

**PREDICCIÓN DE LA DOSIS DE COAGULANTE PARA EL TRATAMIENTO DE  
AGUA POTABLE UTILIZANDO REDES NEURONALES ARTIFICIALES**

**YURLEY VANESSA LIZARAZO GUTIERREZ**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER  
FACULTAD DE INGENIERIAS FISICO QUIMICAS  
ESCUELA DE INGENIERIA QUIMICA  
BUCARAMANGA**

**2018**

**PREDICCIÓN DE LA DOSIS DE COAGULANTE PARA EL TRATAMIENTO DE  
AGUA POTABLE UTILIZANDO REDES NEURONALES ARTIFICIALES**

**YURLEY VANESSA LIZARAZO GUTIERREZ**

**Trabajo de Grado para optar el título de Ingeniera Química**

**DIRECTOR**

**GIOVANNI MORALES MEDINA.**

**Dr. En Ingeniería Química**

**CODIRECTOR**

**JUAN CARLOS MONTES CALA.**

**Ingeniero Químico**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER  
FACULTAD DE INGENIERIAS FISICO QUIMICAS  
ESCUELA DE INGENIERIA QUIMICA  
BUCARAMANGA**

**2018**

## **DEDICATORIA**

A Dios, Por haberme permitido llegar hasta este punto, por haberme dado salud para lograr mis objetivos, por darme la oportunidad de vivir y por estar conmigo en cada paso que doy, por fortalecer mi corazón e iluminar mi mente y por haber puesto en mi camino a aquellas personas que han sido mi soporte y compañía.

A mi familia, por ser el pilar fundamental en todo lo que soy, por haberme apoyado en todo momento, por sus consejos, sus valores, por la motivación constante que me ha permitido ser una persona de bien.

A mi director GIOVANNI MORALES MEDINA Ingeniero Químico, Dr. y mi codirector JUAN CARLOS MONTES CALA Ingeniero Químico. Por su tiempo compartido, su acompañamiento, dedicación y por impulsar el desarrollo de mi formación profesional.

## TABLA DE CONTENIDO

	<b>Pág.</b>
INTRODUCCIÓN .....	13
1. OBJETIVOS.....	19
1.1 OBJETIVO GENERAL .....	19
1.2 OBJETIVOS ESPECÍFICOS.....	19
2. METODOLOGIA .....	20
2.1 RECOPIACIÓN DE LOS RESULTADOS DE PRUEBAS DE JARRAS .....	21
2.2 DEPURACIÓN DE LA BASE DE DATOS.....	22
2.3 PLANTEAMIENTO DE LAS ARQUITECTURAS NEURONALES ARTIFICIALES.....	22
2.4 ANÁLISIS DE AGRUPACIÓN DERIVADAS DE <i>KMEANS</i> .....	23
2.5 ENTRENAMIENTO Y VALIDACIÓN DE REDES CON ARQUITECTURA FEEDFORWARD.....	24
3. RESULTADOS.....	25
3.1 APORTES IMPORTANTES DE CADA REFERENCIA A LA BASE DE DATOS .....	25
3.2 AGRUPACIONES <i>KMEANS</i> .....	35
3.3 ENTRENAMIENTO Y VALIDACIÓN DE LAS RNA.....	35
4. CONCLUSIONES .....	41
5. RECOMENDACIONES.....	42
BIBLIOGRAFÍA.....	43
ANEXOS.....	48

## LISTA DE TABLAS

	<b>Pág.</b>
Tabla 1: parámetros máximos aceptados para agua potable. ....	13
Tabla 2: Especificaciones del sulfato de aluminio comercial .....	21
Tabla 3: Composición del agua base.....	26
Tabla 4: Estadísticos de la base de datos .....	34
Tabla 5: Errores obtenidos para las mejores RNA.....	38
Tabla 6: Evaluación de la influencia de cada parámetro de entrada.....	39
Tabla 7: Errores obtenidos para las mejores RNA.....	40

## LISTA DE FIGURAS

	<b>Pág.</b>
Figura 1: Esquema general de una red neuronal artificial.....	15
Figura 2: Gráfico y símbolo de la función de transferencia Log-sigmoid.....	16
Figura 3: Gráfico y símbolo de la función de transferencia Tan-sigmoid. ....	17
Figura 4: Diagrama de flujo de la metodología. ....	20
Figura 5 : Esquema general de la arquitectura de las RNA .....	23
Figura 6: Relación de la dosis óptima de coagulante y la turbiedad inicial. ....	27
Figura 7: Relación de la dosis óptima de coagulante y el color inicial. ....	27
Figura 8: Comportamiento del pH en los análisis realizados. ....	28
Figura 9: Conjunto de datos recolectados en la literatura para el parámetro Turbidez inicial.....	29
Figura 10: Conjunto de datos recolectados en la literatura para el parámetro Color inicial.....	30
Figura 11: Conjunto de datos recolectados en la literatura para el parámetro pH inicial.....	30
Figura 12: Diagramas de caja y bigotes para las variables S. Ci.....	31
Figura 13: Gráfica de turbidez inicial y final en función de la dosis de sulfato de aluminio. ....	32
Figura 14: Gráfica del color inicial y final en función de la dosis de sulfato de aluminio. ....	33
Figura 15: Gráfica de pH inicial y final en función de la dosis de sulfato de aluminio. ....	34
Figura 16: Agrupamiento de datos kmeans .....	35
Figura 17: Error obtenido en la RNA de una capa con función Logsig alimentada de la base de datos.....	36

Figura 18: Error obtenido en la RNA de una capa con función Tansig alimentada de la base de datos.....	36
Figura 19: Error obtenido en la RNA de una capa con función Logsig alimentada del agrupamiento Kmeans 1. ....	37
Figura 20: Error obtenido en la RNA de una capa con función Tansig alimentada del agrupamiento Kmeans 1. ....	37
Figura 21: Error obtenido en la RNA de una capa con función Logsig alimentada del agrupamiento Kmeans 2. ....	37
Figura 22: Error obtenido en la RNA de una capa con función Tansig alimentada del agrupamiento Kmeans 2. ....	38

## LISTA DE ANEXOS

	<b>Pág.</b>
ANEXO A: Curva de dosificación de sulfato de aluminio Tipo A.....	48

## RESUMEN

**TITULO:** PREDICCIÓN DE LA DOSIS DE COAGULANTE PARA EL TRATAMIENTO DE AGUA POTABLE UTILIZANDO REDES NEURONALES ARTIFICIALES\*

**AUTOR:** YURLEY VANESSA LIZARAZO GUTIERREZ\*\*

**PALABRAS CLAVES:** Coagulación-Floculación, coagulante, dosis óptima, turbidez, prueba de jarras, redes neuronales artificiales (RNA), algoritmos genéticos, matriz.

### DESCRIPCIÓN:

Este trabajo propone la arquitectura de una red neuronal artificiales (RNA) como modelo de predicción para guiar la experimentación y ahorrar tiempo en la deducción de la dosis optima de coagulante sulfato de aluminio ( $Al_2(SO_4)_3 \cdot 18H_2O$ ) para el tratamiento de agua potable, utilizando para su entrenamiento y validación una base de datos construida a partir de resultados experimentales de tratamiento de aguas con sulfato de aluminio como coagulante recolectados de los reportes de Barajas Garzón, Claudia Lorena. & León Luque, Andrea Juliana. (2015); Castrillón Bedoya, Daniela & Giraldo, María de los Ángeles (2012); Izquierdo Flores, Abdón Mauricio. (2015) y Peña Rojas, Anieval Cirilo. (2016). Las anteriores referencias reportan condiciones experimentales similares para el proceso de coagulación-floculación con sulfato de aluminio a escala laboratorio mediante el uso de la prueba de jarras con medición de los parámetros turbidez, color y pH para cada dosis utilizada de coagulante, la arquitectura de red propuesta fue entrenada y validada mediante el algoritmo *backpropagation*, con el método de optimización Levenberg-Marquardt; se aplican técnicas como la repetición del entrenamiento y el método de regularización denominado como *early stopping* para evitar sobreajustes, Las funciones *Logsig* y *Tansig* fueron consideradas como funciones de activación para las neuronas de la capa oculta. Los procedimientos fueron aplicados según los códigos de la herramienta *nntool* de MATLAB R2017b licenciado para la UIS. La mejor arquitectura red según complejidad y promedio de validación corresponde a la 6:10:10:1 con función de activación *Logsig* mostrando un desempeño suficiente para su aplicación semicuantitativa en las etapas de planeación y ejecución de pruebas de jarras para la determinación experimental de la dosis adecuada de sulfato de aluminio.

---

\* Proyecto de grado

\*\* Facultad de Ingenierías Físico Químicas Escuela de Ingeniería Química Director Giovanni morales medina.Dr. En Ingeniería Química Codirector Juan carlos montes cala. Ingeniero Químico

## ABSTRACT

**TITLE:** PREDICCIÓN DE LA DOSIS DE COAGULANTE PARA EL TRATAMIENTO DE AGUA POTABLE UTILIZANDO REDES NEURONALES ARTIFICIALES\*

**AUTHOR:** YURLEY VANESSA LIZARAZO GUTIERREZ\*\*

**KEYWORDS:** Coagulation-Flocculation, coagulant, optimal dose, turbidity, jar test, artificial neural networks (RNA), genetic algorithms, matrix.

### DESCRIPTION:

The purpose of this work is the architecture of a neural artificial network as a prediction model to guide the experimentation and save time at the deduction of aluminium sulphate coagulant's optimal dose  $Al_2(SO_4)_3 \cdot 18H_2O$  for the treatment of drinking water. Used for its validation a data base built from experimental results of water treatment with aluminum sulphate as coagulant which were collected from the reports of Barajas Garzón, Claudia Lorena. & León Luque, Andrea Juliana. (2015); Castrillón Bedoya, Daniela & Giraldo, De los Ángeles (2012); Izquierdo Flores, Abdón Mauricio. (2015) y Peña Rojas, Anieval Cirilo (2016). The references above report similar experimental conditions for the coagulation-flocculation process with aluminum's sulphate in a lab scale using the jar test to measure turbidity, color and pH parameters for each dose of coagulant used, the proposed network architecture was trained and validated using the *backpropagation* algorithm, with the *Levenberg-Marquardt* optimization method; techniques as repetition of training and the regularization method called "*early stopping*" were applied to avoid over-adjustments, the *Logsig* and *Tansig* functions were considered as activation functions for the neurons in the hidden layer. The applied procedures were according to the codes of the nntool tool of MATLAB R2017b licensed for the UIS. The best net architecture according to complexity and average validation corresponds to 6:10:10:1 with Logsig activation function showing a sufficient performance for its semiquantitative application in the stages of planning and execution of the jar tests for the experimental determination of the adequate dose of aluminum's sulphate.

---

\* Proyecto de grado

\*\* Facultad de Ingenierías Físico Químicas Escuela de Ingeniería Química Director Giovanni morales medina. Dr. En Ingeniería Química Codirector Juan carlos montes cala. Ingeniero Químico

## INTRODUCCIÓN

El crecimiento de la población, los avances tecnológicos y el desarrollo industrial han incrementado los problemas ambientales relacionados con la contaminación de las fuentes hídricas tanto de procedencia superficial como subterránea. En la actualidad existen diversos tratamientos para la purificación del agua que juegan un papel fundamental en la sociedad, reguladas en cada país por el Sector de Agua Potable y el Desarrollo Urbano<sup>1</sup>. En Colombia el Ministerio de Ambiente y Desarrollo Sostenible, mediante el Decreto 1575 de 2007 y la Resolución 2115 de 2007 regula los estándares de calidad de agua potable<sup>2 3</sup>.

**Tabla 1. Parámetros máximos aceptados para agua potable.**

Parámetro	Unidades	Valor máximo
Turbidez	Unidades Nefelométricas de turbiedad (UNT)	2
Potencial de hidrógeno	Unidades de pH	6,5 - 9,0
Color aparente	Unidades de platino-cobalto (UPC)	15

Fuente: MINISTERIO DE LA PROTECCIÓN SOCIAL MINISTERIO DE AMBIENTE, VIVIENDA Y DESARROLLO TERRITORIAL Resolución 2115 de 2007. (22 Jun) Por medio de la cual se señalan características, instrumentos básicos y frecuencias del sistema de control y vigilancia para la calidad del agua para consumo humano [en línea] disponible en: [http://www.minambiente.gov.co/images/GestionIntegraldelRecursoHidrico/pdf/Legislaci%C3%B3n\\_del\\_agua/Resoluci%C3%B3n\\_2115.pdf](http://www.minambiente.gov.co/images/GestionIntegraldelRecursoHidrico/pdf/Legislaci%C3%B3n_del_agua/Resoluci%C3%B3n_2115.pdf)

<sup>1</sup> CHULLUNCUY CAMACHO, Nadia Cristina. Tratamiento de agua para consumo humano. (Ingeniería Industrial). Universidad Nacional Mayor de San Marcos. 2011

<sup>2</sup> MINISTERIO DE LA PROTECCIÓN SOCIAL MINISTERIO DE AMBIENTE, VIVIENDA Y DESARROLLO TERRITORIAL Resolución 2115 de 2007. (22 Jun) Por medio de la cual se señalan características, instrumentos básicos y frecuencias del sistema de control y vigilancia para la calidad del agua para consumo humano [en línea] disponible en: [http://www.minambiente.gov.co/images/GestionIntegraldelRecursoHidrico/pdf/Legislaci%C3%B3n\\_del\\_agua/Resoluci%C3%B3n\\_2115.pdf](http://www.minambiente.gov.co/images/GestionIntegraldelRecursoHidrico/pdf/Legislaci%C3%B3n_del_agua/Resoluci%C3%B3n_2115.pdf)

<sup>3</sup> MINISTERIO DE LA PROTECCION SOCIAL Decreto 1575 de 2007. (Mayo 9) Por el cual se establece el Sistema para la Protección y Control de la Calidad del Agua para Consumo Humano [en línea] disponible en: <http://www.minambiente.gov.co/images/GestionIntegraldelRecursoHidrico/pdf/Disponibilidad-del-recurso-hidrico/Decreto-1575-de-2007.pdf>

Una de las etapas con menor costo y mayor eficiencia en el tratamiento de aguas es la coagulación-floculación, ya que permite la remoción de partículas de naturaleza coloidal en suspensión, en un rango significativo de remoción que varía típicamente entre el 80% y el 90% permitiendo cumplir la normatividad vigente<sup>4</sup>. Este proceso consiste en la desestabilización de las partículas coloidales por la adición de un agente coagulante según las condiciones de operación y el ahorro de materia prima. La precipitación de partículas depende de la concentración del coagulante y del pH final de la mezcla. La determinación de la dosis óptima del coagulante permite la obtención de reducciones adecuadas de turbidez según las condiciones de operación.

Un modelo a nivel de laboratorio de los procesos de coagulación y floculación corresponde a la prueba de jarras, que permite el cálculo de la dosis adecuada de coagulante para la generación de floculos con mayor compactación y retención en los sedimentadores<sup>5</sup>; en este modelo, un agitador múltiple o floculador provisto de vasos de 2 litros de capacidad es utilizado para determinar la turbidez y el pH con cada adición de floculante; las velocidades de mezclado varían de 0 a 25 rpm (rango bajo) y de 0 a 335 rpm (rango alto).

A pesar de la utilidad de la prueba de jarras, su aplicación puede ser dispendiosa, costosa y requerir un tiempo apreciable. Un modelo de predicción ajustado con datos disponibles de pruebas de jarras puede guiar la experimentación, ahorrar tiempo en la consecución de la dosis adecuada de coagulante y predecir sensibilidades respecto a la dosis según los cambios en las propiedades del agua tratada.

---


<sup>4</sup> CABRERA BERMÚDEZ, Xiomara; FLEITES RAMÍREZ, Marisol; CONTRERAS MOYA, Ana María. Estudio del proceso de coagulación-floculación de aguas residuales de la empresa textil "desembarco del Granma" a escala de laboratorio, Tecnología Química, 2009 vol. XXIX, núm. 3

<sup>5</sup> CASTRILLÓN BEDOYA, Daniela & GIRALDO, María de los Ángeles 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. (Tecnología química) Universidad tecnológica de Pereira. 2012

Los datos de pruebas de jarras disponibles en la literatura reportan frecuentemente el uso del sulfato de aluminio ( $Al_2(SO_4)_3 \cdot 18H_2O$ ) como coagulante, debido a su bajo costo y fácil comercialización en el mercado. El uso de este coagulante ha mostrado el cumplimiento de las normas ambientales en el tratamiento de aguas residuales en los rangos de pH entre 4,5 hasta 8<sup>6</sup>.

Por otra parte, desde el punto de vista de la ingeniería, las redes neuronales artificiales (RNA), corresponden a un gran sistema dinámico en paralelo, que efectúan predicciones por medio de transformaciones de señales de entrada con diferentes rutas de conexión, pesos y funciones de activación. En la figura 1, se puede apreciar un esquema general.

**Figura 1. Esquema general de una red neuronal artificial**



Fuente: IZAURIETA, Fernando. & SAAVEDRA, Carlos. Redes Neuronales Artificiales. Departamento de Física, Universidad de Concepción, Concepción, Chile.


La transformación de la información depende del modelo de la RNA y del algoritmo de aprendizaje utilizado. El área de aplicación más natural de las RNA son las tareas en las cuales se deben obtener las transformaciones apropiadas de ciertas entradas a ciertas salidas, lo cual es comúnmente denominado como entrenamiento

<sup>6</sup> CABRERA BERMÚDEZ, Xiomara; FLEITES RAMÍREZ, Marisol; CONTRERAS MOYA, Ana María. Op. Cit.

supervisado<sup>7</sup>. Las funciones que definen a las neuronas se denominan funciones de activación; estas funciones son seleccionadas según la linealidad entre las señales de entrada y las señales que deben ser ajustadas. La función de activación logística (Log-sigmoid) recibe información del conjunto de los números reales, y restringe la salida a valores entre cero y uno, según,

$$a = \frac{1}{1+e^n} \quad (1)$$

**Figura 2. Gráfico y símbolo de la función de transferencia Log-sigmoid.**




Fuente: MATICH, D. Redes Neuronales. Conceptos Básicos y Aplicaciones. 2011.

Por su parte, la función de activación tangente hiperbólica (Tan-sigmoid), reporta valores de salida comprendidos en el rango entre -1 y 1, según,

$$a = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad (2)$$

<sup>7</sup> PEÑA ROJAS, Anieval Cirilo. Uso de redes neuronales artificiales para optimizar la dosificación de coagulantes en la planta de tratamiento de agua potable – Huancayo. Universidad nacional agraria la molina, escuela de posgrado, doctorado en ingeniería y ciencias ambientales. 2016

**Figura 3. Gráfico y símbolo de la función de transferencia Tan-sigmoid.**



Fuente: MATICH, D. Redes Neuronales: Conceptos Básicos y Aplicaciones. 2011

Otras funciones de activación, así como detalles en la arquitectura de RNA y sus algoritmos de entrenamiento son descritos con detalle en la literatura<sup>8</sup>.

A nivel de la aplicación, el diseño y el entrenamiento de las redes neuronales pueden ser efectuados utilizando MATLAB 2017 –con licenciamiento para la Universidad Industrial de Santander–. MATLAB cuenta con una caja de herramientas denominada *nntool*, por medio de la cual diferentes estructuras de red neuronal son definidas de forma amigable. Con *nntool* es posible identificar entrenamientos con sobreajuste a través de los resultados con el conjunto de validación (con el 70% de los datos se efectúa el entrenamiento, mientras que con el 15% de los datos se efectúa la validación). Asimismo, *nntool* permite la detención temprana del sobreajuste, lo cual es denominado como *early stopping*<sup>9</sup>.

El presente trabajo fue dedicado al entrenamiento y la validación de diferentes estructuras de red neuronal artificial utilizando información relacionada con el proceso de coagulación-floculación en pruebas de jarras. Las RNA fueron

---

<sup>8</sup> MATHWORKS Neural Network ToolboxDocumentation. [en línea] [Access Ed 21 May 2018]. disponible en: [https://www.mathworks.com/help/nnet/index.html?searchHighlight=toolbox%20network&s\\_tid=doc\\_srchttitle](https://www.mathworks.com/help/nnet/index.html?searchHighlight=toolbox%20network&s_tid=doc_srchttitle)

<sup>9</sup> FISZELEW, A. & GARCÍA MARTINEZ, R. Generación automática de redes neuronales con ajuste de parámetros basado en algoritmos genéticos. Buenos Aires.

entrenadas para reproducir la dosis adecuada de coagulante, según información de las pruebas.

## **1. OBJETIVOS**

### **1.1 OBJETIVO GENERAL**

- Proponer y validar una red neuronal artificial para la determinación de la cantidad de sulfato de aluminio en la etapa de floculación del proceso de tratamiento de agua potable.

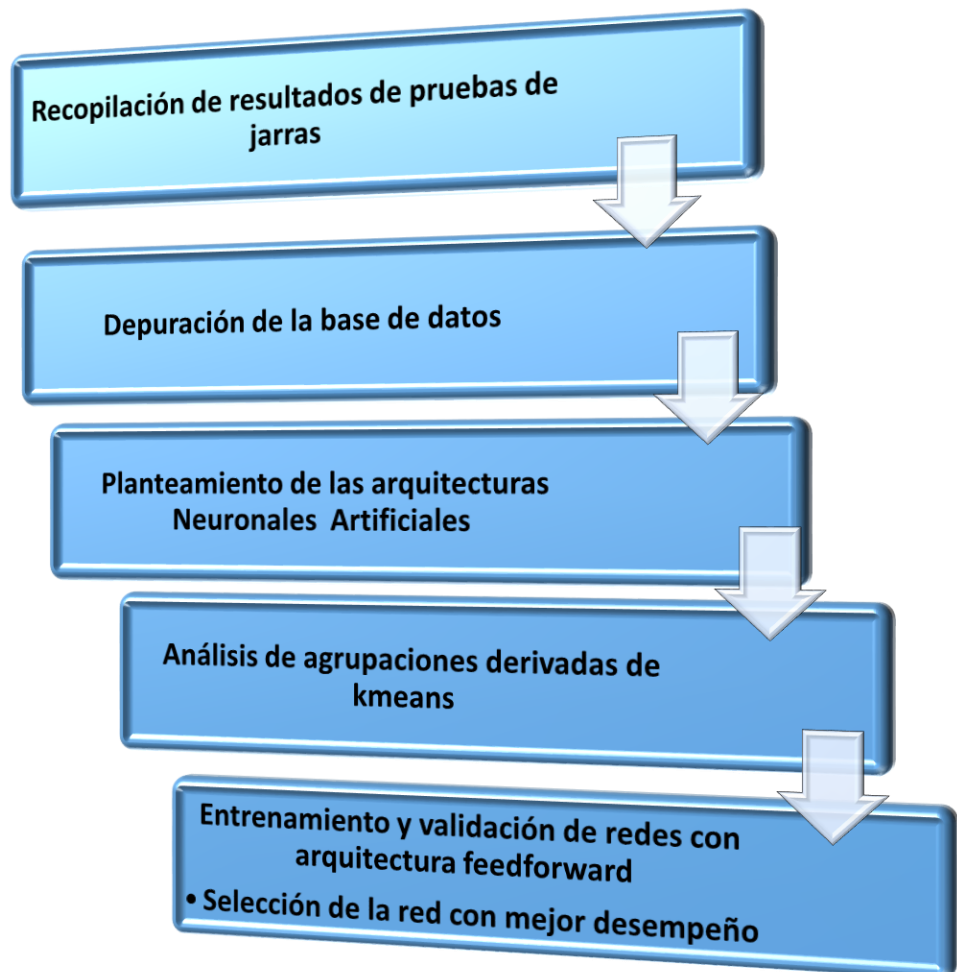
### **1.2 OBJETIVOS ESPECÍFICOS**

- Generar una base de datos recopilada de la literatura para el entrenamiento y la validación de la red neuronal artificial.
- Analizar arquitecturas de red neuronal para su entrenamiento y validación con la base de datos de literatura.
- Proponer la arquitectura de red neuronal artificial para determinar la concentración de sulfato de aluminio.

## 2. METODOLOGIA

En el presente capítulo se esquematiza la metodología de cómo se desarrolla el trabajo para dar cumplimiento a los objetivos. La Figura 4, muestra el diagrama de flujo de la secuencia de ejecución de la presente investigación.

**Figura 4. Diagrama de flujo de la metodología.**



A continuación, se detallan las etapas de la metodología.

## 2.1 RECOPIACIÓN DE LOS RESULTADOS DE PRUEBAS DE JARRAS

La base de datos de tratamiento de aguas con sulfato de aluminio como coagulante fue construida a partir de resultados experimentales reportados en trabajos de la literatura abierta. Los datos encontrados coincidieron en la aplicación de pruebas de jarras a escala laboratorio, para diferentes afluentes con características similares. Los reportes encontrados mostraron el uso de sulfatos Tipo A y Tipo B, en los dos casos granulados; las características de cada tipo de sulfato son mostradas en la Tabla 2. En total, cuatro trabajos fueron seleccionados para construir la base de datos; los datos fueron recolectados de los reportes de Barajas Garzón, Claudia Lorena. & León Luque, Andrea Juliana. (2015); Castrillón Bedoya, Daniela & Giraldo, De los Ángeles (2012); Izquierdo Flores, Abdón Mauricio. (2015) y Peña Rojas, Anieval Cirilo. (2016). Es importante recalcar que las anteriores referencias reportan condiciones experimentales similares para el proceso de coagulación-floculación con sulfato de aluminio a escala laboratorio mediante el uso de la prueba de jarras con medición de los parámetros turbidez, color y pH para cada dosis utilizada de coagulante. En la sección de resultados se presentan los aspectos importantes de cada referencia.

**Tabla 2. Especificaciones del sulfato de aluminio comercial**

<b>ESPECIFICACIONES</b>	<b>SULFATO DE ALUMINIO TIPO A GRANULADO</b>	<b>SULFATO DE ALUMINIO TIPO B GRANULADO</b>
<b>Color</b>	Blanco café	Transparente
<b><i>Al<sub>2</sub>O<sub>3</sub></i> mínimo.</b>	17,0%	15,0%
<b><i>Fe<sub>2</sub>O<sub>3</sub></i> máximo.</b>	1,0%	1,5%
<b>Material insoluble Max.</b>	0,50%	10,0%
<b>Basicidad mínima.</b>	0,05%	0,05%

Fuente: DISTRIBUIDORA DQI. Ficha técnica

## 2.2 DEPURACIÓN DE LA BASE DE DATOS

Los datos recolectados fueron organizados en una matriz de 414x7, donde las columnas corresponden a las variables turbidez inicial y final, color inicial y final, pH inicial y final, y dosis adecuada de floculante.

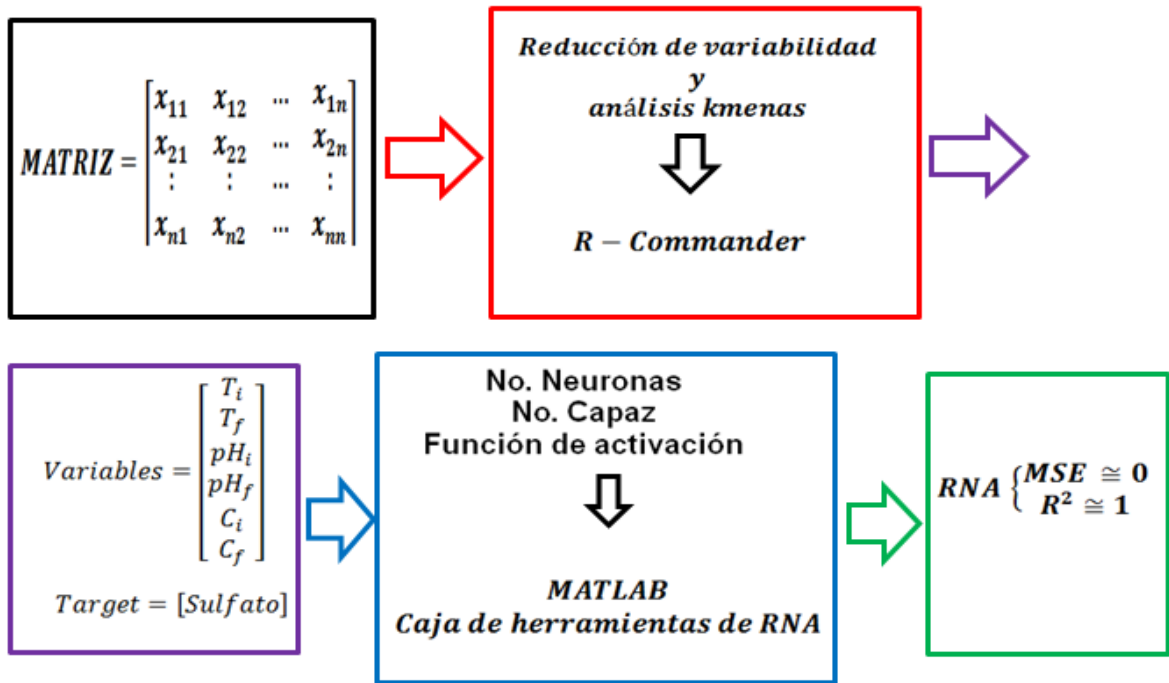
Esta matriz de datos resultante fue reducida por la aplicación de algoritmos de estadística según códigos del programa gratuito *Rcommander*. El rango intercuartíl fue utilizado para eliminar datos atípicos desde la visión univariada. Con esto, la dimensión de la matriz fue reducida a 256x7 (*i.e.* 158 muestras fueron descartadas). En una revisión final, los valores de los parámetros fuera de la normatividad vigente para Colombia fueron omitidos de la base de datos. La matriz de datos final reportó un tamaño de 177x 7; la variación de los datos en esta matriz puede ser visualizada en la sección de resultados.

## 2.3 PLANTEAMIENTO DE LAS ARQUITECTURAS NEURONALES ARTIFICIALES

La figura 5, muestra de manera general el diseño de las RNA realizadas en este trabajo, inicialmente se alimenta con una matriz de datos explicada en la sección 2.1, seguido a esto se realiza un filtrado de valores atípicos o depuración de datos explicado en la sección 2.2, se establece las variables de entrada pH inicial ( $pH_i$ ), pH final ( $pH_f$ ), color inicial ( $C_i$ ), color final ( $C_f$ ), Turbidez inicial ( $T_i$ ), Turbidez final ( $T_f$ ) y el Target que es la concentración de sulfato.

Luego de definir las variables de entrada definitivas las cuales entran de manera vectorial a la caja de herramientas de MATLAB, se utilizan las funciones de activación *Logsig* y *Tansig* descritas en la introducción, variando el número de neuronas de 1 hasta 10 y el número de capas.

**Figura 5. Esquema general de la arquitectura de las RNA**



Con la caja de herramientas de Matlab se realiza el entrenamiento y evaluación de cada RNA diseñada, tomando al final como parámetros de eficiencia el error cuadrático medio (*MSE*) y el *R-validación* al cuadrado. En el capítulo 3 se muestran los resultados obtenidos para cada diseño de la red neuronal.

## 2.4 ANÁLISIS DE AGRUPACIÓN DERIVADAS DE *KMEANS*

Un análisis de agrupamientos ayuda en la detección de muestras comunes y conjuntos representativos de diferentes poblaciones en la base de datos depurada. El método de agrupamiento *kmeans* fue aplicado definiendo la distancia euclidiana como métrica de formación de las agrupaciones; para el método se definieron 2 agrupaciones para determinar la variabilidad de los datos desde un punto de vista multivariable. El algoritmo *kmeans* fue aplicado según los códigos de *RCommander*. Los resultados del método se muestran en el capítulo 3

## 2.5 ENTRENAMIENTO Y VALIDACIÓN DE REDES CON ARQUITECTURA FEEDFORWARD

El entrenamiento de las diferentes redes neuronales planteadas, se realiza a partir de la base de datos depurada, utilizando seis datos de entrada, pH inicial, pH final, color inicial, color final, turbidez inicial, turbidez final. La variable a reproducir correspondió a la dosis adecuada de sulfato de aluminio para el tratamiento de las respectivas muestras.

Las funciones *Logsig* y *Tansig* fueron consideradas como funciones de activación para las neuronas de la capa oculta; la cantidad de neuronas de la capa oculta fue modificada entre 1 y 10. El algoritmo de entrenamiento utilizado fue el *backpropagation*, con el método de optimización Levenberg-Marquardt, mientras que el método de regularización utilizado para evitar sobreajustes fue el denominado como *early stopping*. Los procedimientos fueron aplicados según los códigos de la herramienta *nntool* de MATLAB R2017b licenciado para la UIS.

Las RNA fueron entrenadas primero considerando el conjunto total de datos y considerando por aparte las agrupaciones obtenidas por el método *kmeans*. Cada RNA fue entrenada 10 veces para promediar los estadísticos mean squared (MSE) y el coeficiente de regresión obtenidos con el conjunto de validación (15% de los datos utilizados según el caso). En total, 600 entrenamientos fueron efectuados para determinar la mejor arquitectura de RNA según los estadísticos de validación.

### 3. RESULTADOS

#### 3.1 APORTES IMPORTANTES DE CADA REFERENCIA A LA BASE DE DATOS

A continuación, se detallan los aportes de los reportes de Barajas Garzón, Claudia Lorena. & León Luque, Andrea Juliana. (2015); Castrillón Bedoya, Daniela & Giraldo, De los Ángeles (2012); Izquierdo Flores, Abdón Mauricio. (2015) y Peña Rojas, Anieval Cirilo. (2016).

- Tesis 1 Barajas Garzón, Claudia Lorena. & León Luque, Andrea Juliana. (2015). En su tesis, los autores presentan datos experimentales de la evaluación de la dosis de sulfato de aluminio Tipo B granulado que se usó diluido para 16 niveles de turbidez dentro de un rango de 10 NTU a 1000 NTU, utilizando muestras compuestas como se muestra en la Tabla 3 con el fin de simular la turbidez, el color y la composición orgánica. Los autores ajustaron el pH de las muestras agregando una solución de  $(Ca(OH)_2)$  antes del uso del  $(Al_2(SO_4)_3 \cdot 18H_2O)$  en aguas con pH entre 5.5 y 8. Los autores aplicaron regresión lineal para ajustar la dosis adecuada de coagulante reportando errores promedio de 6.7 mg/L. Estos autores también entrenaron RNA para la predicción de la dosis adecuada, con lo cual los errores alcanzados resultaron menores que para la regresión lineal.

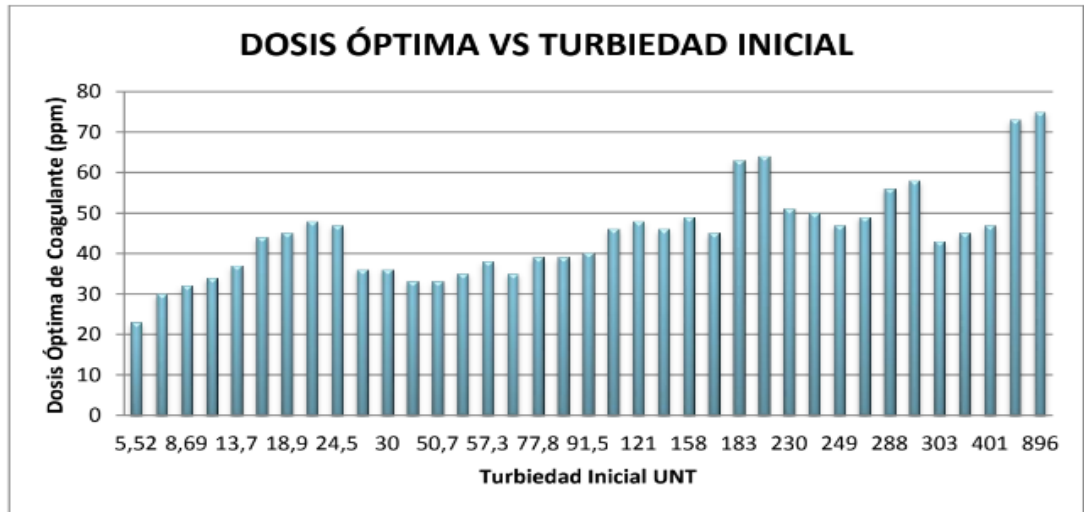
**Tabla 3. Composición del agua base**

<b>Ingrediente</b>	<b>Cantidad</b>
Agua	7000 ml
Arena (0.5-1.0mm)	150 g
Arcilla (<0.004mm)	150 g
Refresco en polvo (colorante, endulzante y saborizante)	20 g

Fuente: BARAJAS GARZÓN, Claudia Lorena. & LEÓN LUQUE, Andrea Juliana. Determinación de la dosis óptima de sulfato de aluminio en el proceso de coagulación - floculación para el tratamiento de agua potable por medio del uso de una red neuronal artificial. (ingeniería ambiental). Universidad Santo Tomás. 2015


- Tesis 2: Castrillón Bedoya, Daniela & Giraldo, María de los Ángeles (2012). Los autores trataron muestras de agua de origen superficial (agua de río), determinando la dosis adecuada para la disminución de la turbiedad y el color; el test de jarras fue efectuado considerando variaciones de la dosis de sulfato de aluminio tipo B. Estos autores analizaron la relación entre los parámetros de turbidez, color y pH versus la dosis de coagulante por medio de regresiones. La Figura 6 presenta la cantidad de sulfato de aluminio adecuada según el valor de turbiedad inicial de la muestra de agua. Según esta figura, para el rango de analizado, la cantidad de sulfato adecuada tiende en promedio a aumentar con la turbiedad de la muestra. Sin embargo, el aumento no es monotónico, con lo cual una regresión lineal reportaría errores considerables en sus predicciones. Por otra parte, los autores obtuvieron porcentajes de remoción de la turbiedad cercana al 60% y disminución de color por encima del 80%, mostrando efectividad del sulfato de aluminio en las muestras tratadas. Unas aclaraciones finales presentan los autores; para colores elevados se hace necesario la adición de una dosis de floculante mayor (Figura 7); lo anterior sugiere la existencia de coloides hidrofílicos en las muestras tratadas; estos coloides benefician la disminución del pH (Figura 8) y la turbiedad con la adición del sulfato de aluminio.

**Figura 6. Relación de la dosis óptima de coagulante y la turbiedad inicial.**




Fuente: CASTRILLÓN BEDOYA, Daniela & GIRALDO, María de los Ángeles 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. (Tecnología química) Universidad tecnológica de Pereira. 2012

**Figura 7. Relación de la dosis óptima de coagulante y el color inicial.**



Fuente: CASTRILLÓN BEDOYA, Daniela & GIRALDO, María de los Ángeles 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. (Tecnología química) Universidad tecnológica de Pereira. 2012

**Figura 8. Comportamiento del pH en los análisis realizados.**




Fuente: CASTRILLÓN BEDOYA, Daniela & GIRALDO, María de los Ángeles 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. (Tecnología química) Universidad tecnológica de Pereira. 2012

- Tesis: Izquierdo Flores, Abdón Mauricio. (2015). Presenta en su tesis la determinación de la dosis óptima de coagulante Sulfato de Aluminio tipo A en solución al 5% en función de los parámetros turbiedad, color y pH. La dosis óptima de coagulante fue determinada a partir de pruebas de jarras para cada turbiedad obteniendo porcentajes de remoción de turbiedad por encima del 80% y de color por encima del 70%. Con los datos obtenidos en cada uno de los ensayos de jarras los autores graficaron la curva de dosificación con los respectivos ajustes que esta requería. En la misma se relacionó la dosis de sulfato de aluminio en función de la turbiedad inicial del agua (anexo A).
- Tesis y Peña Rojas, Anieval Cirilo. (2016). El autor aplicó prueba de jarras para determinar la dosis de sulfato de aluminio tipo B en muestras de agua superficial; las pruebas fueron aplicadas a muestras recolectadas durante un periodo de once meses, con muestreo aleatorio diario. Asimismo, los datos experimentales fueron divididos en dos conjuntos para su ajuste por RNA; un conjunto fue utilizado para el entrenamiento y el otro para la validación; las variables de


entrada consideradas fueron la turbidez, el pH, la conductividad y el color. De las RNA entrenadas, la denominada de regresión generalizada reportó los mejores rendimientos para el ajuste de la dosis adecuada de coagulante (MSE de 3,73 y R2 de 0.984 en validación).

Las Figuras 9-11 presentan las dispersiones de las variables iniciales respecto a la dosis adecuada de floculante definido en cada trabajo. Según estas figuras, la base de datos contiene un rango de valores amplio para las condiciones iniciales; a pesar de presentar este rango amplio, las cantidades de floculante utilizadas reportan valores bajos, lo cual, manifiesta la variedad de muestras que conforman la base de datos y la dificultad en la predicción por una sencilla regresión lineal.


**Figura 9. Conjunto de datos recolectados en la literatura para el parámetro Turbidez inicial.**



**Figura 10. Conjunto de datos recolectados en la literatura para el parámetro Color inicial.**




**Figura 11. Conjunto de datos recolectados en la literatura para el parámetro pH inicial.**



La Figura 12 ilustra los datos atípicos encontrados para la variable sulfato, por medio del diagrama de caja y bigotes. Con esto, la dimensión de la matriz fue reducida a 256x7 (*i.e.* 158 muestras fueron descartadas). En una revisión final, los valores de los parámetros fuera de la normatividad vigente para Colombia fueron omitidos de


la base de datos. La matriz de datos final reportó un tamaño de 177x 7; la variación de los datos en esta matriz puede ser visualizada en las Figuras 13-15.

**Figura 12. Diagramas de caja y bigotes para las variables S. Ci.**



La superficie de turbidez final versus turbidez inicial y dosis de floculante sulfato de aluminio es mostrada en la Figura 13. Los valores resultantes para el parámetro turbidez varían en un intervalo de 1.24 a 33.88 NTU (Nephelometric Turbidity Unit) para turbidez inicial y entre 0.28 a 1.92 NTU para el caso de turbidez final, intervalos que cumplen con la normatividad vigente [2-3 Asimismo, según la Figura 13, la superficie para la turbidez final refleja máximos y mínimos, con una tendencia a presentar valores mayores con mayores valores de turbidez inicial y bajas concentraciones de sulfato. Aunque la tendencia anterior corresponde a lo esperado según el proceso, la superficie de turbidez final exhibe irregularidades que difícilmente pueden ser reproducidas por medio de regresiones lineales.

**Figura 13. Gráfica de turbidez inicial y final en función de la dosis de sulfato de aluminio.**




De otro lado, la Figura 14, ilustra la variación del parámetro color antes y después del proceso de coagulación-floculación con sulfato de aluminio. Los valores obtenidos varían en un intervalo entre 9 a 138 UPC (unidades de platino cobalto) para color inicial y entre 0 a 12 UPC para el color final, valores que también cumplen con la normatividad vigente<sup>10 11</sup>. Según esta figura, los valores de color final se encuentran por debajo de 10; asimismo, en esta figura se aprecian dos rangos máximos importantes para el color final; un máximo se encuentra en el intervalo de color inicial entre 30 y 100 y valores de sulfato inferiores a 10 ppm, mientras que el otro se localiza en valores de color inicial entre 10 y 40, y valores de sulfato superiores a 20. Con lo anterior, el comportamiento del color final resulta atípico,

<sup>10</sup> MINISTERIO DE LA PROTECCIÓN SOCIAL MINISTERIO DE AMBIENTE, VIVIENDA Y DESARROLLO TERRITORIAL Op. Cit.

<sup>11</sup> MINISTERIO DE LA PROTECCION SOCIAL Op. Cit.

reflejando muestras de agua diferentes en la base de datos; no obstante, la superficie de color final cumple con las especificaciones de ley.

**Figura 14. Gráfica del color inicial y final en función de la dosis de sulfato de aluminio.**

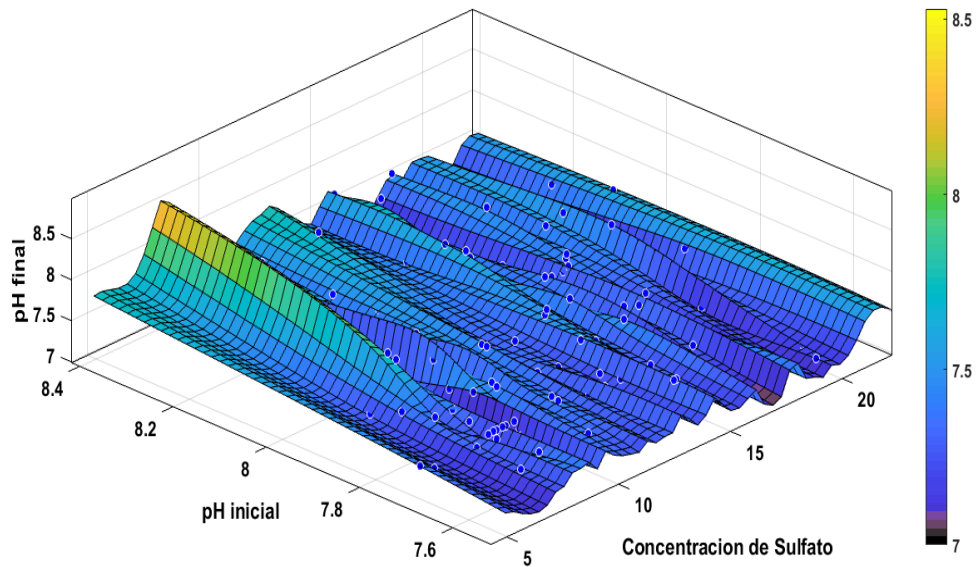


Respecto al pH final, la Figura 15, muestra los valores de pH antes y después del proceso de coagulación-floculación con sulfato de aluminio. Según esta figura, los valores obtenidos varían en un intervalo de 7.5 a 8.4 para pH inicial y entre 7.1 y 7.8 para el caso de pH final, valores que cumplen con la normatividad vigente<sup>12 13</sup>. Asimismo, en la superficie de pH se observa una tendencia en reducción del pH final con el aumento en la dosis de sulfato.

<sup>12</sup> MINISTERIO DE LA PROTECCIÓN SOCIAL MINISTERIO DE AMBIENTE, VIVIENDA Y DESARROLLO TERRITORIAL Op. Cit.

<sup>13</sup> MINISTERIO DE LA PROTECCION SOCIAL Op. Cit.

**Figura 15. Gráfica de pH inicial y final en función de la dosis de sulfato de aluminio.**



Los estadísticos de la base de datos depurada son ilustrados en la Tabla 4. La columna S en esta tabla corresponde a la dosis óptima encontrada para el proceso de coagulación-floculación. Asimismo, según la Tabla 4 la base de datos cubre un rango apreciable de muestras de aguas para tratamiento y todos los resultados después de la adición del sulfato de aluminio conllevan al cumplimiento de la normatividad vigente. Con lo anterior, la base de datos resulta válida para su uso en la predicción de la dosis adecuada de sulfato para el tratamiento de aguas por medio de RNAs.


**Tabla 4. Estadísticos de la base de datos**

	Ti (UNT)	Tf (UNT)	Ci (UPC)	Cf (UPC)	pHi	pHf	S (Mg/L)
<b>Promedio</b>	5,582	0,743	39,045	0,904	7,846	7,419	13,163
<b>Desviación estándar</b>	5,240	0,311	30,164	1,936	0,189	0,157	4,443
<b>Max.</b>	33,880	1,920	138,000	12,000	8,400	7,810	22,910
<b>Min.</b>	1,240	0,280	9,000	0,000	7,500	7,100	4,940

### 3.2 AGRUPACIONES KMEANS

Los resultados del método (Figura 16) sugieren que la mayor parte de los datos corresponden a la misma población (i.e. grupo 2); un total de 154 datos fueron clasificados en la agrupación 2, mientras sólo 23 datos se encontraron en el grupo 1. Lo anterior se debe a que la variable Color Inicial (Ci) para estos 23 datos poseen los valores más elevados de la base de datos. No obstante, estas muestras fueron mantenidas en la base de datos ya que valores mayores de color inicial fueron descartados utilizando el rango intercuartíl.

Figura 16. Agrupamiento de datos kmeans




### 3.3 ENTRENAMIENTO Y VALIDACIÓN DE LAS RNA

Las Figuras 17-22 muestran los errores obtenidos en la validación de las RNA con una subcapa considerando las funciones Logsig y Tansig. Las RNA fueron entrenadas usando la base de datos depurada y los agrupamientos obtenidos por

el método *kmeans*; en las figuras se compararon los valores del error cuadrático medio (MSE) y los valores del coeficiente de regresión (R2) obtenidos en la validación de cada caso.

**Figura 17. Error obtenido en la RNA de una capa con función Logsig alimentada de la base de datos.**



**Figura 18. Error obtenido en la RNA de una capa con función Tansig alimentada de la base de datos.**




Figura 19. Error obtenido en la RNA de una capa con función Logsig alimentada del agrupamiento Kmeans 1.




Figura 20. Error obtenido en la RNA de una capa con función Tansig alimentada del agrupamiento Kmeans 1.




Figura 21. Error obtenido en la RNA de una capa con función Logsig alimentada del agrupamiento Kmeans 2.


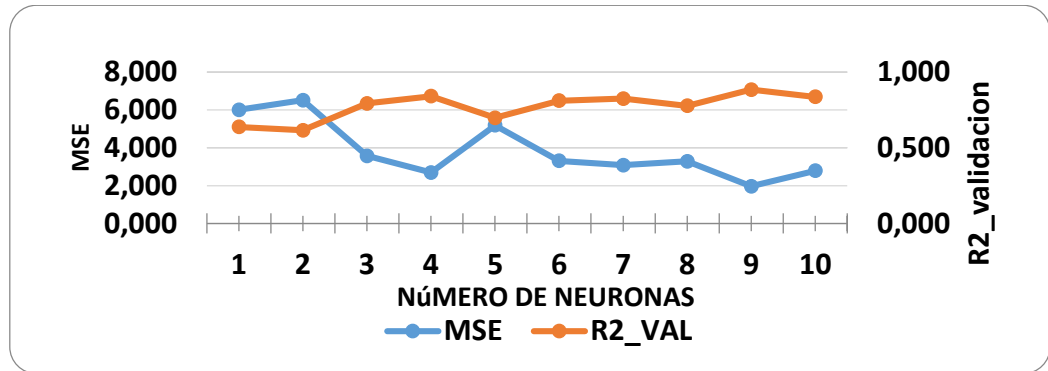


Figura 22. Error obtenido en la RNA de una capa con función Tansig alimentada del agrupamiento Kmeans 2.



Adicionalmente, las redes neuronales fueron analizadas variando el número de capas ocultas de 2 a 3 para cada caso y se eligió entre ellas la red que mostro el mejor ajuste comparando los valores de MSE y R de validación obtenidos promediando los resultados de 10 entrenamientos para cada caso. Como resultado, 6 arquitecturas de redes neuronales, 3 redes por cada función de activación, fueron evaluadas para la base de datos y para los grupos kmeans. La Tabla 5 presenta los resultados de los promedios de los entrenamientos para cada arquitectura de red.

Tabla 5. Errores obtenidos para las mejores RNA.

	FUNCIÓN ACTIVACIÓN	NÚMERO CAPAS	2 CAPAS		3 CAPAS	
		NÚMERO DE NEURONAS	MSE	R2_VAL	MSE	R2_VAL
BASE DE DATOS	LOGSIG	10	2,324	0,878	4,793	0,766
	TANSIG	9	3,817	0,791	4,829	0,729
KMEANS 1	LOGSIG	3	1,233	0,866	2,589	0,752
	TANSIG	9	0,115	0,995	0,045	0,989
KMEANS 2	LOGSIG	8	2,783	0,851	1,793	0,897
	TANSIG	9	2,777	0,823	1,533	0,906

La mejor red según complejidad y promedio de validación corresponde a la Logsig 6:10:10:1 con la base de datos depurada; la otra red de mejor desempeño corresponde a la Tansig 6:9:9:9:1 (*kmean 2*), la cual posee un desempeño similar a la Logsig 6:10:10:1, pero posee una capa oculta adicional; aunque la red Tansig 6:9:9:9:1 exhibe el menor valor de MSE, su entrenamiento considera la agrupación 1 (*kmean*), con lo cual su generalidad no es suficiente para su aplicación en la estimación de la dosis adecuada de sulfato. La red Logsig 6:10:10:1 fue analizada para determinar la influencia de cada entrada según el método *input perturbation*<sup>14</sup>, el cual multiplica por 0,5 una entrada a la vez y ejecuta nuevamente los entrenamientos. La Tabla 6 detalla los resultados del método *input perturbation*; según esta tabla, las tres variables afectan significativamente la RNA; el color posee una influencia ligeramente superior (menor R2) para el conjunto total de datos depurados, debido, probablemente, a las muestras con coloración elevada.

**Tabla 6. Evaluación de la influencia de cada parámetro de entrada**

	<b>Función activación</b>	<b>Número neuronas</b>	<b>Número capas</b>	<b>parámetro de peso 0,5</b>	<b>MSE</b>	<b>R2_VAL</b>
<b>Data</b>	Logsig	10	2	Ci	0,002	0,770
				<b>Ti</b>	<b>0,002</b>	<b>0,807</b>
				<b>pHi</b>	<b>0,001</b>	<b>0,825</b>
<b>Kmeans 1</b>	Tansig	9	3	Ci	0,000	0,848
				<b>Ti</b>	<b>0,000</b>	<b>0,992</b>
				<b>pHi</b>	<b>0,000</b>	<b>0,997</b>
<b>Kmeans 2</b>	Tansig	9	3	Ci	0,004	0,717
				<b>Ti</b>	<b>0,002</b>	<b>0,760</b>
				<b>pHi</b>	<b>0,002</b>	<b>0,779</b>

En la Tabla 7 se resumen las mejores arquitecturas de RNA. La generalidad de la red Logsig 6:10:10:1 (6 entradas, 10 neuronas, dos capas ocultas de 10 neuronas) para el ajuste de todos los datos se presenta como la mejor opción para la obtención

<sup>14</sup> JATINDER, KUMAR, Ajay, Bansal. application of artificial neural network to predict properties of diésel –biodiesel blends. En: kathmandu university journal of science, engineering and technology vol. 6, no. ii, 2010, pp 98-103

de la dosis óptima de sulfato  $MSE=2,324$  y  $R^2=0,878$  en validación. A pesar de estar compuesta por datos de diferentes fuentes, la red Logsig 6:10:10:1 muestra un desempeño suficiente para su aplicación semicuantitativa en las etapas de planeación y ejecución de pruebas de jarras para la determinación experimental de la dosis adecuada de sulfato de aluminio.

**Tabla 7. Errores obtenidos para las mejores RNA**

	<b>Función activación</b>	<b>Número neuronas</b>	<b>Número capas</b>	<b>MSE</b>	<b>R2_VAL</b>
<b>Base de datos</b>	LOGSIG	10	2	2,324	0,878
<b>kmeans 1</b>	TANSIG	9	3	0,045	0,989
<b>kmeans 2</b>	TANSIG	9	3	1,533	0,906

#### 4. CONCLUSIONES

- La red neuronal cuya arquitectura utiliza 6 neuronas de entrada, 10 neuronas en la primera capa y 10 neuronas en la segunda, con función de activación Logsig, entrenada en el presente trabajo predice alrededor del 88% de la varianza ( $MSE=2.324$ ) de la dosis adecuada de sulfato de aluminio para el proceso coagulación-floculación; la red fue entrenada a partir de una base de datos compilada con datos experimentales de pruebas de jarras reportados en la literatura. La red muestra un desempeño suficiente para su aplicación semicuantitativa en las etapas de planeación y ejecución de pruebas de jarras para la determinación experimental de la dosis adecuada de sulfato de aluminio.
- El análisis de sensibilidad de la red 6:10:10:1 reporta a la variable pH inicial como la de mayor influencia para la determinación de la dosis adecuada de sulfato de aluminio. La influencia del pH inicial es ligeramente superior a la turbidez inicial y al color inicial, lo cual puede deberse a que existe un rango de pH óptimo para el cual la coagulación tiene lugar más rápidamente, si la coagulación se realiza fuera del rango de pH óptimo entonces se debe aumentar la cantidad del coagulante; por lo tanto, la dosis requerida es más alta.

## 5. RECOMENDACIONES

- Ensayar otras clases de redes neuronales diferentes a las feedforward. Asimismo, incrementar el tamaño de la base de datos recolectada con un mayor número de reportes experimentales.

## BIBLIOGRAFÍA

ANDÍA CÁRDENAS, Yolanda. Evaluación de Platas y Desarrollo Tecnológico. Tratamiento de agua coagulación y floculación. Lima, Perú. 2000

BARAJAS GARZÓN, Claudia Lorena. & LEÓN LUQUE, Andrea Juliana. Determinación de la dosis óptima de sulfato de aluminio en el proceso de coagulación - floculación para el tratamiento de agua potable por medio del uso de una red neuronal artificial. (ingeniería ambiental). Universidad Santo Tomás. 2015

CABRERA BERMÚDEZ, Xiomara; FLEITES RAMÍREZ, Marisol; CONTRERAS MOYA, Ana María. Estudio del proceso de coagulación-floculación de aguas residuales de la empresa textil "desembarco del Granma" a escala de laboratorio, Tecnología Química, 2009 vol. XXIX, núm. 3

CASTRILLÓN BEDOYA, Daniela & GIRALDO, María de los Ángeles 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. (Tecnología química) Universidad tecnológica de Pereira. 2012

CHULLUNCUY CAMACHO, Nadia Cristina. Tratamiento de agua para consumo humano. (Ingeniería Industrial). Universidad Nacional Mayor de San Marcos. 2011

CORREDOR, D. & JAMES, R. Mejoramiento de un sistema de tratamiento de aguas pluviales provenientes del lavado de ropa, para la reutilización en baterías sanitarias, lavado de pisos, riego de plantas entre otras. (Ingeniera Química.). Universidad Industrial de Santander. 2015

CS An Introduction to Neural Networks. [en línea] disponible en: <http://www.cs.stir.ac.uk/~lss/NNIntro/InvSlides.html>

FIGUEIREDO, M.S.N, PEREIRA, A.M. Managing knowledge – The importance of databases in the scientific production. *Procedia Manufacturing*. Volumen 12 2017, p. 166 – 173. [en línea] disponible en: <https://www.sciencedirect.com/science/article/pii/S2351978917306108>

FISZELEW, A. & GARCÍA MARTINEZ, R. Generación automática de redes neuronales con ajuste de parámetros basado en algoritmos genéticos. Buenos Aires.

IZAURIETA, Fernando. & SAAVEDRA, Carlos. *Redes Neuronales Artificiales*. Departamento de Física, Universidad de Concepción, Concepción, Chile.

IZQUIERDO FLORES, Abdón Mauricio. Determinación de la dosis óptima del coagulante sulfato de aluminio aplicado en la planta de tratamiento de agua de la central termoeléctrica “El descanso”. Facultad de Ciencias Químicas. Escuela de ingeniería ambiental. Universidad de Cuenca. Ecuador. 2015

JATINDER, KUMAR, Ajay, Bansal. application of artificial neural network to predict properties of diésel –biodiesel blends. En: *kathmandu university journal of science, engineering and technology* vol. 6, no. ii, 2010, pp 98-103.

JIMÉNEZ, L. & MELO, J. Diseño a escala laboratorio de un sistema de tratamiento de aguas residuales contaminadas con residuos poliméricos (Ingeniería Química). Universidad industrial de Santander. 2015

LÓPEZ LOAIZA, Dany. Diseño y construcción de una red neuronal artificial de propósito general (ingeniería de sistemas). Universidad Politécnica Salesiana. 2007

LORENZO ACOSTA, Yaniris. Estado del arte del tratamiento de aguas por coagulación-floculación ICIDCA. Sobre los Derivados de la Caña de Azúcar, vol. XL, núm. 2, pp. 10-17 Instituto Cubano de Investigaciones de los Derivados de la Caña de Azúcar Ciudad de La Habana, Cuba. 2006

MATHWORKS Neural Network ToolboxDocumentation. [en línea] [Access Ed 21 May 2018]. disponible en: [https://www.mathworks.com/help/nnet/index.html?searchHighlight=toolbox%20net work&s\\_tid=doc\\_srchtile](https://www.mathworks.com/help/nnet/index.html?searchHighlight=toolbox%20net%20work&s_tid=doc_srchtile)

MATHWORKS Neural Network ToolboxDocumentation. [en línea] [Access Ed 21 May 2018]. disponible en: [https://www.mathworks.com/help/nnet/index.html?searchHighlight=toolbox%20net work&s\\_tid=doc\\_srchtile](https://www.mathworks.com/help/nnet/index.html?searchHighlight=toolbox%20net%20work&s_tid=doc_srchtile)

MATICH, Damián Jorge. Redes Neuronales: Conceptos Básicos y Aplicaciones. Universidad Tecnológica Nacional – Facultad Regional Rosario, Departamento de Ingeniería Química, Grupo de Investigación Aplicada a la Ingeniería Química (GIAIQ). 2011

MINISTERIO DE LA PROTECCION SOCIAL Decreto 1575 de 2007. (Mayo 9) Por el cual se establece el Sistema para la Protección y Control de la Calidad del Agua para Consumo Humano [en línea] disponible en: <http://www.minambiente.gov.co/images/GestionIntegraldelRecursoHidrico/pdf/Disponibilidad-del-recurso-hidrico/Decreto-1575-de-2007.pdf>

MINISTERIO DE LA PROTECCIÓN SOCIAL MINISTERIO DE AMBIENTE, VIVIENDA Y DESARROLLO TERRITORIAL Resolución 2115 de 2007. (22 Jun) Por medio de la cual se señalan características, instrumentos básicos y frecuencias del sistema de control y vigilancia para la calidad del agua para consumo humano [en

línea] disponible en:  
[http://www.minambiente.gov.co/images/GestionIntegralDelRecursoHidrico/pdf/Legislacion\\_del\\_agua/Resoluci%C3%B3n\\_2115.pdf](http://www.minambiente.gov.co/images/GestionIntegralDelRecursoHidrico/pdf/Legislacion_del_agua/Resoluci%C3%B3n_2115.pdf)

PEÑA ROJAS, Anieval Cirilo. Uso de redes neuronales artificiales para optimizar la dosificación de coagulantes en la planta de tratamiento de agua potable – Huancayo. Universidad nacional agraria la molina, escuela de posgrado, doctorado en ingeniería y ciencias ambientales. 2016

PEÑA ROJAS, Anieval. & FLORES DEL PINO, Lisveth (). Redes neuronales para el tratamiento de agua potable en zona de altitud del Perú. Ambiente y Desarrollo, 18(35), 2014 109-116. [http:// dx.doi.org/10.11144/Javeriana.AyD18-35.rnta](http://dx.doi.org/10.11144/Javeriana.AyD18-35.rnta).

RESTREPO OSORNO, Hernán Alonso. Evaluación del proceso de coagulación – floculación de una planta de tratamiento de agua potable. (Facultad de minas). Universidad Nacional De Colombia. 2009

RODRÍGUEZ OJEDA, Luis. MATLAB® Conceptos Básicos y Programación. Instituto de Ciencias Matemáticas Escuela Superior Politécnica del Litoral. Guayaquil, Ecuador. 2007.

SÁEZ, A. Métodos estadísticos con R y R commander. Dpto. de Estadística e Investigación Operativa, Universidad de Jaén. Versión 3.0. 2011

SANTANA, A. Introducción al uso de R-Commander. Dpto. de Matemáticas, Universidad de Las Palmas de Gran Canaria. 2011

SELVA, E., SEYIT, K., Hatem, K., ELÇIN G. Artificial Neural Network and Agility. Procedia - Social and Behavioral Sciences. 2015 Volumen 195, p. 1477-1485. [en

línea]


disponible

en:

<https://www.sciencedirect.com/science/article/pii/S1877042815039270>

## ANEXOS

### Anexo A: Curva de dosificación de sulfato de aluminio Tipo A.



Fuente: IZQUIERDO FLORES, Abdón Mauricio. Determinación de la dosis óptima del coagulante sulfato de aluminio aplicado en la planta de tratamiento de agua de la central termoeléctrica “El descanso”. Facultad de Ciencias Químicas. Escuela de ingeniería ambiental. Universidad de Cuenca. Ecuador. 2015