la idoneidad del modelo con un alto grado de confianza en el resultado del proceso de producción de las empresas de Jean.

Se compara 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.

Hay que recordar que el número de neuronas y capas ocultas es independiente de la DBO₅. Porque el modelo neuronal no utiliza ecuaciones que describen el proceso de la DBO₅ en sus cálculos matemáticos. Se concluyó que este tipo de modelo neuronal es solo una parte de la función matemática que construye la red a partir del conjunto de observaciones.

4.2 Recomendaciones

- En el campo de la Ingeniería Bioquímica, se fomenta la innovación tecnológica continua con este trabajo, especialmente la aplicación de técnicas informáticas RNA (red neuronal artificial), a nuevos trabajos que impliquen riesgo o

incertidumbre, ya que pueden verse como una alternativa a los sistemas tradicionales.

- Para aumentar la fiabilidad de los resultados obtenidos en este estudio, es conveniente realizar estudios en otros campos y utilizar el modelo en situaciones reales.
- Se recomienda utilizar una base de datos más grande que la descrita en el proyecto, ya que esto puede mejorar el rendimiento de predicción de la red neuronal artificial.

REFERENCIAS BIBLIOGRÁFICAS

- Ahmed, A. A. M. (2017). Prediction of dissolved oxygen in Surma River by biochemical oxygen demand and chemical oxygen demand using the artificial neural networks (ANNs). *Journal of King Saud University - Engineering Sciences*, 29(2), 151–158. <https://doi.org/10.1016/J.JKSUES.2014.05.001>
- Akinola, S. O., & Oyabugbe, O. J. (2015). Accuracies and Training Times of Data Mining Classification Algorithms: An Empirical Comparative Study. *Journal of Software Engineering and Applications*, 08(09), 470–477. <https://doi.org/10.4236/jsea.2015.89045>
- Araghinejad, S. (2014). *Artificial Neural Networks* (pp. 139–194). Springer, Dordrecht. https://doi.org/10.1007/978-94-007-7506-0_5
- Bae, J., Harold, F., & Kim, S. D. (2006, February 27). Influences of new azo dyes to the aquatic ecosystem - ProQuest. *Científica*, 7(1). <https://doi.org/10.1007/BF02933599>
- 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.
- Barrios, L., Gaviria, L., Agudelo, E., & Cardona, S. (2015). Technologies for the removal of dyes and pigments present in wastewater . *Redalyc*, 82, 118–126. <https://www.redalyc.org/articulo.oa?id=49639089015>
- 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
- Basogain, X., Olabe, M. Á., & Olabe, J. C. (2017). Pensamiento Computacional a través de la Programación: Paradigma de Aprendizaje. *Revista de Educación a Distancia (RED)*, 46(2), 1–33. <http://www.um.es/ead/red/46>
- Bilińska, L., & Gmurek, M. (2021). Novel trends in AOPs for textile wastewater

- treatment. Enhanced dye by-products removal by catalytic and synergistic actions. *Water Resources and Industry*, 26, 100160. <https://doi.org/10.1016/J.WRI.2021.100160>
- Blatt, E. F., Giannetti, B. F., Agostinho, F., Sevegnani, F., Wang, Y., & Almeida, C. M. V. B. (2020). Evaluating producers as resource consumers and alternative consumption patterns: Outcomes from emergy synthesis of the jeans supply chain. *Cleaner and Responsible Consumption*, 1, 100002. <https://doi.org/10.1016/J.CLRC.2020.100002>
- Braga, J. K., & Varesche, M. B. A. (2014). Commercial Laundry Water Characterisation. *American Journal of Analytical Chemistry*, 5, 8–16. <https://doi.org/10.4236/ajac.2014.51002>
- Brito, H. (2000). *Texto Básico de Operaciones Unitarias I* (E. Docucentro (ed.)). https://www.researchgate.net/publication/313673724_Texto_Basico_de_Operaciones_Unitarias_I
- Brocardo de León, V., Ferraz, B., Brusamarello, C., Domenico, M., & Batista, F. (2020). Artificial neural network for prediction of color adsorption from an industrial textile effluent using modified sugarcane bagasse: Characterization, kinetics and isotherm studies. *Environmental Nanotechnology, Monitoring & Management*, 14, 100387. <https://doi.org/10.1016/J.ENMM.2020.100387>
- Caicedo, E., & López, J. (2017). Una aproximación práctica a las redes neuronales artificiales. In *Una aproximación práctica a las redes neuronales artificiales*. <https://doi.org/10.25100/peu.64>
- Chakraborty, J. N. (2010). Introduction to dyeing of textiles. In *Fundamentals and Practices in Colouration of Textiles* (pp. 1–10). <https://doi.org/10.1533/9780857092823.1>
- 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>

- Chuqui, E., & Sánchez, V. (2018). ESTIMACIÓN DE LA EFICIENCIA DE LOS SISTEMAS DE TRATAMIENTO DE AGUAS RESIDUALES PARA EL SECTOR TEXTIL EN EL CANTÓN PELILEO [Universidad Nacional de Chimborazo]. In *Estimación de la eficiencia de los sistemas de tratamiento de aguas residuales para el sector textil en el Cantón Pelileo*. <http://dspace.unach.edu.ec/bitstream/51000/5339/1/UNACH-EC-ING-AMBT-2019-0003.pdf>
- Cúrvulo, J., de Araújo, S. A., Biazus, J., & De Souza, R. (2015). Simulation of biodegradation process of wastewater from meat industry by means of a multilayer perceptron artificial neural network. *Ingeniare. Revista Chilena de Ingeniería*, 23(2), 269–275. <https://doi.org/10.4067/S0718-33052015000200011>
- Desarrollo, C. de la O. sobre C. y, & 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>
- Funahashi, K. I. (1989). On the approximate realization of continuous mappings by neural networks. *Neural Networks*, 2(3), 183–192. [https://doi.org/10.1016/0893-6080\(89\)90003-8](https://doi.org/10.1016/0893-6080(89)90003-8)
- 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
- García, I., Rodríguez, J. G., López, F., Tenorio, Y. M., La Laguna, B., Ticomán, C., Gustavo Madero, D. A., F-México, D., & López Mateos, A. (2010). Transporte de

- Contaminantes en Aguas Subterráneas mediante Redes Neuronales Artificiales. *Información Tecnológica*, 21(5), 79–86. <https://doi.org/10.4067/S0718-07642010000500011>
- Gavril, M., & Hodson, P. V. (2007). Investigation of the Toxicity of the Products of Decoloration of Amaranth by *Trametes versicolor*. *Journal of Environmental Quality*, 36(6), 1591–1598. <https://doi.org/10.2134/jeq2006.0433>
- 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>
- Global Fashion Agenda & The Boston Consulting Group. (2018, September 19). *El pulso de la industria de la moda 2017*. <https://gabrielfariasiribarren.com/el-pulso-de-la-industria-de-la-moda/>
- 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>
- Grobbelaar, J. U. (2009). Encyclopedia of Inland Waters. *Encyclopedia of Inland Waters*, 699–704. <http://www.sciencedirect.com/science/article/pii/B9780123706263000752>
- 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
- Hamid, Z. (2014). Evaluation of multivariate linear regression and artificial neural networks in prediction of water quality parameters. *Journal of Environmental Health Science & Engineering*, 3–8. <https://doi.org/10.1186/2052-336X-12-40>

- Hilera, R., & Martínez, V. (1995). *Redes neuronales artificiales: Fundamentos, modelos y aplicaciones (Serie Paradigma) (Spanish Edition)* (Issue January 2017). https://www.researchgate.net/publication/44343683_Redес_neuronales_artificiales_fundamentos_modelos_y_aplicaciones_Jose_Ramon_Hilera_Gonzalez_Victor_Jose_Martinez_Hernando
- Hussain, J., Hussain, I., & Arif, M. (2004). Characterization of textile wastewater. In *Journal of Industrial Pollution Control* (Vol. 20, Issue 1, pp. 137–144). <https://doi.org/10.1016/b978-0-12-802326-6.00002-2>
- INEC. (2020). *Producción de la Industria Manufacturera* /. <https://www.ecuadorencifras.gob.ec/produccion-industria-manufacturera/>
- 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>
- Khosravanipour Mostafazadeh, A., Benguit, A. T., Carabin, A., Drogui, P., & Brien, E. (2019). Development of combined membrane filtration, electrochemical technologies, and adsorption processes for treatment and reuse of laundry wastewater and removal of nonylphenol ethoxylates as surfactants. *Journal of Water Process Engineering*, 28(September 2018), 277–292. <https://doi.org/10.1016/j.jwpe.2019.02.014>
- 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>
- Lafi, R., Gzara, L., Lajimi, R. H., & Hafiane, A. (2018). Treatment of textile wastewater by a hybrid ultrafiltration/electrodialysis process. *Chemical Engineering and Processing - Process Intensification*, 132, 105–113.

<https://doi.org/10.1016/J.CEP.2018.08.010>

Lastre, M., Lastre, A., & García, G. (2014, June 30). Artificial Neural Networks in the prediction of insolvency. A paradigm shift to traditional business practices recipes. *Enfoque UTE*, 5(2), 38–58. <https://doi.org/10.29019/ENFOQUEUTE.V5N2.39>

LEXIS SA. (2016). *REFORMA SISTEMA NACIONAL DE PLANIFICACION SNP, Decreto Ejecutivo 878, Registro Oficial 268, 08/02/2008*. Lexis S.A. <https://www.planificacion.gob.ec/wp-content/uploads/downloads/2016/02/Decreto-Ejecutivo-357-2010.pdf>

Li, W., & Zhang, J. (2020). Prediction of BOD concentration in wastewater treatment process using a modular neural network in combination with the weather condition. *Applied Sciences (Switzerland)*, 10(21), 1–14. <https://doi.org/10.3390/app10217477>

López, V., & Crespi, M. (2015). *Gestion de los Efluentes de la Industria textil*. Instituto Nacional de Tecnología Industrial. [https://upcommons.upc.edu/bitstream/handle/2117/87574/Gestión efluentes textiles Num18.pdf](https://upcommons.upc.edu/bitstream/handle/2117/87574/Gestión%20efluentes%20textiles%20Num18.pdf)

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>

MAGIQUO DATA LIVE. (2019, November 1). *Redes neuronales o el arte de imitar el cerebro humano - magiquo creamos inteligencia*. <https://magiquo.com/redes-neuronales-o-el-arte-de-imitar-el-cerebro-humano/>

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>

Matich, D. (2017). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. In *Historia*. <ftp://decsai.ugr.es/pub/usuarios/castro/Material-Redes-Neuronales/Libros/matich-redesneuronales.pdf>

- Matlab. (2021). *MATLAB Online - MATLAB & Simulink*.
<https://es.mathworks.com/products/matlab-online.html>
- 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
- Minsky, M., & Papert, S. A. (2017). *Perceptrons, Reissue of the 1988 Expanded Edition with a new foreword* (L. Bottou (ed.)).
https://books.google.com.ec/books?hl=en&lr=&id=PLQ5DwAAQBAJ&oi=fnd&pg=PR5&dq=Perceptrons:+An+Introduction+to+Computational+Geometry&ots=zzGyzDtnYX&sig=psf3RDOC1gjHUmEgrzGsveZyN8&redir_esc=y#v=onepage&q=Perceptrons%3A+An+Introduction+to+Computational+Geom
- Morera, A. (2017). *Introducción a los modelos de redes neuronales artificiales El Perceptrón simple y multicapa*. <https://zagan.unizar.es/record/69205/files/TAZ-TFG-2018-148.pdf>
- Niinimäki, K., Peters, G., Dahlbo, H., Perry, P., Rissanen, T., & Gwilt, A. (2020). *The environmental price of fast fashion*. *Nature Reviews Earth and Environment*; Springer US. <https://doi.org/10.1038/s43017-020-0039-9>
- 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).

- Organización de las Naciones Unidas. (2018, June 28). *Putting the brakes on fast fashion*.
<https://www.unep.org/news-and-stories/story/putting-brakes-fast-fashion>
- Organización de las Naciones Unidas. (2019, April 12). *El costo ambiental de estar a la moda | Noticias ONU*. El Costo Ambiental de Estar a La Moda.
<https://news.un.org/es/story/2019/04/1454161>
- Pascal, Á. (2019). *Predicción del comportamiento de la dbo 5 , dgo, 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>
- Peces, L. (2020). *La industria textil es la segunda más contaminante después de la petrolera*. <https://www.vidasostenible.org/la-industria-textil-es-la-segunda-mas-contaminante-despues-de-la-petrolera/#8230>
- Pino, R., Gómez, A., & De Abajo, N. (2001). *Introducción a la inteligencia artificial: sistemas expertos, redes neuronales artificiales y computación evolutiva*.
<https://books.google.es/books?hl=es&lr=&id=RKqLMCw3IUkC&oi=fnd&pg=PA10&dq=redes+neuronales+artificiales+&ots=iHHzj5v37R&sig=IVYfnWTMwKSQxrOEfdA45IohxTo#v=onepage&q=redes neuronales artificiales&f=false>
- Piontek, F. M., & Müller, M. (2018). Literature Reviews: Life Cycle Assessment in the Context of Product-Service Systems and the Textile Industry. *Procedia CIRP*, 69, 758–763. <https://doi.org/10.1016/j.procir.2017.11.131>
- Ponce, P. (2011). Inteligencia Artificial con aplicaciones a la ingeniería. In *Alfaomega, México*. <http://www.alfaomega.com.mx>
- Prado, K., Rosa, J., Alves, W., Pereira, F., Santana, J., & Tambourgi, E. (2013). Applying of a Neural Network in Effluent Treatment Simulation as an Environmental Solution for Textile Industry. *Elsevier*, 32. <https://doi.org/10.3303/CET1332013>
- Prieto, A., Atencia, M., & Sandoval, F. (2013). Advances in artificial neural networks and

- machine learning. *Neurocomputing*, 121, 1–4.
<https://doi.org/10.1016/J.NEUCOM.2013.01.008>
- 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>
- Ramos, M. D. N., Lima, J. P. P., de Aquino, S. F., & Aguiar, A. (2021). A critical analysis of the alternative treatments applied to effluents from Brazilian textile industries. *Journal of Water Process Engineering*, 43(August).
<https://doi.org/10.1016/j.jwpe.2021.102273>
- 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
- Rosenblatt, F. (1962). Arlington Hall Station. In *Zhurnal Prikladnoy Mekhaniki i Technicheskoy*.
- Roshni, R., & Kuruvila, E. C. (2017). *Bod Modelling Using Artificial Neural Network*. 4, 32–41.
- 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>
- SENPLADES. (2019). *Agendas Zonales. Zona 3-Centro*. Secretaria Nacional de Planificación y Desarrollo. <https://www.planificacion.gob.ec/wp-content/uploads/downloads/2019/06/Agenda-Coordinación-Zonal-Z3-2017-2021.pdf>
- Serrano, A., Soria, E., & Martín, J. (2010). *REDES NEURONALES ARTIFICIALES*. http://ocw.uv.es/ingenieria-y-arquitectura/1-2/libro_ocw_libro_de_redes.pdf
- Sheela, K. G., & Deepa, S. N. (2014). Selection of number of hidden neurons in neural networks in renewable energy systems. *Journal of Scientific and Industrial Research*, 73(10), 686–688.
- 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
- 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>
- Tanzifi, M., Hosseini, S., Dehghani, A., Olazar, M., Karimipour, K., Rezaiemehr, R., & Ali, I. (2017). Artificial neural network optimization for methyl orange adsorption onto polyaniline nano-adsorbent: Kinetic, isotherm and thermodynamic studies. *Journal of Molecular Liquids*, 244, 189–200. <https://doi.org/10.1016/J.MOLLIQ.2017.08.122>
- Torres, A., & Naveiro, R. (2019, June 4). *Redes neuronales*. <http://albertotb.com/curso-ml-R/Rmd/12-nn/12-nn.html#1>
- 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>
- Valdivieso, C. (2019). *OPTIMIZACIÓN DE BIOPOLÍMEROS EN EL PROCESO DE COAGULACIÓN - FLOCULACIÓN PARA EL TRATAMIENTO DE LIXIVIADOS EN LA CIUDAD DE CUENCA MEDIANTE EL USO DE REDES NEURONALES ARTIFICIALES* [Universidad Católica de Cuenca]. [https://dspace.ucacue.edu.ec/bitstream/ucacue/8200/1/VALDIVIESO VALVERDE CARLOS ANDRES.pdf](https://dspace.ucacue.edu.ec/bitstream/ucacue/8200/1/VALDIVIESO%20VALVERDE%20CARLOS%20ANDRES.pdf)
- Vališ, D., Hasilová, K., Forbelská, M., & Vintro, 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)
- Villada, F., Muñoz, N., & García-Quintero, E. (2016). Redes Neuronales Artificiales aplicadas a la Predicción del Precio del Oro. *Información Tecnológica*, *27*(5), 143–150. <https://doi.org/10.4067/S0718-07642016000500016>
- WWAP-Programa Mundial de Evaluación de los Recursos Hídricos de las Naciones Unidas. (2017). *AGUAS RESIDUALES*. www.unesco.org/open-access/terms-use-ccbysa-en
- Zavala, L., Vázquez, J., Gutiérrez, P., & Tapia, M. (2018). Generación de la formulación de color en un producto textil mediante redes neuronales artificiales. *Nova Scientia*, *10*(21), 78–96. <https://doi.org/10.21640/NS.V10I21.1507>
- Zilouchian, A. (2001). Fundamentals of Neural Networks. In *Intelligent Control Systems Using Soft Computing Methodologies*. <https://doi.org/10.1201/9781420058147.ch2>

ANEXOS

ANEXO 1

Tabla 7. Límites de descarga al sistema de alcantarillado público

Parámetros	Expresado como	Unidad	Límite máximo permisible
Aceites y grasas	Sustancias solubles en hexano	Mg/l	100
Compuestos fenólicos	Expresado como fenol	Mg/l	0,2
Demanda Bioquímica de Oxígeno (5 días)	D.B. O ₅	Mg/l	250
Demanda Química de Oxígeno	D.Q. O	Mg/l	500
Nitrógeno Total Kjedahl	N	Mg/l	40
Potencial de hidrógeno	pH		5-9
Sólidos Sedimentales		Mg/l	20
Sólidos suspendidos totales		Mg/l	220
Sólidos totales		Mg/l	1600
Sulfatos	SO ₄	Mg/l	400
Sulfuros	S	Mg/l	1,0
Fósforo total	P	Mg/l	15
Tensioactivos	Sustancias activas de azul de metileno	Mg/l	2,0

Fuente: Tabla N° 11 - Anexo 1 del A.M 097-A Expide los Anexos del Texto Unificado de Legislación Secundaria del Ministerio del Ambiente.

ANEXO 2

Figura 18

Matriz de datos reales de 30 empresas de Jeans.

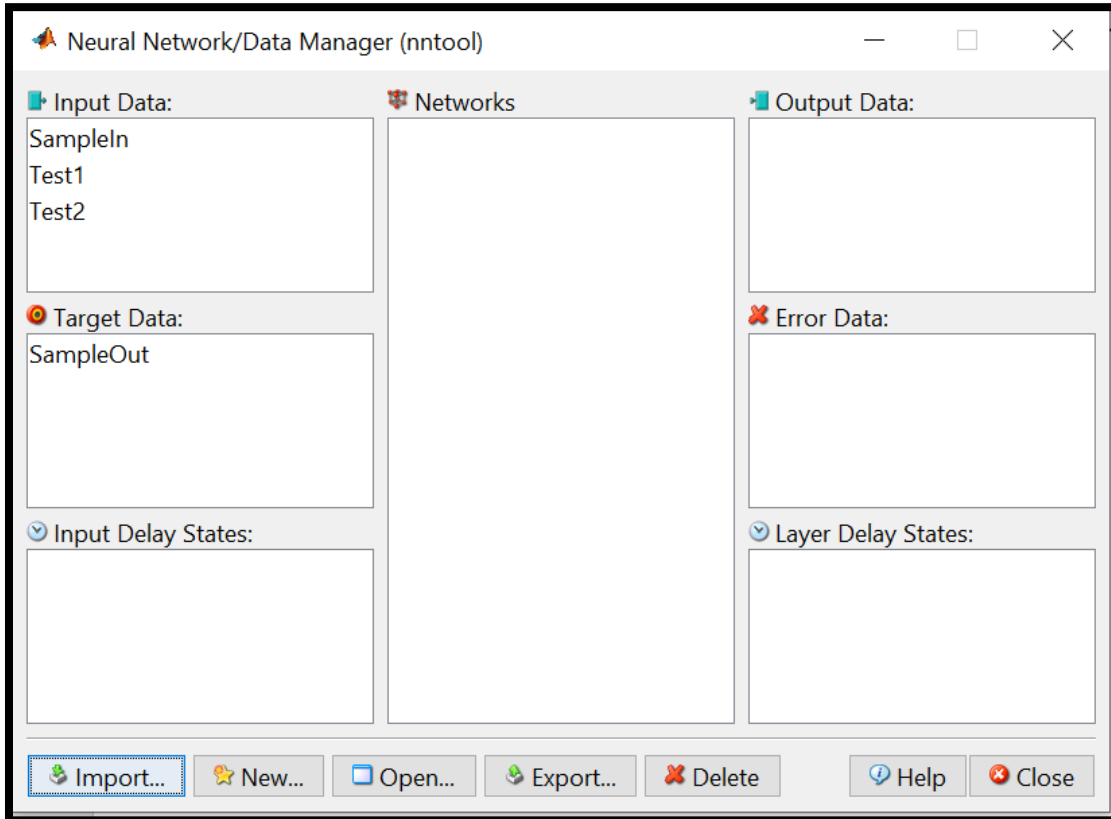
EMPRESAS INDUSTRIALES DE JEANS																																
		AÑO 2017															AÑO 2018															
		Empresa 1	Empresa 2	Empresa 3	Empresa 4	Empresa 5	Empresa 6	Empresa 7	Empresa 8	Empresa 9	Empresa 10	Empresa 11	Empresa 12	Empresa 13	Empresa 14	Empresa 15	Empresa 16	Empresa 17	Empresa 18	Empresa 19	Empresa 20	Empresa 21	Empresa 22	Empresa 23	Empresa 24	Empresa 25	Empresa 26	Empresa 27	Empresa 28	Empresa 29	Empresa 30	
FÍSICOS	A	Temperatura °C	15	16	14,2	14	15	16	14	15,5	16	14	16	16	15	15,6	14,1	16	15	15,4	16	14,2	14	15,3	16	15	15,5	14,1	14,6	15	15	16
	B	Humedad relativa %	86	82	86	81	85	81	81	81	82	81	82	81	85	81	86	82	86	83	82	86	81	81	81	85	81	86	82	86	82	82
	C	Presión atmosférica (Pascal)	103,1	103	103,1	103,2	103	103,1	103,2	103,2	103	103,2	103	103	103	103,2	103,2	103	103,1	103	103	103,1	103,2	103,1	103	103	103,2	103,2	103,2	103,1	103,1	103
	D	Sólidos Totales	1352	1420	1812	1562	1718	1487	1562	1631	1890	1562	1420	1406	1718	1278	1217	1890	1352	1338	1420	1812	1562	1546	1406	1718	1631	1217	1472	1352	1468	1420
	F	Sólidos sedimentales	0,2	1,5	2,5	2,5	0,2	1,7	2,5	2,9	0,3	2,5	1,5	0,2	2,9	1,3	0,2	0,3	0,2	0,3	1,5	2,5	2,5	2,4	0,23	2,1	2,9	0,2	0,3	0,2	2,5	1,5
	G	Sólidos Suspendidos	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50	50
QUÍMICOS	H	Potencial de Hidrógeno	7,04	7,29	8,19	7,56	7,94	7,39	7,65	7,78	8,33	7,56	7,29	7,18	8,04	6,98	6,69	8,33	7,04	7,02	7,29	8,19	7,56	7,64	8,10	7,94	7,78	6,69	7,37	7,04	7,39	7,29
	I	Sulfuros	0,13	0,19	0,13	0,33	0,35	0,14	0,20	0,12	0,36	0,33	0,19	0,31	0,21	0,18	0,12	0,36	0,13	0,13	0,19	0,13	0,33	0,20	0,15	0,35	0,12	0,12	0,14	0,13	0,12	0,19
	J	sulfatos	110	120	110	200	210	116	126	104,50	221	200	120	190	132	114	105	221	110	110	120	110	200	126	127	210	105	105	115	110	110	120
	K	Nitrógeno Total	8,51	9,26	8,91	9,36	9,83	8,94	9,72	8,46	10,32	9,36	9,26	8,89	10,21	8,80	8,08	10,32	8,51	8,49	9,26	8,91	9,36	9,70	9,79	9,83	8,46	8,08	8,91	8,51	8,04	9,26
	L	DQO	131	165	110	179	188	138	173	105	197	179	165	170	182	157	124	197	131	131	165	110	179	173	151	188	105	124	137	131	110	165
	M	Fenoles	0,022	0,026	0,022	0,028	0,029	0,023	0,027	0,021	0,028	0,028	0,026	0,027	0,029	0,025	0,021	0,028	0,022	0,022	0,026	0,022	0,028	0,027	0,025	0,029	0,021	0,021	0,023	0,022	0,020	0,026
	N	Tensioactivos	0,120	0,110	0,070	0,110	0,116	0,126	0,116	0,067	0,121	0,110	0,110	0,105	0,121	0,105	0,114	0,121	0,120	0,120	0,110	0,070	0,110	0,115	0,138	0,116	0,067	0,114	0,126	0,120	0,063	0,110
	Ñ	Fosforo total	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7	1,7
	O	Aceites y Grasas	2,2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2,2	2	2	2	2	2	2	2	2	2	2	2	2	2
Salida	DBO5	65	70	249	77	85	72	77	224	93	77	70	69	246	63	59	93	65	64	70	249	77	76	69	85	224	59	71	65	202	70	
	Matriz de salidas de la red	60,83640824	74,2445734	244,652105	75,889326	76,169937	76,5162385	101,147506	213,1177957	91,915691	75,889326	74,2445734	60,3671258	206,199785	62,3276189	63,1934073	91,9156914	60,8364082	64,1234513	74,2445734	244,652105	75,889326	100,158487	74,8827114	127,355735	213,786331	63,1051632	64,9394488	60,8364082	197,674089	74,2445734	
	Matriz de errores de la red	4,163591755	-4,24457345	4,34789455	1,11067397	8,83040626	-4,51623847	-24,1475062	10,88220429	1,0843086	1,11067397	-4,24457345	8,6328742	39,8002147	0,67238107	-4,19340731	1,08430863	4,16359176	-0,1234513	-4,24457345	4,34789455	1,11067397	-24,1584868	-5,88271138	-42,355735	10,2136686	-4,1051632	6,06055118	4,16359176	4,32591064	-4,24457345	

Nota: Los datos de las 30 empresas de Jeans son obtenidos mediante investigación bibliográfica de la catástrofe del GAD de Pelileo de los años 2017-2018 juntamente con el aporte de algunos datos tomados del Laboratorio de análisis de aguas acreditado.

ANEXO 3

Figura 19

Importación de la matriz de datos a Matlab



Nota: Screenshot de la ventana del Software Matlab donde es importada la matriz de datos en Excel. **Fuente:** Elaboración propia.

ANEXO 4

Figura 20

Propiedades de la Red Neuronal

The screenshot shows the 'Create Network or Data' dialog box with the 'Data' tab selected. The 'Name' field contains 'RNNDBO5'. Under 'Network Properties', the 'Network Type' is 'Feed-forward backprop'. The 'Input data' is 'SampleIn', 'Target data' is 'SampleOut', 'Training function' is 'TRAINLM', 'Adaption learning function' is 'LEARNGDM', and 'Performance function' is 'MSE'. The 'Number of layers' is set to 2. For 'Layer 1', the 'Number of neurons' is 10 and the 'Transfer Function' is 'PURELIN'. At the bottom, there are buttons for 'View', 'Restore Defaults', 'Help', 'Create', and 'Close'.

Nota: Se detalla el nombre y propiedades de la red neuronal utilizada para la estimación de la Demanda Bioquímica de Oxígeno. **Fuente:** Elaboración propia.

ANEXO 5

Figura 21


Programación para obtención de las gráficas

```
>> plot(Linea, SampleOut, '--gs', ...  
      'LineWidth', 2, ...  
      'MarkerSize', 10, ...  
      'MarkerEdgeColor', 'b', ...  
      'MarkerFaceColor', [0.5, 0.5, 0.5])  
>>  
>> hold on  
>> plot(Linea, RNDB05_outputs, '--gs', ...  
      'LineWidth', 2, ...  
      'MarkerSize', 10, ...  
      'MarkerEdgeColor', 'b', ...  
      'MarkerFaceColor', [0.5, 0.5, 0.5])
```

Nota: Se realiza un screenshot de la ventana de programación de Matlab donde se detalle el código para la obtención de las gráficas. **Fuente:** Elaboración propia.

Figura 22

Programa estadístico InfoStat



Nota: Screenshot de la ventana del programa estadístico InfoStat para análisis de los valores estimados por la red neuronal vs los valores reales. **Fuente:** Elaboración propia.

