

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

Elaboration of an artificial neural model for the estimation of turbidity and proposition of dosifications in the wastewater treatment

Luis Octavio González-Salcedo¹
José Benjamín García-Núñez²

¹ Universidad Nacional de Colombia (Colombia). Correo electrónico: logonzalezsa@unal.edu.co; orcid: <https://orcid.org/0000-0003-2460-6106>

² Universidad Nacional de Colombia (Colombia). Correo electrónico: jobega297011@gmail.com

Recibido: 03-08-2018 Aceptado: 02-09-2019

Cómo citar: González-Salcedo, Luis; García-Núñez, José (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), 3-17. <https://doi.org/10.23850/22565035.1636>

Resumen

El crecimiento de la industria avícola en Colombia y el cambio en la normatividad ambiental vigente, conlleva a un mejoramiento en el sistema de tratamiento de las aguas residuales, mediante técnicas alternas entre coagulantes y floculantes. Los costos de estas técnicas requieren dosificar de manera óptima los principales productos allí involucrados. En este trabajo 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.

Palabras clave: aguas residuales; turbidez; prueba de jarras; industria avícola; inteligencia artificial; redes neuronales artificiales.

Abstract

The growth of the poultry industry in Colombia, and the change in current environmental regulations, leads to an improvement in the wastewater treatment system, through alternate techniques between coagulants and flocculants. The cost of these techniques require optimal dosing of the main products involved therein. In this work, we used an artificial neural model based on feedforward-backpropagation multilayer neural networks, to estimate the value of output turbidity in the treatment of wastewater. The trained neural networks subsequently used to propose optimal dosages of the products

and improve the operating conditions that allow obtaining clarified wastewater, so we develop optimization charts. We used the R linear correlation factor as a performance indicator, for the evaluation of the performance of the neural model. The correlation results between the estimated a real values of the output turbidity show its reliability in the application as a prediction tool.

Key words: residual waters; turbidity; jar testing; poultry industry; artificial intelligence; artificial neural networks.

1. Introducción

En los últimos 50 años Colombia ha tenido un alto crecimiento en la producción avícola, reportándose un crecimiento del 7,1 % anual, pasando de aportar el 7,0 % de la producción total nacional de carnes a un valor del 50,4 % (Aguilera-Díaz, 2014), actividad que durante su proceso productivo genera contaminación con aguas residuales que contienen sustancias tanto de naturaleza orgánica como inorgánica (Gómez-Daza, 2012). El componente orgánico se refiere a materias generalmente biodegradables conducentes a la aparición y crecimiento de microorganismos con potencial patógeno (Ocampo-Vélez; Rodríguez-Montes, 2011). Por su parte, el componente inorgánico se refiere, principalmente, al uso de químicos utilizados para limpieza y desinfección de alojamientos avícolas, así como de equipos y maquinaria industrial, que deterioran la calidad física y química del agua (Padilla-Gasca; López-López; Gallardo-Valdez, 2011).

Como alternativas de tratamiento existen los primarios (físico-químicos) que acondicionan el agua residual, previo a su ingreso al tratamiento secundario (biológico). Particularmente, en Colombia, este tipo de industria utiliza tratamientos primarios debido a la disponibilidad de espacios y costos de los mismos. Además, vierten sus aguas residuales directamente a los sistemas de alcantarillado o a fuentes de agua naturales receptoras, requiriéndose entonces un mejor tratamiento de las mismas (Toc-Aguilar, 2012).

En Colombia, la legislación ambiental en esta temática es cada vez más estricta con el fin de disminuir la contaminación y carga orgánica a las fuentes naturales de agua (Aguilera-Díaz, 2014). Una de las finalidades es la de transformar las aguas residuales en aguas clarificadas. Se ha demostrado que los catalizadores orgánicos biológicos ayudan a la degradación de las grasas, permitiendo un mejor tratamiento por el procedimiento físico-químico (Rubio-Clemente; Chica; Peñuela, 2014; Chalén-Medina; Peñafiel-Pazmiño; Saltos-Sánchez, 2017). Sin embargo, sus costos de aplicación requieren de herramientas que permitan obtener dosificaciones económicas a partir de procesos de optimización.

La literatura reporta diversos trabajos de modelación en procesos de aguas residuales a partir de diferentes técnicas o herramientas, como modelos matemáticos de regresión multivariable, metodología de superficie de respuesta, uso de software y redes neuronales artificiales. En algunos casos, la modelación se ha orientado hacia el entendimiento y comprensión del proceso del tratamiento, en otros al efecto de las variables involucradas en dichos procesos sobre la calidad del tratamiento y en otras al efecto de las dosificaciones de coagulante y floculante sobre el valor de la turbiedad (Martínez-Navarro, 2007; Acuña-Zambrano, 2008; Salgado-Reyna, 2013; Salgado *et al.*, 2013; Vásquez-Almazán; Martínez-Morales, 2014; González-Martínez, 2017).

Por su parte, la inteligencia artificial, término acuñado en 1960 por Minsky (1961a, 1961b), en su sentido más amplio indica la capacidad de un artefacto para realizar los mismos tipos de funciones que caracterizan el pensamiento humano y en estos términos, sus métodos son una respuesta al deseo de aproximar el comportamiento y el pensamiento humano a diversos sistemas para la solución de determinadas problemáticas (Haugeland, 1996, 1997; Andler, 2006). Uno de estos métodos son las redes neuronales artificiales, abstracción funcional de la estructura neuronal biológica del sistema central nervioso (ver Figura 1), que recrea desde la perspectiva biológica la estructura de un cerebro humano (Bishop, 2006).




Figura 1. a) Neurona biológica b) Neurona computacional
(Adaptado de Serrano, Soria, Martín, 2010).

Las redes neuronales artificiales hoy en día son consideradas como poderosas reconocedoras y clasificadoras de patrones (Bishop, 2006), utilizadas en la solución (predicción) de problemas de ingeniería como una alternativa en sistemas complejos caracterizados por factores de interacción, en sistemas de aproximaciones estadísticas no lineales, o en sistemas de solución computacional basados en algoritmos complejos y extensos (Haykin, 2005). A su vez, involucren variables cuantitativas y cualitativas y que en estas últimas, relacionarlas en modelos matemáticos se hace difícil.

En su contexto histórico (Widrow; Lehr, 1990), las redes neuronales artificiales se iniciaron como una red monocapa denominada como Perceptrón Simple que solo podía realizar soluciones de algunas funciones lógicas como *OR*, *AND* y *NOT*, sin estimaciones numéricas; posteriormente, su desarrollo permitió estimaciones numéricas, siendo conocida como red ADALINE. Hoy en día, muchos problemas en la ingeniería son abordados a partir de redes con tres o más capas como lo es la red Perceptrón Multicapa, con un procedimiento supervisado de aprendizaje, ya que las redes se entrenan a partir del error de aproximación contra los verdaderos resultados (Bishop, 2006).

Por otro lado, en la actividad industrial y en particular en la agroindustria alimentaria (Arias-Hoyos; Hernández-Medina; Castro-Valencia; Sánchez-Peña, 2017), diferentes materiales son usados para disminuir la turbiedad del agua residual como coagulantes, floculantes y catalizadores biológicos, cuyas cantidades dependerán de situaciones ambientales como la temperatura, el pH, la cantidad y el tipo de turbiedad a tratar, entre otras. La cantidad de los productos mencionados, es determinada, generalmente, por el desempeño de un experimento conocido como Prueba de Jarras (Fúquene; Yate, 2018). Sin embargo, esta prueba experimental consume tiempo y cantidades de los productos para el tratamiento y su procedimiento también contiene errores (Ovalle-Celis; Moreno-Ripe, 2014). Lo anterior, conlleva a realizar diversas ejecuciones experimentales de la prueba hasta encontrar una turbiedad en el agua residual o condición de agua clarificada

aceptable para ser reutilizada o vertida (Fúquene; Yate, 2018) a partir de una dosificación de productos tratantes que no corresponden al óptimo, ya que se incrementan los costos del proceso, por lo cual es de interés optimizarlo.

Aun así, para Fúquene y Yate (2018) la prueba de jarras es uno de los más importantes experimentos en el control del proceso de coagulación química de aguas, en la cual se utilizan variaciones en las dosis de coagulante – floculante que determinan la reducción de coloides en suspensión y materia orgánica a través del proceso de floculación, simulando los procesos unitarios de coagulación, floculación y sedimentación, hasta llegar a los valores en los que la floculación alcanza sus mejores resultados.

Por otro lado, Haghiri; Moharramzadeh; Nahvi; Daghighi (2014) mencionan que la determinación de la dosis óptima en cuanto a coagulantes es de particular significancia, en la cual relaciones complejas entre los factores que influyen en la eficiencia del coagulante y los resultados de la prueba conllevan el problema de optimización al campo de las redes neuronales artificiales.

Al respecto, la literatura muestra un buen número de trabajos que abordan la problemática de la optimización del proceso de tratamiento de aguas usando redes neuronales artificiales (Fernández; Galvis, 2003; Acuña, 2008; Olanrewaju; Muyibi; Salawudeen; Aibinu, 2012; Salgado *et al.*, 2013; Villarreal-Campos; Caicedo-Bravo, 2013; Haghiri *et al.*, 2014; Peña-Rojas; Flóres del Pino, 2014; Prasannasangeetha, 2015; Bui; Giang-Duong; Nguyen, 2016; Barajas-Garzón; León-Luque, 2016; Peña-Rojas, 2016; Rodrigues-dos Santos; Henriques-Librantz; Días; Gozzo-Rodrigues, 2017; De Menezes; Fontes; Oliveira-Esquerre; Kalid, 2018; Haghiri; Daghighi; Moharramzadeh, 2018; Messaoud; Hellal; Imed; 2018), siendo limitado en el tratamiento de aguas residuales de procesos agroindustriales y específicamente en la industria avícola.

De este modo, en el presente estudio, se usa un modelo neuronal artificial basado en redes neuronales artificiales con arquitectura multicapa, alimentación de información hacia adelante y metodología/aprendizaje de propagación y ajuste del error hacia atrás, denominadas como Perceptrón Multicapa *feedforward – backpropagation*, para proponer dosificaciones conjuntas de un catalizador orgánico biológico y coagulantes-floculantes, elementos comercialmente disponibles en el tratamiento de las aguas residuales de la industria avícola. Las redes neuronales artificiales fueron entrenadas para predecir la turbiedad de salida del agua residual a partir de la Prueba de Jarras. El desempeño de las redes neuronales basado en el coeficiente de correlación lineal ($R > 0,98$) muestra una herramienta confiable para ser usada en la simulación de la determinación de la turbiedad de salida para diferentes dosificaciones del tratamiento. El resultado de las simulaciones graficadas en las cartas del resultado de la turbiedad de salida para diferentes condiciones de entrada del agua residual, permite definir cuáles son las dosificaciones más óptimas para obtener agua clarificada con la calidad requerida para el cumplimiento de la normatividad ambiental.

2. Procedimiento metodológico

2.1. Ubicación del proyecto

El estudio se realizó en una planta comercial, procesadora de pollo, ubicada en el municipio de Guacarí, Valle del Cauca, Colombia, la cual procesa 11000 pollos/día con un peso corporal de 1800 – 2200 g/pollo (García-Núñez, 2017).

2.2. Trabajo de campo experimental y construcción del conjunto de entrenamiento

Partiendo de un trabajo de campo experimental en donde se hizo una toma de muestras de aguas residuales denominada prueba de jarras y su correspondiente caracterización de pH, de turbiedad de entrada y de salida, se creó una base de datos para entrenar el modelo neuronal artificial (ICONTEC, 2010). Con el fin de evaluar el aporte del catalizador biológico, las muestras se dividieron en dos grupos: el primer grupo, con dosificaciones de coagulante y floculante (48 registros) y el segundo grupo, además de los dos productos mencionados, con adición de catalizador biológico (48 registros). Se utilizó como coagulante una mezcla de policloruro de aluminio como floculante un polímero ayudante de floculación y como catalizador biológico un catalizador bio-orgánico altamente concentrado, elementos comercialmente disponibles (García-Núñez, 2017). Para la estimación de la turbiedad tanto de entrada como de salida se usó un turbidímetro portátil (Hach Company, 2004).

Para ambos grupos, las variables consideradas fueron: pH de entrada [PH], turbiedad de entrada (agua cruda) [TE], dosis de coagulante [COA], dosis de floculante [FLO] y turbiedad de salida [TS]. Para el segundo grupo, se adicionó como variable la dosis de catalizador biológico [CAT]. Respecto a la base de datos, la información se almacenó en un arreglo matricial para tener en ambos grupos la variable de salida a la turbiedad de salida (agua clarificada) como se muestra en la Tabla 1.

Tabla 1.

Variables de entrada y salida consideradas en la configuración de las redes neuronales artificiales para la estimación de la turbiedad de salida en aguas residuales clarificadas

Exploración	Variables de entrada, unidad de medición, [representación]	Variable de salida, unidad de medición, [representación]
1	pH, sin unidad, [PH] Turbiedad agua cruda, NTU, [TE] Dosis coagulante, ppm, [COA] Dosis floculante, ppm, [FLO]	Turbiedad agua clarificada, NTU, [TS]
2	pH, sin unidad, [PH] Turbiedad agua cruda, NTU, [TE] Dosis coagulante, ppm, [COA] Dosis floculante, ppm, [FLO] Dosis catalizador biológico, ppm, [CAT]	Turbiedad agua clarificada, NTU, [TS]

Fuente: elaboración propia.

2.3. Elaboración y entrenamiento del modelo neuronal artificial para la estimación de la turbiedad (turbiedad de salida) en aguas clarificadas

Con los conjuntos de entrenamiento mencionados anteriormente que relacionan las variables de entrada con la variable de salida, se elaboró una propuesta de modelo neuronal para cada uno y se planteó una arquitectura neuronal artificial multicapa alimentada hacia adelante y con la metodología de entrenamiento hacia atrás (ver Figura 2), denominada Perceptrón Multicapa de *feedforward – backpropagation* y cuyas características son definidas por Rumelhart, Hinton y Williams (1986) y Hinton (1987, 1988).




Figura 2. Propuesta de modelo neuronal para la estimación de la turbidez en aguas residuales tratadas, en una planta avícola
Fuente: elaboración propia.

Las conexiones entre neuronas de las capas se representan mediante funciones de activación. Así, la conexión entre las neuronas de la capa de entrada a cada capa oculta se realiza por medio de la función sigmoidea descrita por Hinton (1987, 1988). Por su parte, la conexión entre la última capa oculta y la neurona a estimar, ubicada en la capa de salida, se hace usando la función lineal, de manera que se permita la comparación de la estimación y del resultado verdadero, como se describe en el entrenamiento supervisado (Rumelhart *et al.*, 1986; Hinton, 1987, 1988). El procedimiento de entrenamiento para cada conjunto se realizó, de acuerdo con lo descrito por García-Núñez (2017), con 156 conformaciones de topologías de redes neuronales artificiales, obtenidas del producto entre 12 métodos de entrenamiento de backpropagation y 13 arquitecturas de capas de neuronas ocultas. Dichas conformaciones se evaluaron a partir del factor de correlación lineal R (Ecuación 1) (Vásquez-Almazán; Martínez-Morales, 2014), estadístico usado para evaluar la calidad de los modelos neuronales artificiales supervisados (Steel; Torrie, 1960; Ibáñez-Quispe, 2009; Barria-Sandoval, 2009 citados por Machaca-Apaza, 2016). Para el funcionamiento computacional del procedimiento de entrenamiento se codificó un algoritmo usando el lenguaje de programación M, propio de la herramienta del software MATLAB® para la plataforma Windows®. El código usa la librería contenida en el Neural Networks Toolbox del mismo software (Beale; Hagan; Demuth, 2012) lo cual permite implementar los modelos del tipo de red que se ha descrito.

$$R = \sqrt{1 - \left(\frac{\sum_{i=1}^n (TS_{real,i} - TS_{estimado,i})^2}{\sum_{i=1}^n (TS_{real,i})^2} \right)} \quad (1)$$

Donde, $TS_{real,i}$ es la turbiedad de salida obtenida mediante la Prueba de Jarras, la turbiedad de salida estimada por la red neuronal artificial corresponde a la posición del par de datos correlacionados y corresponde al total de datos en cada subconjunto. Los 48 vectores de información de cada conjunto de entrenamiento se categorizaron en tres subconjuntos que conformaron igual número de fases en el entrenamiento de una red neuronal: 1) de aprendizaje, en donde se configuraron los pesos sinápticos en las conexiones entre neuronas; 2) de prueba, con lo cual se determinó el momento en el que debe dejar de entrenar y optimizar la estructura de la red neuronal y las especificaciones del modelo interno, de acuerdo con el método de aprendizaje que usa el algoritmo de backpropagation; y 3) de validación, en donde se probó la capacidad de generalizar el modelo para el rango de información que se utilizó para la calibración. A partir del indicador de desempeño se evaluaron las estimaciones de las redes neuronales y las salidas reales de las bases de datos, en los subconjuntos de cada fase de entrenamiento (Aprendizaje, Prueba, Validación y una adicional de Simulación con el total de los datos, para lo cual se consideraron el 60, 20, 20 y 100 % de los datos, respectivamente, y agrupados por división aleatoria de los datos).

Los resultados de este proceso mostraron que para ambos casos de estudio (sin catalizador y con catalizador), la arquitectura con dos capas ocultas y con el método de aprendizaje de Levenberg-Marquardt obtuvieron mejores, adecuados y confiables desempeños ($R > 0,99$), que los demás métodos de entrenamiento usados (Regularización Bayesiana, Cuasi-Newton de Algoritmo BFGS (Broyden-Fletcher-Goldfarb-Shanno), Retro-propagación Resiliente, Gradiente Conjugado Escalonado, Gradiente Conjugado con Reinicio de Powell/Beale, Gradiente Conjugado de Fletcher-Powell, Gradiente Conjugado de Pollak-Ribière, Secante de un Paso, Gradiente Descendiente con Tasa de Aprendizaje Variable, Gradiente Descendiente con Momento y Gradiente Descendiente).

De esta manera, la arquitectura de la mejor red neuronal se configuró entonces para el primer caso de estudio (sin catalizador biológico) con una capa de entrada con cuatro variables de entrada: una primera capa oculta con 10 neuronas, una segunda capa oculta con 30 neuronas, una capa de salida con una variable de respuesta y un algoritmo de aprendizaje backpropagation de Levenberg-Marquardt. Por otro lado en el segundo caso de estudio (con catalizador biológico), la arquitectura de la mejor red se configuró con una capa de entrada con cinco variables de entrada: una primera capa oculta con 10 neuronas, una segunda capa oculta con 20 neuronas, una capa de salida con una variable de respuesta y un algoritmo de aprendizaje backpropagation de Levenberg-Marquardt.

2.4. Simulación de la optimización

Posterior a la elaboración y entrenamiento del modelo neuronal artificial para la estimación de la turbiedad, se seleccionaron las mejores redes neuronales para cada caso de estudio, con las cuales se llevó a cabo un proceso de simulación computacional de la Prueba de Jarras, para lo cual, a través de un código computacional en lenguaje M, se usó cada red neuronal asignada a cada grupo de información y se simuló la información de entrada y de salida de la Prueba de Jarras con las siguientes características: 1) se mantuvieron constantes las condiciones de turbiedad de entrada y pH; 2) se hizo una variación de las dosis de coagulante para dosis fijas de floculante y catalizador (en el caso del segundo grupo); y 3) se obtuvo un resultado de turbiedad de salida estimado por la red neuronal entrenada para cada caso de estudio. Esta simulación permitió recrear diversas cartas de optimización de los productos adicionados (una variación de la característica 2, correspondería a variar la dosis de floculante para dosis fijas de coagulante y catalizador) en el tratamiento del agua residual de esta explotación avícola.

3. Resultados y discusión

3.1. Tratamiento de aguas residuales y caracterización en esta explotación avícola

Desde el punto de vista ambiental y sanitario para todos los ensayos realizados, se pudo observar que la utilización del catalizador biológico permitió un mejor tratamiento basado en la disminución de los valores de turbiedad de salida (agua clarificada), lo cual se infiere al mejoramiento en la degradación de la materia orgánica. Esto es mencionado por Ekama y Wentzel (2017), quienes explican que en la remoción de la materia orgánica, el proceso biológico mediante el cual dicha materia orgánica presente en este tipo de agua residual se transforma en masa de sólidos suspendidos volátiles como organismos heterotróficos ordinarios (anabolismo) con una transferencia asociada de electrones de oxígeno y una pérdida de energía en forma de calor (catabolismo), generando en el proceso completo de la degradación vía catabolismo, un rendimiento mejor.


Según lo reportado por Conde-García (2012), la disminución de la turbiedad se debe, principalmente, a que además de la degradación mencionada se solubiliza la grasa, y el coagulante y floculante pueden actuar sobre los sólidos como es inferido en el caso del tratamiento de aguas residuales provenientes del sacrificio de ganado bovino. Esto sugiere usar dosificaciones bajas del catalizador (por costos) y optimizar entonces las dosificaciones del coagulante y floculante, proceso simulado en la optimización usando el modelo neuronal artificial propuesto.

3.2. Entrenamiento del modelo neuronal artificial


A partir de la elaboración de un modelo neuronal artificial basado en redes neuronales, correspondiente a una red neuronal artificial supervisada del tipo Perceptrón Multicapa, con alimentación hacia adelante y entrenamiento/aprendizaje para la propagación del error hacia atrás, se realizó la estimación de la turbiedad de salida (aguas clarificadas) en aguas residuales provenientes de la explotación avícola, en un proceso de tratamiento de dichas aguas residuales para dos casos: con el uso de coagulante y floculante, y con el uso de tres componentes mediante la adición de catalizador biológico.

El modelo neuronal consistió para el primer grupo (sin catalizador biológico), de una red neuronal artificial conformada por una capa de entrada con cuatro variables de entrada: una primera capa oculta con 10 neuronas, una segunda capa oculta con 30 neuronas, una capa de salida con una variable de respuesta correspondiente a la estimación de la turbiedad en aguas clarificadas y algoritmo de aprendizaje de Levenberg-Marquardt. Para el segundo grupo (con catalizador biológico), el modelo consistió de una red neuronal artificial conformada por una capa de entrada con cinco variables de entrada: una primera capa oculta con 10 neuronas, una segunda capa oculta con 20 neuronas, una capa de salida con una variable de respuesta correspondiente a la estimación de la turbiedad en aguas clarificadas y algoritmo de aprendizaje de Levenberg-Marquardt.

La Figura 3 muestra los resultados de desempeño de las redes neuronales seleccionadas en ambos casos de estudio y para cada una de las etapas de entrenamiento de la misma (entrenamiento, prueba, validación computacional y simulación con todo el conjunto de entrenamiento). Para las etapas donde las redes seleccionadas estiman la turbiedad de salida, se hace una comparación entre el resultado obtenido por la red neuronal artificial (output) y el valor obtenido usando el protocolo experimental de la Prueba de Jarras (target), para lo cual se asocia a dicha comparación el factor de correlación lineal R.



a.



b.

Figura 3. Resultados de desempeño para la red neuronal artificial entrenada para estimar la turbiedad del agua clarificada: a) sin catalizador biológico y b) con catalizador biológico. Para ambos casos, se muestra el coeficiente de correlación R entre la turbiedad de salida obtenido con la Prueba de Jarras y el estimado por el modelo neuronal, para cada fase del aprendizaje (entrenamiento, prueba, validación y simulación con todos los datos)

Fuente: elaboración propia.

Este desempeño basado en el factor de correlación lineal R ($R > 0,99$), de acuerdo con Anscombe (1973) y Achen (1982), mostraron para ambos casos una relación lineal positiva fuerte entre el valor de la turbiedad de salida obtenida a partir del protocolo experimental de la Prueba de Jarras normalizado en la NTC 3903 (ICONTEC, 2010), y el obtenido mediante la predicción de las redes neuronales artificiales seleccionadas, lo cual permite inferir que la herramienta computacional es adecuada y confiable para hacer dichas estimaciones. De acuerdo con Martínez-Rodríguez (2005), los valores del coeficiente de correlación lineal R en ambos casos, muestran que hay una aproximación del resultado obtenido por predicción, lo cual verifica la bondad en el ajuste de dicha predicción, permitiéndose inferir que el modelo computacional basado en las redes neuronales artificiales puede ser usado como metodología complementaria para la Prueba de Jarras en la estimación de la turbiedad del agua residual tanto en tratamientos con coagulante-floculante y con floculante-coagulante-catalizador biológico (p.322).

La literatura reporta diversos trabajos sobre modelación en el tratamiento de aguas residuales mediante el desarrollo de modelos matemáticos, el uso de software para modelación de procesos, la metodología de superficies de respuesta y las redes neuronales artificiales. En dichos reportes se busca, en algunos casos, comprender el proceso del tratamiento, mientras que en otros, se busca relacionar los efectos de los compuestos tipo floculante y coagulante para su optimización.

Con respecto al uso de redes neuronales artificiales, Salgado-Reyna (2013) y Salgado *et al.*, (2013) elaboraron y desarrollaron redes neuronales multicapa de backpropagation para estimar los datos de unidad de osmosis inversa en el tratamiento de aguas residuales de una planta productora de envases, en un proceso de optimización del floculante y el coagulante, obteniendo en la correlación un coeficiente de determinación $R = 0,99$. Acuña-Zambrano (2008) reporta el uso de redes neuronales multicapa de backpropagation para la correlación de pH, turbiedad, color y alcalinidad, con el fin de optimizar la dosis de coagulante en una planta de tratamiento de agua potable de una población urbana, obteniendo una correlación en el caso específico de la estimación de la turbiedad y la dosis del coagulante de $R = 0,88$. Vásquez-Almazán y Martínez-Morales (2014) reportan el desarrollo de redes neuronales artificiales, de tipo multicapa backpropagation y de funciones de base radial, para la estimación de la turbiedad del efluente en una presa, obteniendo coeficientes de correlación $R = 0,9927$ y $R = 0,986$, respectivamente.

En los últimos años, se reporta en la literatura estudios sobre el uso de redes neuronales artificiales y la optimización del coagulante en el tratamiento de aguas con el objetivo de reducir, más no reemplazar, el número de ensayos en la Prueba de Jarras para la medición de la turbiedad de salida. Al respecto, Rodrigues-dos Santos *et al.*, (2017) ($R = 0,989$), Haghir *et al.*, (2018) ($R = 0,949$) y De Menezes *et al.*, (2018) ($R = 0,900$) concluyen, de manera general, que el uso de las redes neuronales artificiales es una herramienta adecuada para determinar las mejores condiciones de control del proceso del tratamiento del agua, principalmente para estimar la dosis óptima del coagulante, lo que permite una reducción de la materia prima del tratamiento y la posibilidad de realizar investigaciones adicionales para mejorar los resultados sobre reducción de costos y consumo de materia prima.

Para las redes neuronales artificiales elaboradas en el presente estudio y entrenadas para estimar la turbiedad de salida en dos casos de tratamiento de aguas residuales (sin catalizador y con catalizador), sus resultados de desempeño evaluados a partir del coeficiente de correlación lineal R , muestran que estas estimaciones son concordantes con los trabajos mencionados y desarrollados con anterioridad, con lo cual se infiere que el uso de las redes neuronales artificiales pueden ser usadas confiablemente como herramientas de predicción para complementar los resultados experimentales involucrados en el tratamiento de aguas residuales y, en particular, en la Prueba de Jarras para la estimación de la turbiedad de salida. Sin embargo, la literatura no reporta el uso de modelos neuronales artificiales en la estimación de turbiedad para el caso de aguas residuales de la explotación pecuaria así como tampoco en el uso de tres productos (coagulante, floculante y catalizador biológico) para dicho tratamiento, lo cual brinda una agenda futura en este campo, enfocados en la optimización de las dosificaciones de los productos del tratamiento propuesto.

3.3. Simulación de un proceso de optimización usando redes neuronales artificiales

Las redes neuronales artificiales seleccionadas se usaron para simular un proceso de Prueba de Jarras para diversas condiciones de entrada. Para ambos casos de estudio se realizó la simulación. A manera de ejemplo, se muestra el caso en

el cual se tiene un pH = 7,5, diferentes valores de turbiedad de entrada y diferentes dosis del coagulante, y en el segundo caso de estudio en adición a un valor constante del catalizador biológico. Este proceso de simulación permite en cada caso construir una carta de optimización como se muestra en la Figura 4. Los resultados gráficos permiten mediante el trazado de una línea horizontal que represente el valor normativo de turbiedad aceptada en el agua clarificada, definir en cada caso la dosificación del coagulante a usar. Los resultados permiten confirmar que el uso del catalizador biológico (Figura 4-b), para todos los casos en una dosis constante, conlleva a usar una menor cantidad del coagulante.




Figura 4. Ejemplo de utilización del modelo neuronal artificial para crear cartas de optimización del coagulante para un pH = 7.5: a) sin catalizador biológico; y b) con catalizador biológico. Las líneas muestran para un valor estable de pH, las diferentes condiciones de la agua residual a tratar (turbiedad del agua cruda) y mediante el uso de la red neuronal se estima la turbiedad de salida (eje vertical), de acuerdo con una dosis de coagulante (eje horizontal)
Fuente: elaboración propia.

De igual manera, la Figura 4 permite mostrar cómo en el proceso se logra un total tratamiento del agua residual (en el caso de los valores negativos que estima el modelo, y que en la realidad correspondería a “cero” turbiedad), y cómo en muchos casos el uso de valores adicionales del coagulante y/o del catalizador conllevan a “ensuciar” nuevamente el agua clarificada, lo que direccionan nuevamente un valor positivo de la turbiedad (ya en este caso el contaminante corresponde al mismo producto de tratamiento). Algunos reportes mencionan los efectos adversos en el tratamiento debido al exceso principalmente de coagulantes (Andía-Cárdenas, 2000; Castrillón-Bedoya; Giraldo, 2012; Díaz-Claros, 2014).

4. Conclusiones y recomendaciones

El trabajo permite mostrar el entrenamiento de un modelo neuronal artificial, basado en redes neuronales multicapa *feedforward-backpropagation*, para ser usado en el tratamiento de aguas residuales, en este caso para la estimación de la turbiedad del agua clarificada (turbiedad obtenida después del tratamiento del agua residual). El uso de estas redes neuronales permite en esta aplicación la reducción del número de ensayos de la Prueba de Jarras, con lo cual conlleva a un ahorro de recursos (tiempo, floculante y coagulante), enfocando la parte experimental a un número reducido de la prueba alrededor de la estimación óptima de coagulante y/o floculante. En el trabajo realizado se puede concluir que, de acuerdo con el indicador de desempeño y el comportamiento gráfico entre la relación de los valores estimados y reales, el modelo neuronal artificial entrenado y basado en este tipo de redes neuronales, son adecuadas para la realización de la estimación propuesta.

La confiabilidad de las redes neuronales artificiales entrenadas en cada caso, en los tratamientos sin catalizador y con catalizador, respectivamente, permite ser usadas para otros procesos de exploración computacional, como en este estudio, en herramienta de optimización, con lo cual se recrea la Prueba de Jarras y se realizan las cartas de optimización. De igual manera, permite confirmar la eficacia en los resultados operativos reales con la incorporación de nuevos productos (catalizador biológico) en el tratamiento de aguas residuales.

La aplicabilidad del modelo neuronal artificial en la temática del trabajo presentado, permite explorar su uso en los procesos de tratamiento de aguas residuales para diversas producciones pecuarias, es decir, ser usada en otros ámbitos, como por ejemplo, la cría de cerdos o ganado vacuno. Asimismo, se sugiere la exploración de su uso incorporando otras variables de caracterización físico-química o biológica, como en el caso de las demandas biológica y química de oxígeno, color y olor del agua cruda y tratada (estas dos últimas son variables cualitativas apropiadas para ser incluidas en modelos de inteligencia artificial), con el fin de adaptar el tratamiento a procesos más rigurosos desde el punto de vista ambiental y sanitario.

5. Referencias

- Achen, Christopher (1982). *Interpreting and Using Regression*. Series/Number 07-029. Newbury Park (CA), USA: Sage University Paper, Sage Publications.
<https://doi.org/10.4135/9781412984560>
- Acuña-Zambrano, Decsy (2008). *Modelo de correlación entre las variables medibles en línea que afectan el proceso de determinación de la dosis óptima de coagulante en la planta de tratamiento de agua potable de Bosconia, del Acueducto Metropolitano de Bucaramanga S.A. E.S.P* (tesis de pregrado) Universidad Pontificia Bolivariana, Bucaramanga, Colombia. Recuperado de <https://repository.upb.edu.co/handle/20.500.11912/214>
- Aguilera-Díaz, María (2014). *Determinantes del desarrollo de la avicultura en Colombia: Instituciones, organizaciones y tecnología*. Documentos de trabajos sobre Economía Regional, No. 214. Cartagena, Colombia: Centro de Estudios Económicos Regionales (CEER), Banco de la República.
<https://doi.org/10.32468/dtseru.214>
- Andía-Cárdenas, Yolanda (2000). *Tratamiento de agua: coagulación y floculación*. Lima, Perú: SEDAPAL.
- Andler, Daniel (2006). Phenomenology in Artificial Intelligence and Cognitive Science. En Dreyfus, H. I.; Wrathall, M. A.; (Eds.). *A Companion to phenomenology and existentialism* (Chapter 26, pp.377-393). London, UK: Blackwell Publishing.
<https://doi.org/10.1002/9780470996508.ch26>
- Anscombe, F. J. (1973). Graphs in Statistical Analysis. *The American Statistician*, 27(1), 17-21.
<https://doi.org/10.1080/00031305.1973.10478966>
- Arias-Hoyos, Arnol; Hernández-Medina, José; Castro-Valencia, Andrés; Sánchez-Peña, Nazly (2017). Tratamiento de aguas residuales de una central de sacrificio: uso del polvo de la semilla de la *m. Oleifera* como coagulante natural. *Bioteología en el Sector Agropecuario y Agroindustrial*, 15, edición especial, 29-30.
[https://doi.org/10.18684/BSAA\(15\)29-39](https://doi.org/10.18684/BSAA(15)29-39)
- 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 pregrado). Universidad Santo Tomás, Bogotá, Colombia. Recuperado de <https://hdl.handle.net/11634/2916>
- Barría-Sandoval, Paola (2010). *Pronóstico de caudales medios mensuales en las cuencas de los ríos Baker y Pascua* (tesis de pregrado). Universidad de Chile, Santiago de Chile, Chile. Recuperado de: http://repositorio.uchile.cl/tesis/uchile/2010/cf-barria_ps/pdfAmont/cf-barria_ps.pdf
- Beale, Mark; Hagan, Martin; Demuth, Howard (2012). *Neural Networks Toolbox™, user's guide*. R2012a. Natick, MA, USA: The Mathworks Inc.

- Bishop, Christopher (2006). *Pattern recognition and machine learning*. Singapore, Singapore: Springer.
- Bui, Ha;Giang-Duong, Huong;Nguyen, Cuong (2016). Applying an artificial neural network to predict coagulation capacity of reactive dyeing wastewater by chitosan. *Polish Journal of Environmental Studies*, 25(2), 545-555. <https://doi.org/10.15244/pjoes/61114>
- Castrillón-Bedoya, Daniela; Giraldo, María de los Ángeles (2012). *Determinación de las dosis óptimas del coagulante sulfato de aluminio granulado tipo B en función de la turbiedad y el color para la potabilización del agua en la planta de tratamiento de Villa Santana* (tesis de pregrado). Universidad Tecnológica de Pereira, Pereira, Colombia. Recuperado de: <http://recursosbiblioteca.utp.edu.co/tesis/textoyanexos/6281622H565.pdf>
- Chalén-Medina, Judith; Peñafiel-Pazmiño, Magaly; Saltos-Sánchez, Armando (2017). Eliminación de la materia orgánica e inorgánica presentes en el agua residual de una industria de pulpa de fruta empleando un catalizador enzimático. *Dominio de las Ciencias*, 3(3), 362-376.
- Conde-García, Érika; (2012). *Evaluación del proceso de electrocoagulación sobre aguas de lavado con contenido de lactosuero* (tesis de pregrado). Universidad del Valle, Santiago de Cali, Colombia. Recuperado de <http://bibliotecadigital.univalle.edu.co/handle/10893/9020>
- De Menezes, F. C.; Fontes, R. M.; Oliveira-Esquerre, K. P.; Kalid, R. (2018). Application of uncertainty analysis of artificial neural networks of predicting coagulant and alkalizer dosages in a water treatment process. *Brazilian Journal of Chemical Engineering*, 35(4), 1369-1381. <https://doi.org/10.1590/0104-6632.20180354s20170039>
- Díaz-Claros, José Nahum; (2014). *Coagulantes-floculantes orgánicos e inorgánicos elaborados de plantas y del reciclaje de la chatarra, para el tratamiento de aguas contaminadas* (tesis de maestría). Universidad Pedagógica Nacional Francisco Morazán, San Pedro Sula Cortés, Honduras.
- Ekama, George; Wentzel, Mark; (2017). Remoción de materia orgánica. Capítulo 4. En: López V., C.M.; Buitrón M., G.; García, H.A.; Cervantes C., F.J.; (eds., versión en español). *Tratamiento biológico de aguas residuales: principios, modelación y diseño*. (pp. 57-96). Londres, Reino Unido: IWA Publishing, Cambridge University Press.
- Fernández, Edgar; Galvis, Alberto (octubre de 2003). Artificial Neural Networks Model used for clear water treatment plants. En *Seminario Internacional «La Hidroinformática en la Gestión Integrada de los Recursos Hídricos»-AGUA 2003*. Cartagena, Colombia. Recuperado de <https://pdfs.semanticscholar.org/1b07/33cd7885b5d9af7319fd14dfbb318ae0215a.pdf>
- 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>
- García-Núñez, José (2017). *Optimización de la utilización de catalizadores orgánicos biológicos en el tratamiento de aguas residuales de la industria avícola usando Redes Neuronales Artificiales* (tesis de maestría). Universidad Nacional de Colombia Sede Palmira, Palmira, Colombia.
- Gómez-Daza, Elcy (2012). *Estudio de gestión ambiental para la Empresa Avícola Agrícola Mercantil del Cauca – AGRICAA S.A* (tesis de maestría). Universidad de Manizales, Manizales, Colombia. Recuperado de http://ridum.umanizales.edu.co:8080/xmlui/bitstream/handle/6789/563/402_Gomez_Daza_Elcy_2012.pdf?sequence=1&isAllowed=y
- González-Martínez, Álvaro (2017). *Modelado y simulación de una planta de tratamiento de aguas residuales (PTAR) empleando el software GPS-X* (tesis de maestría). Universidad Autónoma de San Luis Potosí, San

- Luis Potosí, México.
Recuperado de <http://ciep.ing.uaslp.mx/tesis/tesisPDF/233201813958.pdf>
- Hach Company (2004). *Turbidímetro Portátil Modelo 2100p ISO. Manual del instrumento*. Recuperado de <https://dk.hach.com/asset-get.download.jsa?id=25593612953>
- Haghiri, Sadaf; Daghighi, Amin; Moharramzadeh, Sina (2018). Optimum coagulant forecasting by Modeling Jar Test Experiments using ANNs. *Drinking Water Engineering and Science*, (11), 1-8. <https://doi.org/10.5194/dwes-11-1-2018>
- Haghiri, Sadaf; Moharramzadeh, Sina; Nahvi, Ali; Daghighi, Amin (December 2014). Modeling the jar test experiments using artificial neural networks to predict the optimum coagulant. En *2nd International Congress on Structure, Architecture and Urban Development*, Tabriz, Iran.
- Haugeland, John (1996). Body and world: a review of what computers still can't do: a critique of artificial reason (Hubert I. Dreyfus). *Artificial intelligence*, 80, 119-128. [https://doi.org/10.1016/0004-3702\(95\)00084-4](https://doi.org/10.1016/0004-3702(95)00084-4)
- Haugeland, John (Ed.). (1997). *Mind Design II: Philosophy, Psychology, Artificial Intelligence*. 2nd edition, Cambridge, MS, USA: MIT Press.
- Haykin, Simon (2005). *Neural Networks. A Comprehensive Foundation*. 9th Indian Edition. Delhi, India: Pearson Prentice Hall.
- Hinton, Geoffrey (1987). *Connectionist learning procedures*. Technical Report CMU-CS-87-115. Pittsburg, PA, USA: Computer Science Department, Carnegie-Mellon University.
- Hinton, Geoffrey (1988). Connectionist Learning Procedures. *Artificial Intelligence*, 40(1-3), 185-234. [https://doi.org/10.1016/0004-3702\(89\)90049-0](https://doi.org/10.1016/0004-3702(89)90049-0)
- Ibáñez-Quispe, Victor (2009). *Análisis y diseño de experimentos*. Puno, Perú: Editorial Universitaria, Universidad Nacional del Altiplano.
- ICONTEC. (2010). NTC 3903:2010. Procedimiento para el ensayo de coagulación – floculación en un recipiente con agua o Método de Jarras / ICONTEC, Bogotá, Colombia.
- 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>
- Machaca-Apaza, Lianne (2016). *Estimación de la evapotranspiración de referencia utilizando modelos de redes neuronales artificiales en función de elementos climáticos en la cuenca del río Huancané* (tesis de pregrado). Universidad Nacional del Altiplano, Puno, Perú.
Recuperado de <http://repositorio.unap.edu.pe/handle/UNAP/4612>
- Martínez-Navarro, Fabiola (2007). *Tratamiento de aguas residuales industriales mediante electrocoagulación y coagulación convencional* (tesis doctoral). Universidad de Castilla La Mancha, Ciudad Real, España.
Recuperado de <https://ruidera.uclm.es/xmlui/handle/10578/984>
- Martínez-Rodríguez, Elena (2005). Errores frecuentes en la interpretación del coeficiente de determinación lineal. *Anuario Jurídico y Económico Escurialense*, (38), 315-332.
- Messaoud, Djeddou; Hellal, Aouatef; Imed, Loukam; (June of 2018). Waste treatment plant performances

- modelling using Artificial Neural Networks. In: *Ecotechnologies for Wastewater Treatment*, Ontario, Canada.
- Minsky, Marvin (1961a). Steps toward Artificial Intelligence. *Proceedings of the IRE*, 49(1), 8-30. <https://doi.org/10.1109/JRPROC.1961.287775>
- Minsky, Marvin (1961b). A selected descriptor-indexed bibliography to the literature on artificial intelligence. *IRE Transactions on Human Factors in Electronics*, vol. HFE-2(1), 39-55. <https://doi.org/10.1109/THFE2.1961.4503297>
- Ocampo-Vélez, Luisa; Rodríguez-Montes, John (2011); *Gestión del recurso hídrico en el subsector avícola de la cuenca del río La Vieja* (tesis de pregrado). Universidad Tecnológica de Pereira, Pereira, Colombia. Recuperado de <http://repositorio.utp.edu.co/dspace/handle/11059/2076>
- Olanrewaju, R. F.; Muyibi, S. A.; Salawudeen, T. O.; Aibinu, A. M. (2012). An intelligent modeling of coagulant dosing system for water treatment plants based on artificial neural network. *Australian Journal of Basic and Applied Sciences*, 6(1), 93-99. Recuperado de <https://www.cabdirect.org/cabdirect/abstract/20123074724>
- Ovalle-Celis, Ruthbel; Moreno-Ripe, Cristian; (2014). *Cartilla guía para la ejecución de prácticas de laboratorio en saneamiento de agua potable* (tesis de pregrado). Universidad Católica de Colombia, Bogotá, Colombia. Recuperado de <https://repository.ucatolica.edu.co/bitstream/10983/1797/1/Proyecto.pdf>
- Padilla-Gasca, Edith; López-López, Alberto; Gallardo-Valdez, Juan; (2011). Evaluation of stability factors in the anaerobic treatment of slaughterhouse wastewater. *Journal of Bioremediation and Biodegradation*, 2(1), 114-118. <https://doi.org/10.4172/2155-6199.1000114>
- Peña-Rojas, Anieval (2016). *Uso de redes neuronales artificiales para optimizar la dosificación de coagulantes en la planta de tratamiento de agua potable – Huancayo* (tesis doctoral). Universidad Nacional Agraria La Molina, Lima, Perú. Recuperado de <http://repositorio.lamolina.edu.pe/bitstream/handle/UNALM/2841/P10-P4-T.pdf?sequence=1&isAllowed=y>
- Peña-Rojas, Anieval; Flores del Pino, Lisveth (2014). Redes neuronales para el tratamiento de agua potable en zona de altitud del Perú. *Ambiente y Desarrollo*, 18(35), 109-116. <https://doi.org/10.11144/Javeriana.AyD18-35.rnta>
- Prasannasangeetha, A. (2015). Optimization of Coagulant using Artificial Neural Network. *International Journal of Science and Engineering Research*, 3(4), 1-4. Recuperado de <http://www.ijoser.org/Files/174.pdf>
- Rodrigues-dos Santos, Fábio; Henriques-Librantz, André; Días, Cleber; Gozzo-Rodrigues, Sheila (2017). Intelligent system for improving dosage control. *Acta Scientiarum. Technology*, 39(1), 33-38. <https://doi.org/10.4025/actascitechnol.v39i1.29353>
- Rubio-Clemente, Ainhoa; Chica, Edwin; Peñuela, Gustavo (2014). Aplicación del proceso fenton en el tratamiento de aguas residuales de origen petroquímico. *Ingeniería y Competitividad*, 16(2), 211-223. <https://doi.org/10.25100/iyc.v16i2.3696>
- Rumelhart, David E.; Hinton, Geoffrey E.; Williams, Ronald J. (1986). Learning internal representations by error propagation. Chapter 8: In: *Parallel Distributed Processing*. Vol. 1, pp. 318-362., MIT Press. Cambridge, MA, USA. Recuperado de https://web.stanford.edu/class/psych209a/ReadingsByDate/02_06/PDPVolIChapter8.pdf

- Salgado, A.; Soto, E.; Gómez, R.; Cerino, F. J.; García, R. B.; Garza, M. T.; Loredó, J. A.; Alcalá, M. M. (2013). Modelación de un tratamiento avanzado de aguas residuales, provenientes de una planta de envasado, usando las metodologías de análisis de superficie de respuesta (ASR) y de redes neuronales (RNA). *Química Hoy Chemistry Sciences*, 3(2), 42-53.
- Salgado-Reyna, Alejandro (2013). *Uso de redes neuronales artificiales (RNA) para la modelación de una unidad de ósmosis inversa en una planta piloto de tratamiento de aguas residuales* (tesis doctoral). Universidad Autónoma de Nuevo León, Monterrey, México.
Recuperado de <http://eprints.uanl.mx/3959/>
- Serrano, Antonio José; Soria Olivas, Emilio; Martín, José David; (2010). *Redes neuronales artificiales*. Curso 2009-2010. Valencia, España: Universidad de Valencia.
Recuperado de http://ocw.uv.es/ingenieria-y-arquitectura/1-2/libro_ocw_libro_de_redes.pdf
- Steel, R. G.; Torrie, J. H. (1960). *Principles and Procedures of Statistics with Special Reference to the Biological Sciences*. London, UK: Mcgraw-Hill.
doi.org/10.1002/bimj.19620040313
- The Mathworks Inc.; (2008). *Matlab® & simulink® Release 2008a, Installation Guide for Windows*. Natick, MA, USA: The Mathworks Inc.
- Toc-Aguilar, René (2012). *Efecto de los microorganismos eficientes (M.E.) en las aguas residuales de la granja porcina de Zamorano, Honduras* (tesis de pregrado). Escuela Agrícola Panamericana, Zamorano, Honduras.
Recuperado de <https://bdigital.zamorano.edu/bitstream/11036/1039/1/T3265.pdf>
- Vásquez-Almazán, María; Martínez-Morales, José (octubre de 2014). Modelado de la calidad del efluente en el tratamiento de aguas residuales mediante Redes Neuronales Artificiales. *XVI Congreso Latinoamericano de Control Automático – CLCA*. Asociación de México de Control Automático, Cancún, México.
Recuperado de <http://amca.mx/memorias/amca2014/media/files/0140.pdf>
- Villarreal-Campos, Carlos; Caicedo-Bravo, Eduardo; (2013). Técnicas de inteligencia computacional aplicadas a modelos de estimación de coagulante en el proceso de potabilización de agua. *Revista Facultad de Ingeniería Universidad de Antioquia*, (69), 205-215.
- Widrow, Bernard; Lehr, Michael (1990). 30 years of adaptive neural networks: perceptrons, madaline, and backpropagation. *Proceedings of the IEEE*, 78(9), 1415-1442.
<https://doi.org/10.1109/5.58323>