

# 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)

A. Salgado\*, E. Soto, R. Gómez, F. J. Cerino, R. B. García, M. T. Garza, J. A. Loredó y M. M. Alcalá

Universidad Autónoma de Nuevo León, Facultad de Ciencias Químicas, Ciudad Universitaria S/N, Ciudad Universitaria, San Nicolás de los Garza, Nuevo León CP 66451, México.

\*E-mail: salgadoasr1@hotmail.com

Recibido 16 de mayo de 2013, Aceptado 14 de junio de 2013

## Resumen

El agua residual estudiada fue obtenida de una planta productora de latas, localizada en el centro de la República Mexicana. Esta agua residual fue caracterizada y tratada a nivel laboratorio y planta piloto usando procesos de coagulación y floculación. Tres coagulantes y dos floculantes fueron usados en seis combinaciones y un diseño factorial, así como un análisis de superficie de respuesta (ASR) fueron llevados a cabo para explorar los efectos de pH, concentraciones de coagulante y floculante y velocidad de agitación. Del mismo modo pruebas de sedimentación en columna fueron llevadas a cabo, a las mejores condiciones de operación, para determinar el tiempo de detención para la planta piloto. Estas condiciones fueron utilizadas para construir una planta piloto para tratar 15.14 L/min, la cual incluye una membrana de ósmosis inversa (OI). En la prueba de jarras, las mejores condiciones de remoción UNT con cero turbidez fueron alcanzadas por la combinación de  $\text{Al}_2(\text{SO}_4)_3$ -NALCO 9907, a  $100 \text{ min}^{-1}$  y pH ácido. En la planta piloto fue requerido un tiempo de detención de 2 horas para remover el 100 % de los sólidos suspendidos en el tanque de sedimentación. La unidad de OI permitió el incremento de remoción de los sólidos totales disueltos a 96.1 % permitiendo una recuperación máxima de agua residual de casi 72 %. Los datos de la unidad de OI fueron exitosamente modelados mediante redes neuronales artificiales (ANN). Una red de cuatro capas alimentada hacia adelante con un algoritmo de propagación hacia atrás fue usada para entrenar todos los modelos de RNA. Los datos esperados y experimentales fueron bien correlacionados y fue alcanzado un coeficiente de determinación de 0.99.

**Palabras clave:** Coagulación, floculación, ósmosis inversa (OI), análisis de superficie de respuesta (ASR) y redes neuronales artificiales (RNA).

## 1. Introducción

Cada año empresas en México y en todo el mundo se ven obligadas a drenar cientos de miles de metros cúbicos de aguas residuales provenientes de sus procesos [1,2]. Esto se debe principalmente a la falta de aplicación de técnicas confiables de modelación [3,4], falta de aplicación de técnicas de ahorro de agua en descargas [5], falta de nuevas metodologías de tratamiento biológico [6,30], químico [7] y fisicoquímico [8,9,31] en combinación con nuevas [10], más eficientes y menos costosas tecnologías.

La modelación de la Planta de tratamiento de aguas residuales (PTAR) usando la metodología de análisis de superficie de respuesta (ASR) simultáneamente con procedimientos de cero descargas (PCD), redes grises (RD) y redes neuronales artificiales (RNA) han sido aplicadas para tratar efluentes industriales generados por diferentes industrias como: Efluentes de aceite de palma en aserraderos [11], electrometalizado [12], efluentes de parques industriales [13], acabado de

metales [14], hospitales [15], etc. El uso de RNA para modelar procesos de tratamiento de aguas residuales ha sido exitosamente aplicado para predecir el desempeño de plantas de tratamiento de aguas residuales [16-19], decoloración de soluciones con tintas provenientes de procesos de textiles [20-22], nanofiltración [23] y remoción de metales pesados [4, 24, 25], entre otros.

Estas técnicas de modelación han sido aplicadas para predecir la calidad de los efluentes como una función de los parámetros de calidad del agua residual [13], para estimar el comportamiento de un sistema a diferentes condiciones [26] y para predecir las mejores condiciones operacionales como una función de los parámetros de calidad de los influentes (DQO, DBO y STD) [17].

De acuerdo con la literatura más reciente, aún y cuando existen estudios relativos al uso de RNA para modelar el desempeño de membranas de ósmosis inversa en diferentes condiciones de operación, no fueron encontrados estudios relativos al uso de RNA para modelar membranas de ósmosis inversa (OI) como parte de una planta

piloto usada para el tratamiento de un flujo de agua residual proveniente de una planta fabricante de latas. Por esta razón, el objetivo de esta investigación fue el de incrementar la tasa de reuso del agua industrial residual, mediante la determinación de las mejores condiciones para los procesos de coagulación-floculación a nivel laboratorio; adicionalmente, estas condiciones serían aplicadas a nivel de planta piloto, la cual incluye una membrana de OI. Los datos obtenidos en esta unidad de OI serán estudiados y modelados mediante RNA.

En esta investigación fue estudiado un flujo de agua industrial residual proveniente de una planta de manufactura de latas, el cual contiene cantidades significativas de sólidos disueltos totales (SDT), sólidos suspendidos (SS) y grasa. La planta piloto de tratamiento de aguas residuales (PPTAR) propuesta incluye el uso de un químico anti-incrustante y una unidad de OI, en contraste con la planta de tratamiento actual la cual está basada en el diseño descrito por Reynolds y Richards [32].

Procedimientos básicos para determinar las mejores condiciones de coagulación-floculación fueron establecidos mediante pruebas de jarras basadas en diseños factoriales  $2^n$  [33,34] con seis combinaciones coagulante-floculante en las cuales fueron estudiadas concentraciones iniciales de coagulante y floculante, velocidad de agitación y pH en la solución.

Con el objetivo de diseñar el tanque de sedimentación, fueron determinadas curvas de isoporcentaje mediante pruebas por lotes en columna de sedimentación. Los equipos de la unidad de coagulación y floculación para tratar el agua industrial residual estudiada fueron diseñados en base a los resultados del cálculo del tiempo de sedimentación. Una vez que la planta piloto fue puesta en operación, un segundo diseño factorial fue efectuado en la unidad de la membrana de OI, a diferentes condiciones de operación para analizar su desempeño, basado en dos variables (pH y concentración de anti-incrustante), cuatro niveles en el control de pH (3.0, 4.0, 7.0 y 12.0) y dos niveles en la concentración de anti-incrustante (1.0 y 3.0 mg/L). Los datos obtenidos en este diseño factorial fueron usados para modelar la tasa de reutilización del agua industrial residual por medio de un modelo de redes neuronales artificiales (RNA).

## 2. Parte Experimental

### 2.1 Caracterización del agua industrial residual

La Tabla 1 muestra las características de calidad

del flujo de agua residual bajo estudio. Varias muestras de agua industrial residual de la planta de manufactura de latas fueron obtenidas y analizadas, usando métodos fisicoquímicos [38] tales como NMX-AA-093-SCFI-2000 para conductividad, NMX-AA-072-SCFI-2001 para dureza total, NMX-AA-008-SCFI-2000 para pH, NMX-AA-034-SCFI-2001 para sólidos suspendidos totales (SST), y NMX-AA-005-SCFI-2000 para grasa y aceites. Es muy importante mencionar que este efluente contiene altos valores de conductividad, óxido de silicio, sólidos totales, sólidos disueltos totales y DQO.

Estos altos valores son debidos principalmente a la falta de mejores y más efectivos procesos de filtración en la planta actual. Particularmente, altos valores de óxido de silicón son debidos a que el agua de lavado usada en el proceso de fabricación de latas, proviene de yacimientos de agua subterráneos, y por otro lado, altos valores de conductividad, de sólidos totales, de sólidos totales disueltos y de DQO están relacionados con los químicos adicionados durante el proceso de lavado de latas. Esta característica de calidad del agua industrial residual indica que el efluente no puede ser reusado en otra etapa de lavado o descargado al drenaje sin un apropiado tratamiento.

**Tabla 1.** Características de calidad del flujo de agua industrial residual.

Parámetro	Unidades	Valores
Conductividad	Micro ohm/cm	2467
pH	unidades de pH	8.35
Dureza total	mg/L as $\text{CaCO}_3$	71.6
Dureza de calcio	mg/L as $\text{CaCO}_3$	36
Dureza de magnesio	mg/L as $\text{CaCO}_3$	35.6
Oxido de silicio	mg/L	258
Sólidos totales (ST)	mg/L	1862
Sólidos disueltos totales (SDT)	mg/L	1817
Sólidos suspendidos totales (SST)	mg/L	45
Demanda química de oxígeno (DQO)	mg/L	300

## 2.2 Prueba de jarras.

Cuando una sal de coagulante es añadida al agua, esta se disocia y los iones metálicos se hidrolizan y crean complejos iónicos hidroximetálicos cargados positivamente.

De este modo,  $Al_2(SO_4)_3$  en soluciones acuosas produce algunos polímeros poli-electrolíticos complejos tales como:  $[Al_6(OH)_{15}]^{3+}$ ,  $[Al_7(OH)_{17}]^{4+}$ ,  $[Al_8(OH)_{20}]^{4+}$  y  $[Al_{13}(OH)_{34}]^{5+}$ , estos polímeros poseen carga positiva y son adsorbidos en la superficie de coloides negativos; por consiguiente, una reducción del potencial zeta es alcanzado, los coloides son des-estabilizados y esto lleva a la formación de flóculo [32].

Para determinar las mejores condiciones en el proceso de coagulación-floculación, una muestra obtenida del efluente fue estudiada en una prueba de jarras [35] a 22.6 °C. La Tabla 2 muestra las combinaciones de coagulante-floculante usados en este estudio. En todos los casos el pH fue mantenido constante usando una solución de HCl 1.0 N.

Para cada combinación de coagulante-floculante mostrada en la Tabla 2, fue llevado a cabo un diseño factorial  $2^4$  [33] considerando las condiciones operacionales del sistema, las cuales fueron definidas como sigue: pH inicial en el agua industrial residual (5 y 10), concentración del coagulante, (1.0 y 3.5 mg/L), concentración del floculante (1.0 y 4.0 mg/L), velocidad de agitación por 10 minutos para la coagulación ( $250 \text{ min}^{-1}$ ), velocidad de agitación durante 45 segundos para la floculación ( $100$  y  $150 \text{ min}^{-1}$ ) y la velocidad de agitación para la formación de flóculo ( $40 \text{ min}^{-1}$ ).

El diseño factorial completo fue analizado para identificar cuales variables independientes (factores) y sus interacciones, podrían tener un efecto significativo en las características de calidad del agua residual tratada. El número total de experimentos o corridas para cada pareja de coagulante - floculante en este diseño factorial, es  $2^4 = 16$ .

**Tabla 2.** Combinaciones de coagulante-floculante para las diferentes pruebas de jarras.

Combinación	Coagulante	Floculante
1	CaO	NALCO 9907
2	$Al_2(SO_4)_3$	NALCO 9907
3	$FeCl_3$	NALCO 9907
4	CaO	NALCO 3249
5	$Al_2(SO_4)_3$	NALCO 3249
6	$FeCl_3$	NALCO 3249

## 2.3 Pruebas en columna de sedimentación

La mejor combinación de coagulante-floculante en los experimentos llevados a cabo en el equipo de jarras, fue escogida para la prueba en la columna de sedimentación, debido a los valores más bajos de turbidez obtenidos. Para alcanzar una efectiva separación de los sólidos suspendidos después del proceso de coagulación-floculación, es importante determinar el tiempo de detención en el tanque de sedimentación. Por esta razón fueron llevadas a cabo algunas pruebas en la columna de sedimentación, para determinar el porcentaje de sólidos suspendidos, en muestras de agua extraídas desde puertos de la columna a diferentes alturas y a diferentes tiempos. [32,34].

La Figura 1 muestra una representación de la columna de sedimentación, la cual consiste de una tubería de acrílico de 330 cm de altura y un diámetro de 15.24 cm, con seis puertos de muestreo localizados cada 50 cm.



**Figura 1.** Representación de la columna de sedimentación.

## 2.4 Planta piloto

Los principales cambios entre el diagrama de flujo actual y el diseño propuesto en esta investigación, los cuales afectaron positivamente la calidad del efluente tratado, fueron el reactor de coagulación y el equipo de ósmosis inversa (OI). Por esta razón el desempeño de estas dos etapas de proceso fue evaluado. El desempeño del reactor de coagulación-floculación fue evaluado usando un diseño factorial de  $2^4$ . La membrana de filtración de OI fue evaluada usando RNA [27].

La Figura 2 muestra el diagrama de flujo propuesto para nuestra planta piloto de tratamiento de aguas residuales. Una planta piloto con una capacidad de  $0.9084 \text{ m}^3/\text{h}$  ( $4.0 \text{ gpm}$ ) fue construida basada en éste diseño para propósitos de validación y prueba.





**Tabla 3.** Experimentos en el sistema de filtrado de ósmosis inversa.

Experimento	pH	Concentración de Anti-incrustante VIATEC 4000 mg/L
1	12	1.0
2	7	1.0
3	12	3.0
4	7	3.0
5	4	1.0
6	4	3.0
7	3	1.0
8	3	3.0
9 (*)	4	3.0

(\*) Para éste caso particular, la membrana de OI fue previamente lavada con una solución de HCl para reducir la caída de presión y así incrementar el flujo permeado.

Dos experimentos, 6 y 9, fueron llevados a cabo a las mismas condiciones con la única diferencia de que el experimento 9 utilizó una membrana que fue retrolavada con una solución de HCl 1.0 N y en el experimento 6 fue utilizada una membrana nueva.

Una vez que el mejor experimento para la unidad de OI fue seleccionado, varias corridas experimentales fueron llevadas a cabo y sus datos fueron estudiados y analizados mediante el software "MATLAB R2009b [38,35] utilizando la herramienta de RNA" [37].


## 2.5 Modelando con RNA

Las redes neuronales artificiales RNA, son técnicas de modelación matemática inspiradas en redes neuronales biológicas [20,25,36,37]. Ellas tienen la ventaja en el manejo de datos para adaptarse y aprender del proceso, tejiendo relaciones no lineales ocultas entre los datos. El elemento básico de una red neuronal es comúnmente llamado neurona, la cual recibe entradas ponderadas desde otras unidades o desde una fuente externa. Está basada sobre una función de activación, usualmente una del tipo tangente hiperbólica, sigmoidal o lineal, la cual genera una señal de salida descrita en la ecuación 3.1.

$$y_{kj} = f(\sum_j w_{ij}x_{ij} + \theta_k) \quad 3.1$$

donde  $y_{kj}$  = salida de la neurona  $i$  en la capa  $k$ ,  $w_{ij}$  = pesos asociados a las entradas de la neurona  $i$  desde las entradas  $j$ ,  $x_j$  = entrada a la neurona  $j$ th,  $\theta_k$  = bias asociado a la capa  $k$  y  $f$  = función activación, usualmente una función tangente hiperbólica, sigmoidal o lineal.

Las RNA tienen tres tipos de capas llamadas de entrada, ocultas y de salida, tal y como se muestra en la Figura 3. La capa oculta puede incluir varias capas con múltiples neuronas. Normalmente una capa oculta con suficientes neuronas es capaz de aprender y predecir el comportamiento de un sistema con un buen nivel de precisión. Por lo tanto, se debe tener especial cuidado en la selección del número de neuronas en la capa oculta [37]. Esta red cuenta con tres neuronas en la capa de entrada, 4 neuronas en la primera capa oculta, 3 neuronas en la segunda capa oculta y una neurona en la capa de salida.



**Figura 3.** Arquitectura de redes neuronales artificiales (RNA).

Para representar el sistema de RNA, primero debe ser llevado a cabo el entrenamiento, lo cual sucede al efectuar una optimización del tipo de Levenberg-Marquardt, Newton, etc., minimizando el costo de la función.

Normalmente el error cuadrático medio, el error cuadrático medio normalizado o el error medio absoluto, pueden calcular la diferencia entre la salida de datos experimentales y la salida de datos esperados (predicción) para la misma entrada de datos experimentales.

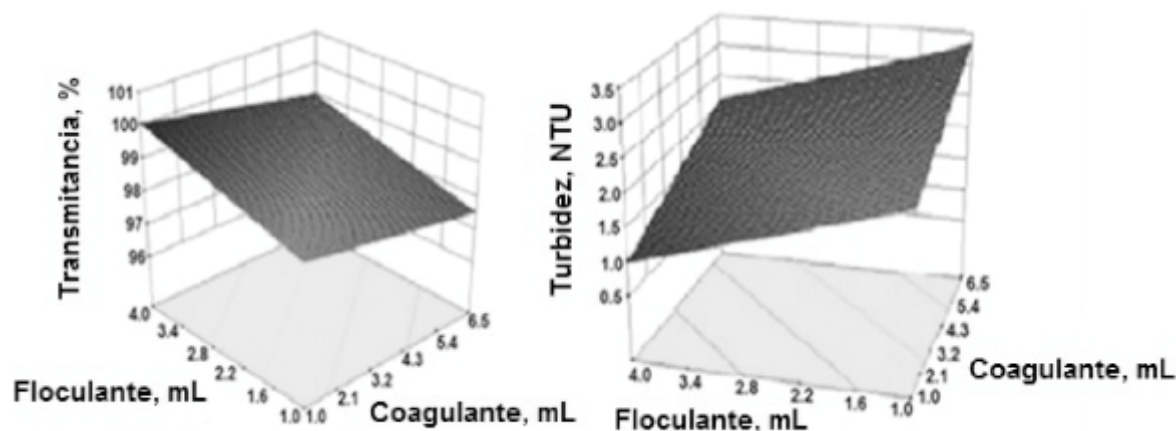
## 3. Resultados y discusión

### 3.1 Experimentos de prueba de jarras

Para cada combinación de coagulante-floculante mostrada en la Tabla 2, una serie de 16 corridas fueron llevadas a cabo y la calidad del agua tratada fue determinada en cada caso. Los mejores resultados en la prueba de jarras [34], fueron obtenidos en la combinación 2 (Ver Tablas 2 y 4), con la combinación de  $Al_2(SO_4)_3$  como coagulante y NALCO 9907 como floculante, velocidad de agitación de  $250 \text{ min}^{-1}$  durante 10 minutos después de la adición de coagulante, velocidad de agitación de  $100 \text{ min}^{-1}$  y  $150 \text{ min}^{-1}$  (dos pruebas) durante 45 segundos después de

**Tabla 4.** Resultados de la prueba de jarras para el caso 2 con  $\text{Al}_2(\text{SO}_4)_3$ -NALCO 9907.

Corrida	pH inicial	Coagulante $\text{Al}_2(\text{SO}_4)_3$ (mL) 0.1 mg/L	RPM's NALCO 9907 45 s.	Floculante Catiónico NALCO 9907 (mL) 1.0 mg/L	pH final	Turbidez UNT	ABS	% T
4	10	6.50	100.00	1	9.72	4.00	0.017	96.23
1	10	1.00	100.00	1	9.78	1.00	0.003	99.34
6	10	1.00	100.00	4	9.80	1.00	0.004	99.06
7	10	6.50	100.00	4	9.81	0.00	0.000	100.0
10	10	1.00	150.00	1	9.77	2.00	0.007	98.47
9	10	6.50	150.00	1	9.78	4.00	0.019	95.69
8	10	6.50	150.00	4	9.59	1.00	0.004	99.20
5	10	1.00	150.00	4	9.58	2.00	0.009	98.00
12	5	6.50	100.00	1	5.59	1.00	0.004	99.08
3	5	1.00	100.00	1	5.61	1.00	0.006	98.70
15	5	6.50	100.00	4	5.72	0.00	0.001	99.68
16	5	1.00	100.00	4	5.82	0.00	0.000	100.0
11	5	6.50	150.00	1	5.93	5.00	0.022	95.06
13	5	1.00	150.00	1	5.98	1.00	0.003	99.23
14	5	1.00	150.00	4	6.00	1.00	0.002	99.60
2	5	6.50	150.00	4	6.01	2.00	0.010	97.65



**Figura 4.** Análisis de superficie de respuesta para transmitancia y turbidez en el caso  $\text{Al}_2(\text{SO}_4)_3$ -NALCO 9907.

la adición de floculante, entonces una velocidad de agitación de  $40 \text{ min}^{-1}$  fue mantenida durante los últimos 5 minutos de la corrida. Todos estos experimentos fueron llevados a cabo a  $22.6^\circ\text{C}$ .


De acuerdo con los resultados mostrados en la Tabla 4, fueron obtenidos valores muy bajos de turbidez. De cualquier forma, los valores más bajos fueron obtenidos en las corridas 7 y 16 y es muy

importante mencionar que en la corrida número 7, una relativamente alta cantidad de coagulante fue requerida en contraste con la usada en la corrida 16. Estos resultados pueden ser explicados por el efecto del pH, debido a que en esta corrida valores de pH ácido promueven la formación de flóculo de gran tamaño, considerando también que el rango de pH óptimo para el sulfato de aluminio es de 4.5 a 8 y que el hidróxido de aluminio es relativamente

insoluble dentro de éste rango [32].

La Figura 4 muestra el análisis de superficie de respuesta (ASR) para mostrar los efectos de las dosis de coagulante y floculante sobre la transmitancia y turbidez del agua bajo estudio.

La Figura 5 muestra la predicción de valores y los compara contra los valores actuales generados durante la prueba de jarras, utilizando el análisis de superficie de respuesta (ASR).



**Figura 5.** Predicción de valores de transmitancia mediante el análisis de superficie de respuesta (ASR).

La Figura 6 muestra el efecto estandarizado de cada variable de entrada sobre la variable de respuesta y puede ser observado que las dosis de coagulante y floculante tienen el mismo efecto sobre la turbidez (UNT) y/o transmitancia.

De acuerdo con los resultados, el agua residual tratada a las condiciones de las corridas 6, 7, 15 y 16 alcanzaron los valores más bajos de turbidez UNT.

Como quiera que sea, por razones económicas, las condiciones descritas en la corrida 16 fueron seleccionadas para las siguientes etapas de ésta investigación, debido a que se requiere la dosis más baja de coagulante y el valor de pH (5) está cercano a la del flujo de agua industrial residual, consecuentemente, fue requerida una baja cantidad de químicos para ajustar el pH.

Es muy importante comentar que para la selección de la mejor pareja de coagulante - floculante, las pruebas de jarras para cada pareja fue llevada a cabo por triplicado y los resultados fueron muy consistentes, manteniendo por mucho la pareja de  $\text{Al}_2(\text{SO}_4)_3$ -NALCO 9907 el mejor desempeño en la calidad del agua siendo tratada con más puntos de operación donde se consigue una transmitancia mayor de 99 % y con más puntos



**Figura 6.** Efectos de las principales variables sobre la Transmitancia / Turbidez; A = Dosis de floculante, B = Dosis de coagulante, C = Velocidad de agitación durante la floculación y D = Valor de pH en la solución.

de operación donde se consigue el 100%. Pero lo más importante es que una vez que se eligió la pareja de  $\text{Al}_2(\text{SO}_4)_3$ -NALCO 9907, en todas las veces que fue repetida la corrida 16 mostrada en la Tabla 4 (5 veces), fue conseguida una transmitancia perfecta del 100 %, que es lo que se quiere asegurar a la salida del reactor coagulador durante la operación de la planta piloto de tratamiento de aguas residuales.

### 3.2 Prueba de sedimentación en columna

Pruebas de sedimentación en columna [32,34] fueron llevadas a cabo para evaluar la sedimentación de una suspensión floculenta producida durante el tratamiento del agua industrial residual. La cantidad de sólidos removidos fue calculada para cada muestra, desde la cantidad inicial de sólidos suspendidos y la concentración de sólidos de cada muestra tomada en puertos localizados a diferentes alturas de la columna, a diferentes tiempos y expresadas como porcentajes.

La Figura 7 muestra curvas de isoporcentaje representando la remoción de sólidos a diferentes tiempos y profundidades en la columna de sedimentación. Como se puede ver, al tiempo de sedimentación de 60 minutos existe una remoción de sólidos suspendidos del 85.41 %.

La remoción completa de sólidos suspendidos fue experimentalmente confirmada por el tiempo de sedimentación de dos horas. De acuerdo con éste resultado, un tiempo de detención de 2 h fue usado para el diseño del tanque de sedimentación.

**Tabla 5.** Desempeño de la membrana de ósmosis inversa a diferentes condiciones de operación.

Casos	1	2	3	4	5	6	7	8	9
<b>pH</b>	12	7.0	12.0	7.0	4.0	4.0	3.0	3.0	<b>4.0</b>
<b>Concentración de anti-incrustante, (mg/L)</b>	1.0	1.0	3.0	3.0	1.0	3.0	1.0	3.0	<b>3.0</b>
<b>Concentración de SiO<sub>2</sub> a la entrada, (mg/L)</b>	18	20	21	19	20	20	20	20	<b>19</b>
<b>Concentración de SDT a la entrada, (mg/L)</b>	1380	1343	1302	1311	1350	1351	1339	1341	<b>1346</b>
<b>Flujo de agua permeada, (gpm)</b>	1.75	2.13	2.21	2.55	2.62	2.76	2.15	2.25	<b>2.85</b>
<b>Concentración de SiO<sub>2</sub> a la salida, (mg/L)</b>	4.0	4.0	4.0	4.0	4.0	4.0	10	6.0	<b>4.0</b>
<b>Concentración de SDT a la salida, (mg/L)</b>	165	171	152	156	111	72	185	175	<b>71</b>

### 3.3 Membrana de ósmosis inversa

La Tabla 5 muestra los resultados sobre el desempeño de la membrana de OI después de 6 días de operación continua, para diferentes valores de pH y anti-incrustante Viatic 4000. Cada experimento fue llevado a cabo hasta que la membrana se saturó, causando un incremento en la caída de presión.

Para todos los casos estudiados la concentración del óxido de silicio en el flujo de entrada a la membrana estuvo en el rango de 18 a 21 mg/L, mientras que en el flujo de agua permeada estuvo en el rango de 4 a 6 mg/L.


De acuerdo a los resultados de la corrida 9, los porcentajes de remoción de óxido de silicio del 92.63 % y 78.94 % fueron alcanzados por el tratamiento desde el flujo de agua residual industrial a la entrada del sistema hasta la entrada de la unidad de OI y solo por la unidad de OI respectivamente. Esto significa que el porcentaje de remoción global de óxido de silicio del 98.44 %. Adicionalmente los porcentajes de remoción de SDT del 25.92 % y 94.72 % fueron alcanzados en las mismas etapas de proceso, lo cual representa un porcentaje de remoción global del 96.09 % de SDT. Estos resultados confirman la contribución de la membrana de OI, debido a que los SDT no fueron efectivamente removidos por los procesos de coagulación y floculación.

En relación a los resultados mostrados en la

Tabla 5, el flujo de agua permeada muestra un crecimiento lineal al incremento del agente anti-incrustante; del mismo modo, cuando el pH disminuye, el flujo de agua permeada se incrementa hasta alcanzar un máximo a un pH de 4.

Por otro lado, los SDT muestran una relación similar con el pH y la concentración de anti-incrustante de manera conjunta, debido a que una sola variable no tiene influencia directa sobre ellos.

Para las variables críticas (flujo de agua permeada y SDT) el mejor comportamiento fue




**Figure 7.** Curvas de isoporcentajes para el cálculo del porcentaje de remoción de sólidos en las pruebas de columna de sedimentación.


alcanzado a pH 4 y una concentración de anti-incrustante de 3 mg/L, por lo tanto, estas condiciones fueron usadas para la operación continua de la planta piloto.




Las Figuras 8 a y 8 b muestran los valores de la concentración de óxido de silicio y la concentración de sólidos disueltos totales (SDT) a la entrada de la membrana de OI, durante 6 días (144 h) de operación; debido a las condiciones de operación inestables la concentración de óxido de silicio y de SDT estuvieron en el rango de 18 a 22 mg/L y de 1300 a 1380 mg/L, respectivamente. La Figura 9 muestra el desempeño del flujo del agua permeada en el mismo periodo; y como puede ser observado, el flujo de agua permeada fue mantenido constante in 3.0 gpm durante 85.15 h de operación continua; de cualquier modo, después de este tiempo el flujo decrece a 2.2 gpm, debido al ensuciamiento de la membrana, lo que significa que el flujo de agua permeada estuvo en el rango de 55 a 72 % de recuperación en ese período.



**Figura 8 a).** Variación de la concentración de  $\text{SiO}_2$  a la entrada de la membrana de OI.




**Figura 8 b).** Variación de la concentración de los STD a la entrada de la membrana de OI.




**Figura 9.** Flujo de agua permeada a la salida de la membrana de ósmosis inversa (OI).

Las Figuras 10 y 11, muestran los valores de la concentración de óxido de silicio y de la concentración de sólidos disueltos totales (SDT) a la salida de la membrana de OI durante 6 días (144 h) de operación de la planta piloto. Como puede ser observado, la concentración de óxido de silicio se mantuvo constante durante el período estudiado, lo cual confirma la efectividad de la membrana de ósmosis inversa (OI) para remover el óxido de silicio. Es muy importante mencionar que después de 144 h de operación la caída de presión se incrementó debido al ensuciamiento de la membrana, por consiguiente, una etapa de lavado fue necesaria antes de usar la membrana de OI.



**Figura 10.** Variación de la concentración de  $\text{SiO}_2$  a la salida de la membrana de OI.



**Figura 11.** Variación de la concentración de STD a la salida de la membrana de OI.

### 3.4 Modelación de RNA en la unidad de ósmosis inversa

Una RNA alimentada hacia delante fue construida usando la herramienta de red neuronal artificial de Matlab y ésta fue entrenada usando los datos experimentales del caso 9 para la unidad de OI, en la Tabla 4. Los datos fueron obtenidos durante 6 días de operación continua de la planta.

La arquitectura de la red está compuesta de 4 capas, con 3 neuronas utilizadas en la capa de entrada, tomando en cuenta el pH de la solución, la concentración de anti-incrustante y el tiempo. En la primera capa oculta fueron usadas 4 neuronas y en

la segunda 3 neuronas, usando una función de activación tangente-sigmoidea, brindando una excelente capacidad de predicción con éste pequeño número de neuronas.

Este aspecto es importante debido a que un incremento en el número de neuronas en las capas ocultas puede ser contraproducente en la habilidad de predicción de una RNA, debido a que estas pueden aprender el ruido del sistema. Finalmente, en la capa de salida fue considerada 1 neurona, con una función de activación lineal, la cual representa el flujo de agua permeada a la salida de la Membrana de OI.

Los pesos de la RNA son ajustados durante el proceso de entrenamiento, el cual utiliza un algoritmo de optimización de Levenberg-Marquardt [38,35] para el presente estudio, para determinar un punto de referencia o ajuste óptimo para los pesos de la red, lo cual reducirá el error cuadrático medio (ECM) obtenido mediante la comparación del valor experimental vs. el valor esperado (predicción) por la RNA.

Un grupo de datos son tomados de forma aleatoria de todo el grupo de datos experimentales para propósitos de entrenamiento de la RNA.

Para propósitos de validación y prueba de la RNA son formados dos grupos de datos de manera aleatoria. Una vez que el entrenamiento fue terminado, todos los datos experimentales son aplicados a la red, para observar sus capacidades de predicción basadas en la velocidad de flujo de agua permeada.

La Tabla 6 siguiente muestra los resultados de la RNA, incluyendo el ECM, el número de iteraciones y el coeficiente de determinación para los datos experimentales en los nueve casos descritos en la Tabla 5. Para todos los casos fueron consideradas 3 neuronas en cada una de las capas ocultas y las redes fueron entrenadas usando el algoritmo de Levenberg-Marquardt.

Como se muestra en la Tabla 5, el caso 9 reproduce el flujo permeado mayor y las más bajas concentraciones de óxido de silicio y SDT a la salida de la membrana de OI, durante 6 días continuos de operación. Adicionalmente, el caso 9 resulta en uno de los más bajos ECM y uno de los mayores coeficientes de determinación. Diferentes configuraciones en el modelo de RNA fueron probadas con 3 neuronas en ambas capas ocultas y la Tabla 7 muestra los resultados de la RNA, incluyendo la red usada, el ECM, el número de iteraciones y el coeficiente de determinación para los datos experimentales obtenidos en el caso 9.

**Tabla 6.** Resultados de la RNA para los datos experimentales obtenidos de todos los casos usados para estudiar el sistema de OI.

Caso	ECM (x 10 <sup>4</sup> )	Número de iteraciones	Coeficiente de Determinación (R <sup>2</sup> ; x 10 <sup>1</sup> )
1	72	181	9.87
2	171	143	9.75
3	322	21	9.56
4	7.34	574	9.97
5	5.78	29	9.98
6	2.38	171	9.98
7	242	56	9.86
8	345	55	9.64
9	5.55	27	9.97

**Tabla 7.** Resultados de la RNA utilizando diferentes tipos de redes para los datos experimentales obtenidos para el caso 9 en la prueba del sistema de la membrana de OI.

Corrida	Red usada	ECM (x10 <sup>4</sup> )	Número de iteraciones	Coeficiente de Determinación (R <sup>2</sup> ; x 10 <sup>1</sup> )
1	Newff	5.64	25	9.98
2	Newfitt	2.38	170	9.75
3	Newlrn	6.29	95	9.79
4	Newpr	2.81	25	No determinado


La Tabla 7 muestra que la red Newff resulta en un muy bajo ECM y en el más alto coeficiente de determinación. El desempeño obtenido con la red Newff usando diferentes configuraciones neuronales es mostrado en la Tabla 8.

La Figura 12 a) muestra los flujos de agua permeada experimental y esperada (predicción) con respecto al tiempo, y la Figura 12 b) compara el flujo esperado (predicción) de agua permeada vs. el flujo de agua permeada experimental, donde se puede observar que la predicción es extremadamente cerrada a los valores reales, con un coeficiente de determinación de 0.99.


**Tabla 8.** Resultados de la RNA utilizando diferentes configuraciones neuronales para los datos experimentales obtenidos durante el caso 9, en la prueba del sistema de la membrana de OI.

Corrida	Número de neuronas en la primera capa oculta (*)	ECM ( $\times 10^4$ )	Número de iteraciones	Coefficiente de Determinación ( $R^2 \times 10^1$ )
1	3	5.64	25	9.98
2	4	2.83	250	9.98
3	5	3.45	160	9.98
4	6	4.54	45	9.98

(\*) Fueron utilizadas 3 neuronas en la segunda capa oculta en todas las corridas.



**Figura 12 a).** Predicción de valores de flujo de agua permeada vs. tiempo, para todos los grupos.



**Figura 12 b).** Predicción de valores de flujo de agua permeada vs. objetivo, para todos los grupos.

### 3.5 Análisis comparativo entre los diseños original y propuesto

En general, la operación completa de la PPTAR (operación propuesta), es comparada con la de Reynolds y Richards [32] para plantas fisicoquímicas (operación original de la PTAR en la planta de manufactura de latas) y los resultados son mostrados en la Tabla 9. Ésta muestra las mejoras en la operación de la planta piloto en todos los parámetros reportados. Las razones principales de estas mejoras son: el uso de filtros coalescentes, los cuales maximizaron la eliminación de grasas y aceites; mejora en la remoción de la DQO; el ajuste

del pH en un valor de 4.0 ayudó a reducir la concentración de  $\text{SiO}_2$  en el flujo de agua permeada; la mejor selección de la pareja de coagulante y floculante, mediante el uso de pruebas de jarras; la eliminación de todo tipo de dureza en el flujo de agua permeada; la inclusión de una membrana de OI, al final de la planta piloto mejoró el proceso de filtración del flujo de agua residual industrial, disminuyendo el contenido total de sólidos; la combinación de filtros pulidores con el uso de un químico anti-incrustante Viatic 4000 mejoraron el tiempo de ciclo operacional de la membrana de OI, disminuyendo significativamente el ensuciamiento sobre esta.

### 4. Conclusiones

Tanto el diseño de experimentos, como el análisis de superficie de respuesta llevados a cabo en la prueba de jarras a nivel laboratorio, concluyeron que los mejores resultados de turbidez/transmitancia fueron obtenidos con la pareja de coagulante y floculante de  $\text{Al}_2(\text{SO}_4)_3$ -NALCO 9907.

Durante el uso del análisis de superficie de respuesta en los datos generados en la prueba de jarras, fueron obtenidos coeficientes de correlación ( $R^2$ ) mayores que 0.97, lo cual significa que el proceso es representado adecuadamente.

Las curvas de isoporcentaje muestran que se espera un 100 % de remoción de sólidos sedimentables después del tanque de sedimentación en la planta piloto de tratamiento de aguas residuales, debido al tiempo de detención de 60 minutos en cada uno de los equipos del Reactor coagulador y del tanque de sedimentación.

Durante el experimento del caso 9, con un pH de 4.0 y una concentración de anti-incrustante de 3 mg/L, fue alcanzado un flujo de agua permeada de 2.85 gpm, el cual representa un 71.25 % de recuperación de agua con suficiente calidad para ser reutilizada. En este mismo experimento se tuvo una reducción del 94.72 % en la concentración de

**Tabla 9.** Comparación de resultados operacionales entre la planta de tratamiento de aguas residuales (PTAR) en la planta de manufactura de latas (proceso original) y la planta piloto de tratamiento de aguas residuales (PPTAR) que es el nuevo diseño propuesto.

Parámetro	Unidades	Proceso original (Reynolds & Richards) [32]	PPTAR (planta piloto)	Mejora (%)
Conductividad	Micro ohm/cm	119.7	65.8	45.02
pH	pH units	7.3	4.0	-
Dureza total	mg/L as CaCO <sub>3</sub>	30	0.0	100
Dureza de calcio	mg/L as CaCO <sub>3</sub>	19	0.0	100
Dureza de magnesio	mg/L as CaCO <sub>3</sub>	11	0.0	100
Oxido de silicio	mg/L	20	4.0	80
Sólidos totales (ST)	mg/L	122	71	41.80
Sólidos disueltos totales (SDT)	mg/L	122	71	41.80
Sólidos suspendidos totales (SST)	mg/L	0	0	0
Demanda química de oxígeno (DQO)	mg/L	50	<10	>80
Flujo de agua recuperada y reusada	%	40	71.25	31.25

los sólidos totales disueltos (SDT) y un 79.0 % de reducción en la concentración de SiO<sub>2</sub>.

El flujo de agua permeada disminuyó al incrementar el pH del agua residual industrial alimentada a la membrana de ósmosis inversa (OI), independientemente del nivel de concentración de anti-incrustante Viatic 4000 utilizado.

El flujo de agua permeada se incrementa al incrementar la concentración del agente anti-incrustante.

Una red neuronal con 3 neuronas en la capa de entrada, 4 neuronas en la primera capa oculta, 3 neuronas en la segunda capa oculta y una neurona en la capa de salida generaron los mejores resultados para la presente modelación.

La planta piloto de tratamiento de aguas residuales, PPTAR, muestra resultados operacionales mucho mejores (calidad del agua tratada y principalmente flujo total de agua recuperado) en términos de conductividad, dureza total, dureza de calcio, dureza de magnesio, concentración de óxido de silicio, concentración de sólidos totales, concentración de sólidos totales disueltos y demanda química de oxígeno, que los obtenidos por Reynolds and Richards (que es la tecnología original siendo usada en la planta de manufactura de latas en Toluca, México).

En las etapas de entrenamiento, validación y prueba de la red neuronal artificial (RNA), para cada caso fueron obtenidos coeficientes de correlación ( $R^2$ ) mayores que 0.99, lo cual significa

que el proceso es representado adecuadamente.

La concentración de sólidos disueltos totales (SDT) en el flujo de agua permeada, cambia de 85 a 55 mg/L en un tiempo de 140 horas, promediando 70 mg/L.

El caso 9, llevado a cabo en la membrana de OI, es el mejor en desempeño, debido al más alto flujo de agua permeada alcanzado y las concentraciones más bajas de óxido de silicio y sólidos disueltos totales (SDT) a la salida.

## 5. Referencias

1. G. W. Miller, Integrated concepts in water reuse: managing global water needs, J.desal, Water Reuse Association (WRA), Elsevier, 187 (2006) 65-75.
2. T. Asano and J.A. Cotruvo, Groundwater recharge with reclaimed municipal wastewater: health and regulatory considerations, J.watres, Elsevier, (2004).
3. P.D. Saha and S. Dutta, Mathematical modeling of biosorption of safranin onto rice husk in a packed bed column using artificial neural network analysis, Desalination and Water Treatment, 41(2012) 308-314.
4. M. Sadrzadeh, T. Mohammadi, J. Ivakpour, N. Kasiri, Neural network modeling of Pb<sup>2+</sup> removal from wastewater using electrodialysis, Chemical Engineering and Processing: Process Intensification, Elsevier, 48 (2009) 1371-1381.
5. United States Environmental Protection Agency (EPA), Water Recycling and Reuse: The Environmental Benefits, Water Division Region IX □ EPA 909-F-98-001, Guidelines for Water Reuse, US EPA Office of Technology Transfer and Regulatory Support EPA/625/R-92/004, (September 2004).
6. J.P. Scott and D.F. Ollis, Integration of Chemical and Biological Oxidation Processes for Water Treatment:



- Review and Recommendations, Environ. Prog, AIChE, 14 (1995) 88-103.
7. S.H. Lin and C.M. Lin, Treatment of textile waste effluents by ozonation and chemical coagulation, J.watres , Elsevier, 27 (1993) 1743-1748.
8. P.P. Pathe, A.K. Biswas, N.N. Rao, S.N Kaul, Physico-chemical Treatment of Wastewater from clusters of Small Scale Cotton Textile Units, Environ Technol, 26 (2005) 313-327.
9. M. Gomez, F. Plaza, G. Garralon, J. Perez, M.A. Gomez, A comparative study of tertiary wastewater treatment by physic-chemical-UV process and macrofiltration-ultrafiltration technologies, J.desal, Elsevier, 202 (2006), 369-376.
10. T. Melin, B. Jefferson, D. Bixio, C. Thoeye, W. De Wilde, J. De Koning, J. Van der Graaf and T. Wintgens, Membrane bioreactor technology for wastewater treatment and reuse, J.desal, Elsevier, 187 (2006) 271-282.
11. A.L. Ahmad, S. Ismail, S. Bathia, Optimization of coagulation-flocculation process for a palm oil mill effluent, using RSM; ENVIRON SCI TECHNOL, 39 (2005) 2828- 2834.
12. Q. Xu, A. Telukdarie, H.H. Lou, and Y. Huang, Integrated electroplating system modeling and simulation for near zero discharge of chemicals and metals, Ind. Eng. Chem. Res., 44(2005) 2156-2164.
13. T.Y. Pai, Gray and neural network prediction of effluent from the wastewater treatment plant of industrial park, using influent quality, Environmental Engineering Science, 25 (2008).
14. F.G. Babuna, I. Kabdasli, S. Sozen, D. Orhon, Effluent management for a metal finishing industry aiming zero discharge conditions, J Environ Sci Health A Tox Hazard Subst Environ Eng. 41 (2006) 1793-1806.
15. T.Y. Pai, Y.P. Tsai, H.M. Lo, C.H Tsai, and C.Y. Lin, Grey and neural network prediction of suspended solids and chemical oxygen demand in hospital wastewater treatment plant effluent; Computers & Chemical Engineering, Elsevier, 31 (2007) 1272-1281.
16. M.M. Hamed, M.G. Khalafallah, E.A. Hassanien, Prediction of waste water treatment plant performance using ANN, Environmental modeling & software, 19 (2004) 919-928.
17. F.S. Mjalli, S. Al-Asheh, H.E. Alfadala, Use of artificial neural network black-box modeling for the prediction of wastewater treatment plants performance, J Environ Manage, Elsevier, 83 (2007) 329-338.
18. H. R. Tashauie, G.B. Gholikandi, H.Hazrati, Artificial neural networks modeling for predict performance of pressure filters in a water treatment plant, Desalination and Water Treatment, 39 (2012) 192-198.
19. D. Hanbay, , Prediction of wastewater treatment plant performance based on wavelet packet decomposition and neural networks, Science Direct, Journal of Expert Systems with Applications, Elsevier, 34 (2008) 1038-1043.
20. N. Daneshvar, A.R. Khataee, N. Djafarzadeh, The use of artificial neural networks (ANN) for modeling of decolorization of textile dye solution containing C.I. basic yellow 28 by electrocoagulation process; J Hazard Mater, 137 (2006) 1788-1795.
21. A. Aleboyeh, M.B. Kasiri, M.E. Olya, and H. Aleboyeh, Prediction of azo dye decolorization by UV/H<sub>2</sub>O<sub>2</sub> using artificial neural networks, DYE PIGMENT, Elsevier, 77 (2008) 288-294.
22. A. R. Khataee, Photocatalytic removal of C.I. Basic Red 46 on immobilized TiO<sub>2</sub> nanoparticles: Artificial neural network modeling, Environ Technol, 30 (2009) 1155-1168.
23. M.S. Noghabi, S.M. Ali Razavi, S.M. Mousavi, Prediction of permeate flux and ionic compounds rejection of sugar beet press water nanofiltration using artificial neural networks, Desalination and Water Treatment, 44 (2012) 83-91.
24. A. Kardam, K. Rohit Raj, J Kumar Arora, M. Mohan Srivastava, S. Srivastava, Artificial Neural Network Modeling for Sorption of Cadmium from Aqueous System by Shelled Moringa Oleifera Seed Powder as an Agricultural Waste, Journal of Water Resource and Protection, 2 (2010) 339-344.
25. K. Yetilmezsoy and S. Demirel, Artificial neural network (ANN) approach for modeling of Pb(II) adsorption from aqueous solution by Antep pistachio (Pistacia Vera L.) shells, J Hazard Mater, Elsevier, 153 (2008) 1288-1300.
26. M. Vyas, et al, Performance Forecasting of Common Effluent Treatment Plant Parameters by Artificial Neural Network, ARPN Journal of Engineering and Applied Sciences, 6 (2011) 38-42
27. M. Khayet, C. Cojocaru, M. Essalhi, Artificial neural network modeling and response surface methodology of desalination by reverse osmosis, Journal of Membrane Science, Elsevier, 368 (2011), 202-214.
28. L.A. Huchler, Improved membrane filtration designs and equipment are revolutionizing utility systems, Mar Tech Systems, Inc., Lawrenceville, N.J., Hydrocarbon Processing (2008).
29. H. Huang, , Pretreatment for low pressure membranes in water treatment: A Review, American Chemical Society, Environ. Sci. Technol, 43 (2009) 3011-3019.
30. M. Henze, P. Harremoës, J. la Cour Jansen and E. Arvin, Wastewater Treatment, Biological and Chemical Processes, Third Edition, Springer-Verlag (2002).
31. L. Pawlowski, Psysicochemical Methods for Water and Wastewater Treatment, Elsevier Scientific Publishing Company inc., (1982).
32. T.D. Reynolds and P.A. Richards, Unit operations and processes in environmental engineering, PWS Publishing Company, (1995).
33. M.J. Anderson, P.J. Withcomb, DOE Simplified (Practical tools for effective experimentation, 2<sup>nd</sup> edition), Taylor & Framas Inc, (2007).
34. Metcalf & Eddy Inc., Waste water engineering, treatment and reuse, Mc Graw Hill, (2003).
35. S.A. Martinez Delgadillo, M.G. Rodríguez Rosalez, Tratamiento de aguas residuales con MATLAB, Editorial Reverté, Barcelona, (2005).
36. P.J. Braspenning, F. Thuijsman, A.J.M.M. Weijters, Artificial Neural Networks: An Introduction, Springer, (1995).
37. B.M.del Brío, A.S. Molina, Redes Neuronales y sistemas borrosos, Alfaomega Grupo editor, SA de CV, México, (2007).
38. Mathworks, MATLAB, Natick, Massachusetts, (2011): <http://www.mathworks.com/products/matlab/>
39. Instituto Mexicano de tecnología del agua (IMTA)/Comité Técnico de Normalización Nacional de Sistemas y Equipos de Riego: [http://www.imta.gob.mx/cotennser/index.php?option=com\\_content&view=article&id=94&Itemid=84](http://www.imta.gob.mx/cotennser/index.php?option=com_content&view=article&id=94&Itemid=84)