




ARTÍCULO ORIGINAL

Redes neuronales artificiales para el tratamiento de efluentes de curtiduría

Artificial neural networks for the treatment of tanneries effluents

Manuel Omar García La Barrera^{1a}, Brander Jean Carlos Vega Gonzales^{1b}, Juan Carlos Mariños Legendre ^{2c*}, Bertha Beatriz Anhuaman Namoc^{2d}, Maricielo Campos Gutiérrez ^{2e} y Miguel Elías Pinglo Bazán ^{2f}

¹ Inter-Company S.R.L., Trujillo, Perú

² Instituto Tecnológico de la Producción, Trujillo, Perú

^a mgarlab@hotmail.com, ^b brandervega.1992@gmail.com, ^c jmarinos@itp.gob.pe, ^d banhuaman@itp.gob.pe,

^e mcampos@itp.gob.pe, ^f mpinglo@itp.gob.pe

* Autor de correspondencia

Resumen

Uno de los principales problemas que inquieta a las empresas dedicadas al curtido y adobo de cueros radica en las altas concentraciones contaminantes del efluente que liberan a la red de alcantarillado, los cuales sobrepasan los valores máximos admisibles (VMA) establecidos en el DS 010-2019-VIVIENDA. En línea con esta realidad, se presenta una alternativa para reducir la carga contaminante de Demanda Bioquímica de Oxígeno (DBO₅), Demanda Química de Oxígeno (DQO) y Sólidos Suspendidos Totales (SST) presentes en las aguas de curtiduría a través del uso de un sistema de tratamiento de efluentes que es controlado por una red neuronal artificial que permite determinar de forma automática las dosificaciones de insumos para el tratamiento de efluentes en curtiembres y dependiendo de la combinación de efluentes de los procesos de curtiduría se dosifican los insumos químicos. La metodología empleada consta de remoción de carga orgánica sedimentable a través de una trampa de grasa y poza de sedimentación, oxidación de sulfuro materia orgánica, regulación de pH, coagulación y floculación de

acuerdo con la dosificación indicada en la red neuronal artificial. Con una muestra de 5 m³/día, se logró reducir 70% los parámetros, obteniendo una concentración de DBO₅, DQO y SST en torno a los 211.3 O₂ mg/L, 790 mg/L y 109.7 mg/L respectivamente; en tanto se obtuvo 0.007 mg/L de cromo hexavalente, 0.005 mg/L de cianuro total, 1.9 mg/L de sólidos sedimentables, 6.5 mg/L de aceites y grasas y 740.9 mg/L de sulfatos; todo bajo el sistema de tratamiento validado a diferencia de las metodologías convencionales que solo tratan los efluentes por cada proceso por separado.

Palabras claves: red neuronal artificial, tratamiento de efluentes, sistema piloto, demanda bioquímica de oxígeno, demanda química de oxígeno, sólidos suspendidos totales

Abstract

One of the main problems that concerns companies dedicated to leather tanning and dressing lies in the high contaminant concentrations of the effluent that they release into the sewage network, which exceed the maximum admissible values (VMA) established in DS 010-2019 -VIVIENDA. In line with this reality, an alternative is presented to reduce the contaminant load of Biochemical Oxygen Demand (BOD₅), Chemical Oxygen Demand (COD) and Total Suspended Solids (TSS) present in tannery waters through the use of an effluent treatment system that is controlled by an artificial neural network that automatically determines the dosing of inputs for the treatment of effluents in tanneries and depending on the combination of effluents from the tannery processes, the chemical inputs are dosed. The methodology used consists of removal of sedimentable organic load through a grease trap and sedimentation pond, oxidation of sulfur organic matter, pH regulation, coagulation and flocculation according to the dosage indicated in the neural network and an aeration system. With a sample of 5 m³ / day, it was possible to reduce the parameters by 70%, obtaining a concentration of BOD₅, COD and TSS around 211.3 O₂ mg / L, 790 mg / L and 109.7 mg / L respectively; meanwhile, 0.007 mg / L of hexavalent chromium, 0.005 mg / L of total cyanide, 1.9 mg / L of settleable solids, 6.5 mg / L of oils and fats and 740.9 mg / L of sulfates were obtained; all under the validated treatment system unlike conventional methodologies that only treat the effluents for each process separately.

Keywords: artificial neruonal network, effluent treatment, pilot system, biochemical oxygen demand, chemical oxygen demand, total suspended solids

Introducción

Al cierre del año 2020 la industria del cuero a nivel regional congregó a un promedio de 118 empresas activas según la Superintendencia Nacional de Aduanas y de Administración Tributaria, obteniendo un total de 550 empresas a nivel nacional. El problema identificado que limita la competitividad de las empresas dedicadas al curtido y adobo de cueros radica en la calidad del efluente que liberan a la red de alcantarillado por las altas concentraciones de contaminantes que posee, los cuales sobrepasan los VMA establecidos en el DS 010-2019-VIVIENDA, propiciando así el inicio de procesos sancionadores y multas con las autoridades fiscalizadoras de OEFA y SEDALIB.

En la actualidad la técnica habitual se basa en realizar tratamiento por separado para los efluentes de pelambre y curtido, iniciando con un tratamiento de retención de sólidos en combinación con la floculación y coagulación, utilizando 80 mg/l de sulfato de Aluminio y 4 mg/l de coagulante aniónicos; y sedimentación secundaria para remover los flóculos formados; usados para el tratamiento del efluente de pelambre. Para el curtido, una etapa de sedimentación primaria y antes de ser reciclado requiere de un acondicionamiento previo por la concentración de cromo y la acidez. Los desechos sólidos generados a partir del tratamiento primario del efluente de curtido, deben ser dispuestos en un relleno de seguridad, debido a su contenido de cromo.

Se puede utilizar la coagulación y la floculación seguidas de un tratamiento biológico para tratar las aguas residuales de la curtiembre. El potasio de alumbre se usó para la coagulación y el Drewfloc 270 se usó para la floculación. Se concluyó que este método de tratamiento es exitoso en la reducción de la concentración de contaminantes de efluente de curtiembres para alcanzar los estándares nacionales de calidad ambiental (NEQS). (Shahid, M. et al 2017).

En tal sentido, las RNA, pueden ser consideradas como un método de resolver problemas, de forma individual o combinada con otros métodos para tareas de clasificación, identificación, diagnóstico, optimización o predicción en las que el balance datos/conocimiento se inclina hacia los datos y donde, adicionalmente, puede existir la necesidad de aprendizaje en tiempo de ejecución y de cierta tolerancia a fallos. En estos casos las RNA se adaptan dinámicamente reajustando constantemente los “pesos” de sus interconexiones. Las RNA inspiran su comportamiento y/o funcionamiento en sus contrapartes biológicas. Donde, cada neurona por separado es una unidad capaz de procesar señales (impulsos) de manera individual. Sin embargo, al combinarse entre ellas formando redes de interconexiones, la capacidad de procesamiento y/o complejidad aumentan significativamente. La neurona, recibe impulsos externos, los cuales representan sus entradas. (Aguilar, L. 2019).

El desarrollo de las pruebas de tratabilidad o ensayo de jarras en muestras de aguas residuales de origen industrial, con el fin de simular el proceso de coagulación a nivel laboratorio. Esto permite identificar cual es el coagulante y dosis adecuada a emplear, para clarificar el agua y obtener una remoción de los sólidos suspendidos y en suspensión del agua cruda, quedando a punto para continuar con los otros procesos de tratamiento establecidos en la Planta de tratamiento de aguas residuales. (Fúquene, Diana; Yate, Andrea; 2018).

Estas soluciones presentan inconvenientes puesto que suponen una solución de tratamiento de efluentes de curtiduría por tipo de efluente, sin tratar la totalidad que va a descargar directo a la red de alcantarillado. Por tanto, que el sistema piloto de tratamiento de efluentes integrado con una red neuronal artificial hoy presentado ha validado su eficacia y eficiencia bajo un proceso contemplado en fases secuenciales entre las que se considera principalmente el uso de una red neuronal artificial que dosifica las cantidades específicas de floculante y coagulante de acuerdo a las características específicos de la mezcla de procesos a descargar.

Material y métodos

a. Diseño y construcción de la red neuronal

El primer paso consistió en el análisis exploratorio de los datos con el objetivo de determinar las variables de entrada y salida:

1. *ph_inicial*: Variable que mide el pH inicial en los efluentes antes del proceso de tratamiento.
2. *turbidez_inicial*: Variable que mide el nivel de turbidez inicial en los efluentes antes del proceso de tratamiento.
3. *dosificación_ácido*: Variable dependiente que determina el nivel de dosificación de ácido en el proceso con el objetivo de regular el pH inicial a niveles compatibles con la normativa ambiental.
4. *dosificación_coagulante*: Variable dependiente que determina el nivel de dosificación de coagulante en el proceso.
5. *dosificación_floculante*: Variable dependiente que determina el nivel de dosificación de floculante en el proceso.
6. *ph_final*: Variable dependiente que determina el nivel de pH final en el proceso. Esta es la variable que finalmente se monitorea con el objetivo de determinar si se está cumpliendo con la normativa ambiental.

Por medio de Python, lenguaje de programación de alto nivel que permite la implementación de prototipos de manera sencilla, asimismo, se hizo uso de la librería Tensorflow para la creación de los modelos basados en redes neuronales.

El proceso de construcción de datos se basó en las muestras que se realizaron durante las pruebas de jarras. Se recolectaron 110 muestras, cabe precisar que para realizar todos los experimentos se tomó en cuenta los valores normados (ver Tabla 1).

Tabla 1

Valores según normatividad ambiental.

Parámetro	M-1	M-2	M-3	LMP	VMA
Aceites y grasas (HEM)	45.2	411	106	50	100
Demanda Bioquímica de oxígeno (DBO5)	329	1150	246.6	500	500
Demanda Química de oxígeno (DQO)	4923	5257	1978	1500	1000
Sólidos suspendidos totales (TSS)	848	2354	1002	500	500
pH (medición en campo)	11.51	12.62	11.66	6 – 9	6 – 9
Sulfuros	62.4	20.1	27.8	4	2
Cromo Total (Cr)	2.8576	80	80	2	10

Nota: Decreto Supremo 010-2019-VIVIENDA

Con los datos filtrados se procedió a calcular correlaciones entre las variables utilizando la correlación de Pearson. Estas correlaciones brindaron las relaciones entre

las variables independientes y dependientes, y sirvieron como guía durante el proceso de construcción de los modelos. Es importante mencionar que los datos fueron previamente filtrados, ya que debido a la naturaleza de los experimentos realizados en laboratorio existían varias muestras que introducían ruido. Durante el proceso de experimentación para encontrar el valor ideal de dosificante se mantenían constantes las variables independientes (condiciones iniciales) y se modificaba la cantidad de dosificante (variable dependiente) hasta que se conseguía que el efluente se encuentre dentro de los límites ambientales. Es lógico que aquellos experimentos de dosificación que no conseguían disminuir lo suficiente la turbidez del efluente fueron descartados (Tabla 2).

Tabla 2:

Matriz de correlaciones

	Ph_init	Turbidez	Dos_acido	Dos_coag	dos_floc	Ph_final	Turb_final
Ph_init	1.00000	0.333721	0.828701	0.099304	-0.046230	0.331741	0.387737
Turbidez	0.333721	1.000000	0.521620	0.283831	-0.021355	0.314045	0.741058
Dos_Acido	0.828701	0.521620	1.000000	0.128696	-0.006529	0.248681	0.625896
Dos_coag	0.099304	0.283831	0.128696	1.000000	0.001560	0.037142	0.081020
Dos_floc	-0.046230	-0.021355	-0.006529	0.001560	1.000000	-0.187542	-0.015155
Ph_final	0.331741	0.314045	0.248681	0.037142	-0.187542	1.000000	0.184980
Turb_final	0.387737	0.741058	0.625896	0.081020	0.184980	0.184980	1.000000

Nota: Matriz de correlaciones entre las variables de acuerdo a la correlación de Pearson

Se continuó con la normalización de datos que consistió en procesar los datos de forma que al final cada variable tenga una desviación estándar igual a 1 y una media igual a 0. De esta forma se consiguió que todas las variables en la base de datos tengan la misma escala y no generan un sesgo en el modelo durante el entrenamiento (Tabla3).

Una vez normalizada, se procedió a generar el modelo especificando el algoritmo de optimización a utilizar, y la función de pérdida o error a monitorear. Para todos los experimentos se utilizó el optimizador Adam, que es la opción por defecto para cualquier tipo de configuración. Por otro lado, se utilizó la función de pérdida del tipo Error Cuadrático Medio por tratarse de un problema de regresión.

Tabla 3*Muestras del dataset normalizado.*

	Ph_init	Turbidez	Dos_acido	Dos_coag	dos_floc	Ph_final	Turb_final
0	0.319482	0.214362	0.380531	0.315309	-0.941618	0.291231	-0.599895
1	1.599546	0.156892	1.889430	-1.496284	1.068864	0.366813	0.069465
2	0.755248	1.813199	0.380531	0.088860	1.068864	0.245881	2.077999
3	-1.445373	0.062938	-1.012300	0.768207	-0.941618	-0.736688	-0.621882
4	1.599546	0.156892	2.469777	-1.496284	1.068864	-0.132030	2.761521
...
110	0.319482	0.214362	0.380531	0.994656	-0.941618	-0.011098	-0.610048

Nota: Conjunto de datos (dataset) normalizado para evitar el sesgo durante el entrenamiento

Adicionalmente a los parámetros propios del modelo, se indicaron ciertos hiper parámetros fundamentales durante el entrenamiento del modelo:

1. Tasa de Aprendizaje: Factor que modula la intensidad en la modificación de los pesos de la red. Este factor es uno de los más importantes y puede determinar la convergencia o la divergencia del modelo hacia una solución óptima.
2. Tamaño de Batch: El tamaño del batch nos indica cuantos datos está procesando el modelo al mismo tiempo. Mientras más grande sea el tamaño del batch mejores resultados obtendremos durante el entrenamiento. Sin embargo, esto debe estar balanceado con las capacidades o recursos computacionales disponibles.
3. Número de Épocas: Indica cuántas veces el algoritmo procesa todo el dataset. El procesamiento de todo el dataset una sola vez indica una época. El número de épocas normalmente se establece lo suficientemente alto para que el modelo sea capaz de aprender lo suficientemente bien el dataset de entrenamiento. Sin embargo, se debe tener cuidado en no establecerlo demasiado alto de forma que el modelo empiece a sobre entrenar, es decir no tener un buen rendimiento sobre datos que nunca ha visto.

El siguiente código muestra la configuración que se probó en cada modelo:

Figura 1

Código de configuración de la red neuronal

```
def get_model(hidden_neurons, lr, shape):

    tf.random.set_seed(42)
    inputs = Input(shape=(shape,))
    x = Dense(hidden_neurons, activation="sigmoid")(inputs)
    x = Dense(1)(x)
    model = Model(inputs=inputs, outputs=x)

    model.compile(optimizer=SGD(lr=lr), loss="MSE")

    return model
```

Nota. La imagen representa el código de configuración de la red neuronal según el lenguaje de programación Python.

En línea con el procedimiento descrito, se continuó con el entrenamiento y evaluación del modelo el cual siguió el enfoque de Kfold cross validation, en donde partimos los datos en un número determinado de particiones. En nuestro caso utilizamos 5 particiones, donde cada partición contenía alrededor de 30 y 40 muestras. El objetivo consistió en entrenar el modelo con 4 de las 5 particiones y evaluar el modelo con la partición que hemos dejado de lado. El proceso se repitió utilizando en cada iteración particiones distintas.

Finalmente, se determinó la configuración (unidades neuronales por capa), variables de entrada, variable de salida y el error de evaluación de cada uno de los modelos entrenados (Tabla 4):

Tabla 4

Resumen de los modelos entrenados

Modelo	Configuración	Variables de Entrada	Variables de Salida	Error Final
Modelo de Dosificación de Ácido	Capa Entrada: 02 Capa Oculta: 05 Capa Salida: 01	ph inicial turbidez inicial	dosificación ácido	0.13
Modelo de Dosificación de Coagulante	Capa Entrada: 02 Capa Oculta: 03 Capa Salida: 01	ph inicial turbidez inicial	dosificación coagulante	0.743

Nota: Error final de cada modelado entrenado

La columna error final indica el rendimiento de los modelos. Por ejemplo, si el modelo de ácido realiza una predicción de que la dosificación debe ser 0.5 ml, el valor ideal puede estar en el rango de 0.5 +- 0.13 ml.

Ambos modelos solo tienen una capa oculta tal como se puede observar en la columna configuración, lo único que cambia es el número de unidades neuronales. La función de activación en ambos casos para la capa oculta es una función sigmoide. Las capas de salida no tienen función de activación debido a que se trata de un problema de regresión.

b. Remoción de carga orgánica sedimentable

El agua residual es vertida a una poza, para ser posteriormente impulsada hacia la etapa de tratamiento físico químico. La poza es rectangular con un volumen de 22.0 metros cúbicos fabricado de concreto. El tanque dispone de un agitador de hélice sumergido.

c. Red neuronal artificial

La red entrenada refirió variables de entrada medidas con sensores en las pozas de almacenamiento: pH inicial y turbidez, la cual procesó generando de forma automática las dosificaciones de ácido, álcalis, floculante y coagulante.

d. Regulación de pH

El agua procedente del tanque eductor llega al tanque de ajuste de pH, donde se dosifica ácido o álcalis para regular el pH del agua a 7.5, como agente oxidante se usa el peróxido de hidrógeno (H_2O_2) al 20% y como álcalis el ácido fosfórico (H_3PO_4) al 20%. El tanque tiene un diámetro de 2.20 metros y una altura de 1.82 metros, con un volumen de 5 metros cúbicos. El tiempo de residencia es de 10 minutos. Este tanque cuenta con un agitador vertical tipo paleta.

e. Coagulación

El agua residual pasa a un tanque de coagulación, donde se dosifica el coagulante (Policloruro de aluminio al 30%) para que se produzca la coagulación. El volumen de este tanque es de 5 metros cúbicos. El tiempo de retención hidráulica es de 10 minutos. Se opta por un agitador tipo paleta en posición vertical para que produzca una mezcla rápida.

f. Floculación

Finalizada la coagulación, el agua residual pasa a dos tolvas de 3 metros cúbicos cada una, donde se dosifica un floculante orgánico de 500 ppm para que se produzca la

floculación. El tiempo de retención hidráulica en este compartimiento es de 30 minutos. Se opta por un agitador tipo paleta para que produzca una mezcla lenta y no rompa los flóculos formados. Finalmente, después de haber terminado el proceso de floculación el agua es retenida en las tolvas para se lleve a cabo la sedimentación de los flóculos formados (Figura 2).

Figura 2

Formación de flóculos



Nota. La imagen muestra el proceso de floculación en donde al finalizar el agua es retenida en las tolvas para se lleve a cabo la sedimentación de los flóculos.

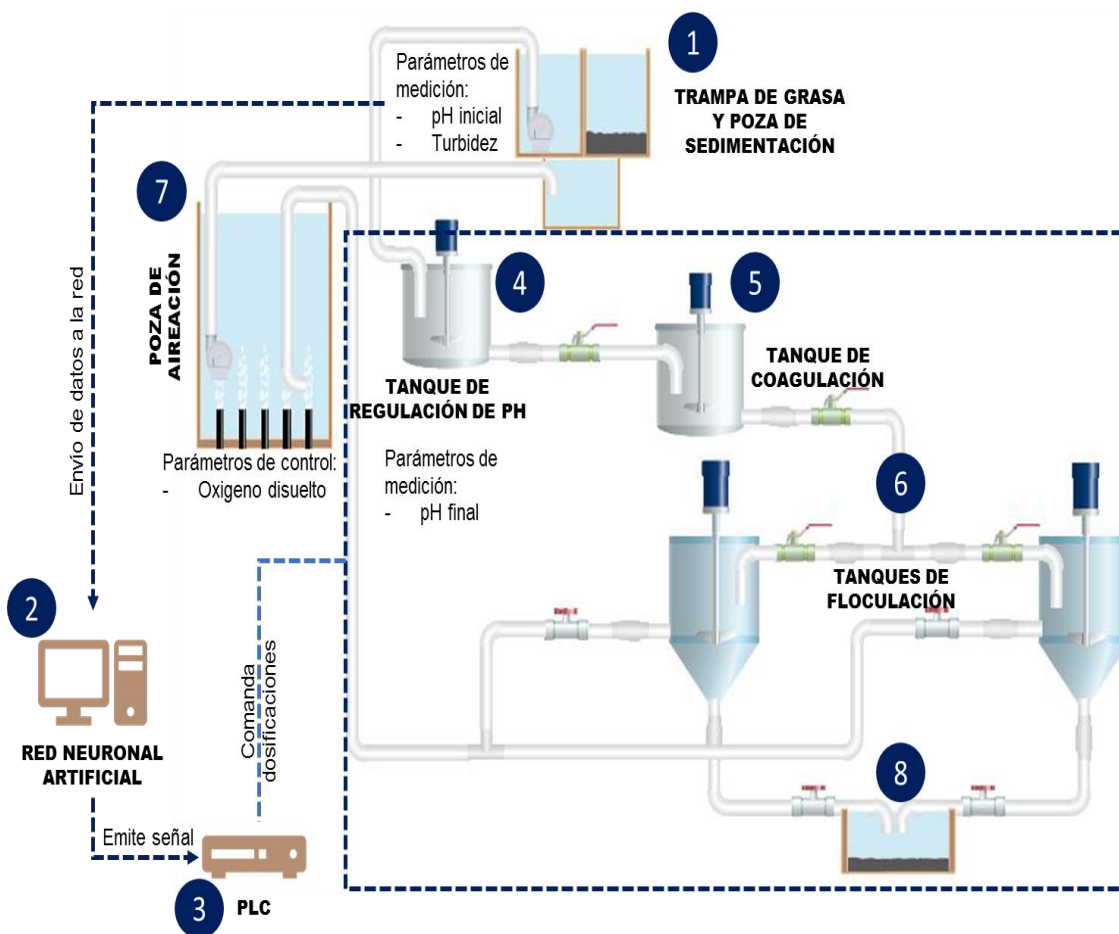
Una vez que se ha terminado el proceso se hace la primera descarga de lodos a la poza de almacenamiento.

g. Sistema de aireación

El sobrenadante de la tolva de sedimentación es recogido en la piscina de aireación para eliminar la carga orgánica que contiene el agua. El fango o lodo que se extrae por la parte inferior de las tolvas es almacenado en un recipiente metálico para su posterior disposición. Los reactivos químicos son almacenados en depósitos cilíndricos con un volumen aproximado de 100 litros para el ácido, oxidante, coagulante y floculante (Figura 3).

Figura 3:

Diseño visual del sistema de tratamiento de aguas residuales industriales con redes neuronales.



Nota. La imagen muestra el proceso gráfico del tratamiento de efluentes indicando las etapas y secuencia

Resultados

La remoción de la Demanda Bioquímica de Oxígeno (DBO_5), Demanda Química de Oxígeno (DQO) y Sólidos Suspendidos Totales (SST) ha sido excepcional al finalizar el tratamiento, demostrando que logró ser eficaz la dosificación de la red neuronal artificial y eficiente permitiendo que se recupere un aproximado del 50% al 70% de efluente tratado, el cual podría utilizarse como parte del proceso (Tabla 5 y 6).

Tabla 5*Muestras tomadas del sistema de tratamiento de efluentes*

Muestras	Descripción
M-1	Al final del proceso físico químico
M-2	La primera poza de aireación
M -3	Descarga final de la poza de aireación

Nota: Descripción de las muestras tomadas del sistema de tratamiento de efluentes

Tabla 6*Resultados obtenidos en cada muestra de efluente*

Parámetros	Unidad	M1	M2	M3	VMA
Aceites y grasas	mg/L	1.8	4.2	6.5	100
DBO	O ₂ mg/L	212.9	435.6	211.3	500
DQO	mg/L	1468	564	790	1000
Cianuro Total	mg/L	0.005	0.005	0.005	1
Cromo Hexavalente	mg/L	0.007	0.007	0.007	0.5
Solidos Suspendidos totales	mg/L	9.2	92.3	109.7	500
Solidos Sedimentables	mg/L	0.5	1.1	1.9	8.5
Sulfatos	mg/L	47.31	648.6	740.9	1000
Nitrógeno Amoniacal	mg/L	89.05	76.96	58.05	80
Sulfuros	mg/L	1.92	2.23	1.79	5
pH	unidad pH	9.27	9.29	9.3	9
T°	°C	22.2	21.6	21.1	35

Nota: Resultado analizado en laboratorio

Discusión

El tratamiento de efluentes de curtiduría con procesos físico-químicos comandado por una red neuronal artificial es un procedimiento completo que, a diferencia de las técnicas convencionales, permite tratar las aguas residuales de todos los procesos sin necesidad de implementar técnicas para cada proceso por separado.

La elección toma en consideración factores técnicos, económicos y sobre todo ambientales como: posibilidad de recirculación de agua, reducción de parámetros DBO₅, DQO y SST, entre otros.

Se usó un modelo neuronal artificial basado en redes neuronales multicapa feedforward-backpropagation, para la estimación del valor de la turbidez de salida en el tratamiento de las aguas residuales. Posteriormente, se usaron las redes neuronales entrenadas para proponer dosificaciones óptimas de los productos y mejorar las condiciones de operación, lo que permitió obtener aguas residuales clarificadas, para lo cual se elaboraron cartas de optimización. Respecto a la evaluación del desempeño del modelo neuronal, se usó como indicador de desempeño el factor de correlación lineal R. Los resultados de correlación entre los valores estimados y reales de la turbidez de salida muestran la confiabilidad en la aplicación como herramienta de predicción. (González, L. & García, J. 2020). Confirmando así que el uso de redes neuronales artificiales para la determinación de los valores de dosificaciones y para nuestro caso para la posterior aplicación en el tratamiento de efluentes de curtiembres.

El prototipo desarrollado combina un arreglo de sensores de gas de óxido de estaño con una red neuronal utilizada para identificar químicos comunes presentes en el hogar. Los resultados iniciales demuestran la capacidad para el reconocimiento de patrones del paradigma de las redes neuronales en el análisis de sensores. Al mismo tiempo, el prototipo es un compacto y portátil que facilita el análisis en tiempo real, así como la automatización del proceso de censura, análisis y reconocimiento. En cuanto a las dos redes neuronales creadas, la primera presenta una tasa de falsos positivos menor a la siguiente, aunque en ambas, dicha tasa de falsos positivos es pequeña y aceptable para el desarrollo de soluciones, sin embargo la primera, que únicamente contiene 3 neuronas en la capa oculta, presenta una tasa de falsos positivos menores y al mismo tiempo una carga de procesamiento mucho menor que la red con 10 neuronas en la capa oculta. Con este hecho resulta aceptable incorporar algoritmos de redes neuronales en sistemas portátiles. (Rubio, J.A. Hernández-Aguilar, F.J. Ávila-Camacho, J.M. Stein-Carrillo, A. Meléndez-Ramírez 2016). La precisión para las dosificaciones va a generar variaciones de acuerdo a las variables que la red neuronal artificial deba analizar y al nivel de capas que se desarrollen hasta determinar el modelo óptimo.

Se utilizó en el laboratorio el ensayo denominado Prueba de Jarras para determinar la dosis de coagulante a emplear durante un periodo de once meses, con muestreo aleatorio diario. Las variables consideradas para el estudio fueron la turbidez, el pH, la conductividad, el color y sólidos disueltos totales con una temperatura promedio de 10 °C y un caudal promedio de 148 l/s. Los cálculos obtenidos fueron utilizados para entrenar y probar dosis óptimas de coagulante haciendo uso de redes neuronales artificiales con tres topologías específicas: Red de tres capas (entrada de cinco neuronas, oculta de cinco neuronas, salida una neurona), Red de cuatro capas (entrada de cinco neuronas, dos ocultas de seis y cinco neuronas, salida una neurona) y Red de cuatro capas con dos ocultas llamada también de regresión generalizada (una de entrada con cinco neuronas, dos capas ocultas, en la primera se adiciona una neurona por cada caso entrenado y en la segunda oculta dos neuronas receptoras para regresión y una capa de salida con una neurona). Se concluyó que la topología más adecuada fue la última con una asertividad de 96.9 por ciento frente a los datos reales y en su entrenamiento se obtuvo una correlación de 98.4 por ciento evidenciando además que los factores más influentes al modelo son: color, turbidez y pH. La red seleccionada finalmente permitió predecir la dosificación de coagulante óptimo con una probabilidad de error máximo de 1.6 por ciento y en tiempo real con nuevos valores de entrada en el agua a tratar sin necesidad de recurrir a la Prueba de Jarras el cual sólo se realiza posteriormente para enriquecer su aprendizaje. (Peña, A. 2016). Para poder determinar las variables y la influencia de estas en el tratamiento de efluentes en curtiduría es importante el uso de la prueba de jarras, lo que nos indica como ir desarrollando modelos para las variables, obtener datos y entrenar la red neuronal artificial.

Se llevó a cabo la determinación de la dosis óptima de Sulfato de Aluminio ($Al_2(SO_4)_3$) utilizando modelos de correlación entre variables como las regresiones lineales y polinomiales y al mismo tiempo un modelo de Red Neuronal Artificial (RNA) que al enfrentarse a variaciones en tiempo real de la turbidez sea capaz de arrojar como resultado una dosis indicada, con el objetivo de conseguir una coagulación efectiva en el agua a tratar y de esta forma evitar la presencia excesiva o insuficiente de coagulante, minimizar la necesidad de realizar ensayos de jarras continuamente y al mismo tiempo lograr disminuir las pérdidas de carácter económico debido al gasto inadecuado del coagulante. (Barajas-Garzón, Claudia; León-Luque, Andrea 2016). Las empresas dedicadas a la curtiduría varían el tipo de piel que usan y los tipos de químicos para su curtición, por esto la importancia de poder integrar un modelo de red neuronal artificial al tratamiento de efluentes, que permita por medio de variables generar dosificaciones óptimas de forma rápida y elevar la calidad ambiental.

El proceso de coagulación y floculación es una de las operaciones más importantes dentro del proceso de potabilización del agua, pero su efectividad se ve

afectada debido al cálculo de la dosificación de coagulante que se realiza mediante las pruebas Jar o el uso del Detector de Corriente de Flujo (SCD), teniendo como principal inconveniente que no tiene en cuenta el cambio de los parámetros fisicoquímicos del agua en tiempo real y además la necesidad de obtener un punto óptimo de funcionamiento del equipo. En este trabajo la dosificación óptima de Sulfato de Aluminio ($\text{Al}_2(\text{SO}_4)_3 \cdot 18\text{H}_2\text{O}$) se determina mediante un modelo de Red Neuronal Artificial (RNA) que, ante variaciones de turbidez en tiempo real, es capaz de calcular una dosis indicada de coagulante, con el fin de conseguir una coagulación eficaz en el agua del ensayo y evitar un exceso o insuficiencia. presencia de coagulante, minimizar la necesidad de hacer probar los frascos continuamente y reducir las pérdidas económicas por gasto inadecuado de coagulante. La RNA creada es capaz de calcular la dosificación en función del valor de turbidez inicial del fluido a tratar con un MSE 0 mg/L, consiguiendo porcentajes de eliminación superiores al 93% en la mayoría de los casos. (León-Duque, A. J.; Barajas, C. L.; Peña-Guzmán, C. A.; 2016). Confirmando que el uso óptimo de variables por medio de las redes neuronales artificiales genera dosificaciones óptimas que permiten dentro de las empresas de curtiduría poder llevar a cabo labores más rápidas de control ambiental y cumplir con lo estipulado en la norma.

La alternativa de determinar las dosificaciones de coagulante por medio de un modelo de red neuronal artificial entrenada y validada ha demostrado su eficacia pues permitirá implementar un sistema de control automático que puede ser utilizado en el tratamiento de agua potable, el cual será capaz de predecir y aplicar una dosis óptima de coagulante de acuerdo con el nivel de turbidez inicial que presente el agua a tratar. La elección del proyecto por apostar por el uso de una red neuronal artificial para determinar las dosificaciones no solo de coagulante, sino de ácido, álcalis y floculante a partir del pH y turbidez radica en la repercusión que tienen estos en cuanto a los parámetros de estudio para la mezcla de procesos de curtiduría y evidencia en la reducción de los parámetros de evaluación según el DS 010-2019-VIVIENDA.

Nuestro estudio evidencia en torno al uso del proceso físico-químico una reducción de 70% en los parámetros, obteniendo una concentración de DBO5, DQO y SST en torno a los 211.3 O_2 mg/L, 790 mg/L y 109.7 mg/L respectivamente.

La investigación internacional y los resultados de nuestra propuesta logran finalmente comprobar la disminución de la carga orgánica DBO5, DQO y SST; asimismo, se corrobora la reducción de la materia orgánica percibida como DBO5 y materia inorgánica como DQO, logrando reducir, a su vez la presencia de cromo hexavalente, cianuro total, aceites y grasas, sólidos sedimentables y sulfatos.

Conclusiones

Debido al tratamiento del agua residual generada de 5 m³/día, se logró reducir 70% los parámetros, obteniendo una concentración de DBO₅, DQO y SST en torno a los 211.3 O₂ mg/L, 790 mg/L y 109.7 mg/L respectivamente; en tanto se obtuvo 0.007 mg/L de cromo hexavalente, 0.005 mg/L de cianuro total, 1.9 mg/L de sólidos sedimentables, 6.5 mg/L de aceites y grasas y 740.9 mg/L de sulfatos; todo ello bajo el sistema de tratamiento validado a diferencia de las metodologías convencionales que solo tratan los efluentes por cada proceso por separado, optimizando en un 70 por ciento el proceso y permitiendo así el cumplimiento de los valores máximos admisibles del DS 010-2019-VIVIENDA.

Agradecimientos

Un especial agradecimiento al Programa Nacional de Desarrollo Tecnológico e Innovación - Proinnóvate por el cofinanciamiento para el desarrollo de la presente investigación y por su apoyo en el fomento de la innovación, que permita al país fortalecer sus capacidades tecnológicas y de innovación para de esta manera contribuir al crecimiento de la competitividad y productividad con fondos para la generación de proyectos innovadores realizando el acompañando técnico y de monitoreo oportuno que finalmente permita lograr un impacto positivo en el desarrollo productivo y el fortalecimiento de las empresas de todos los sectores y niveles, emprendedores innovadores, entidades de soporte al emprendimiento, asociaciones de productores y gremios empresariales, además de entidades del sector público y entidades académicas.

Contribución de autoría

Manuel Omar García La Barrera, Brander Jean Carlos Vega Gonzales, Juan Carlos Mariños Legendre, Bertha Beatriz Anhuaman Namoc y Maricielo Campos Gutiérrez concibieron la idea, diseñaron el estudio, recogieron los de datos y realizaron el análisis e interpretación de datos. Maricielo Campos Gutiérrez realizó la búsqueda bibliográfica, revisó el borrador y elaboró el primer borrador. Juan Carlos Mariños Legendre revisó el primer borrador del manuscrito y elaboró la versión final. Miguel Elías Pinglo Bazán revisión crítica de su contenido y aprobación final de la versión que va a publicarse.

Conflictos de interés

<https://doi.org/10.54353/ritp.v2i2.e002>

Ninguno.

Referencias

- Aguilar, L. (2019). *Análisis comparativo en la implementación de la red neuronal backpropagation usando el método de componentes principales y el método clásico*. [Tesis de Doctorado, Universidad Nacional de Piura, Perú]. <https://repositorio.unp.edu.pe/handle/UNP/1583>
- Barajas-Garzón, Claudia; León-Luque, Andrea (2016). *Determinación de la dosis óptima de sulfato de aluminio ($Al_2(SO_4)_3 \cdot 18H_2O$) en el proceso de coagulación – floculación para el tratamiento de agua potable por medio del uso de una red neuronal artificial*. [Tesis de Ingeniería, Universidad Santo Tomás, Bogotá, Colombia]. <https://hdl.handle.net/11634/2916>
- Fúquene, Diana; Yate, Andrea; (2018). Ensayo de jarras para el control del proceso de coagulación en el tratamiento de aguas residuales industriales. *Working Papers ECAPMA*, (1), 1-7. <https://doi.org/10.22490/ECAPMA.2771>
- González, L. & García, J. (2020). Elaboración de un modelo neuronal artificial para la estimación de turbiedad y proposición de dosificaciones en el tratamiento de aguas residuales de la industria avícola. *Informador Técnico* 84(1) Enero - Junio 2020: 3-17. Recuperado de http://revistas.sena.edu.co/index.php/inf_tec/article/view/1636.
- J.J. Rubio, J.A. Hernández-Aguilar, F.J. Ávila-Camacho, J.M. Stein-Carrillo, A. Meléndez-Ramírez (2016) Sistema sensor para el monitoreo ambiental basado en redes Neuronales. *Ingeniería Investigación y Tecnología*, XVII (2) (abril-junio 2016), pp. 211-222. <https://bit.ly/3uYpT9K>
- León-Duque, A. J.; Barajas, C. L.; Peña-Guzmán, C. A.; (2016). Determination of the Optimal Dosage of Aluminum Sulfate in the Coagulation-Flocculation process using an Artificial Neural Network. *International Journal of Environment Science and Development*, 7(5), 346-350. <https://doi.org/10.7763/IJESD.2016.V7.797>

Peña, A. (2016). *Uso de redes neuronales artificiales para optimizar la dosificación de coagulantes en la planta de tratamiento de agua potable* – Huancayo. Repositorio Universidad Agraria de La Molina. <https://bit.ly/3uUWTPU>

Shahid, M. *et al* (2017). Coagulation Flocculation Based Biological Treatment of Tannery Industry Wastewater using Potash Alum and Drewfloc [Tratamiento biológico basado en coagulación y floculación de aguas residuales de la industria de curtidos utilizando potasio, aluminio y Drewfloc]. European Journal of Advances in Engineering and Technology, 2017,4 (1):71-75. <http://ejaet.com/coagulation-flocculation-based-biological-treatment-of-tannery-industry-wastewater-using-potash-alum-and-drewfloc/>.