



CENTRO DE INVESTIGACIÓN Y DESARROLLO  
TECNOLÓGICO EN ELECTROQUÍMICA, S.C.



---

OPTIMIZACIÓN DE PROCESOS DE TRATAMIENTO DE  
AGUAS RESIDUALES SALOBRES

# TESIS

PARA OBTENER EL GRADO DE

*Doctor en Ciencia y Tecnología  
en la Especialidad de Ingeniería Ambiental*

PRESENTA

**M. en H. Alain Ricardo Picos Benítez**

Santiago de Querétaro, Qro., México, Diciembre del 2016.



Agradezco ampliamente al Consejo Nacional de Ciencia y Tecnología de México (CONACYT) por la asignación de la beca brindada como:

- **Becario No. 235688**
- **Durante el periodo Enero 2012-Diciembre 2015**

Con la cual pude realizar mis estudios de Doctorado en Ciencia y Tecnología en el Centro de Investigación y Desarrollo Tecnológico en Electroquímica en el período antes mencionado.

## AGRADECIMIENTOS

Al Centro de Investigación y Desarrollo Tecnológico en Electroquímica por permitirme realizar mis estudios de doctorado.

Al Dr. Adrián Rodríguez García por la asesoría prestada para realizar este trabajo.

Al Dr. Abraham Ulises Chávez Ramírez por todo el apoyo brindado en la realización del modelo de inteligencia artificial.

M en C. Jesús Cárdenas Mijangos por su tiempo y apoyo brindado.

A los doctores integrantes del grupo de Electroquímica Ambiental por sus valiosos aportes a este proyecto.

A aquellos amigos que hicieron muy amena mi estadía en la ciudad de Querétaro.

A mi familia por el apoyo incondicional brindado durante todo el tiempo que dedique en realizar este trabajo.

Al Dr. Evaristo Méndez Gómez y la M. en C. Ana María Rivas Montañó por alentarme en todo momento y brindarme su amistad.

A todos ustedes gracias.

A T E N T A M E N T E.

Alain Ricardo Picos Benítez

## DEDICATORIA

A mi madre María de Jesús Benítez Jiménez.

## RESUMEN

El presente estudio muestra la utilidad de un modelo de inteligencia artificial, basado en redes neuronales artificiales y algoritmos genéticos, para la optimización de un proceso de tratamiento anaerobio que depura aguas residuales salobres. Durante la etapa de acondicionamiento, el sistema anaerobio fue capaz de trabajar con una eficiencia de remoción de 83% de la carga orgánica a 23 g/L de salinidad. Estos valores de remoción son muy altos, considerando el efecto inhibitorio causado por la sal en los sistemas de tratamiento biológico. Después de la etapa de acondicionamiento del inóculo siguió una etapa de experimentación. El objetivo de la fase de experimentación fue la generación de datos para entrenar una red neuronal que fuera capaz de predecir el comportamiento del reactor UASB. La red neuronal fue acoplada a un algoritmo genético que se utilizó para obtener las condiciones experimentales en las cuales, el desempeño del reactor sería el mejor. El algoritmo genético acoplado a la Red Neuronal Artificial (RNA) arrojaron la siguiente combinación de operación: temperatura 25 °C, salinidad 20 g/L y carga orgánica de 9.9 Kg DQO/m<sup>3</sup>.d; bajo estas condiciones, la eficiencia del reactor, probada experimentalmente fue de un 70%, validando la eficacia del modelo de inteligencia artificial.

## ABSTRACT

The present study shows the usefulness of an artificial intelligence model, based on artificial neural networks and genetic algorithms, for the optimization of an anaerobic treatment process that treats residual brackish water. During the conditioning stage, the anaerobic system was able to work with a removal efficiency of 83% of the organic load at a salinity of 23 g/L. This removal value is very high, considering the inhibitory effect caused by the salt in biological treatment systems.

After an inoculum conditioning step, a stage of experimentation was followed. The objective of the experimental phase was to generate real experimental data to train a neural network that was able to predict the behavior of a UASB reactor. The neural network was coupled to a genetic algorithm that was used to obtain the experimental conditions in which the performance of the reactor would be the best. The genetic algorithm coupled to an Artificial Neural Network (ANN) gave the following operational conditions: temperature 25 °C, salinity 20 g/L and an organic load of 9.9 Kg COD/m<sup>3</sup>.d; after an experimental validation of these conditions, the reactor efficiency reached a COD removal of 70%, proving the efficacy of the artificial intelligence model as a helpful tool for design or monitoring wastewater treatment systems.



**Este trabajo fue realizado en el Centro de  
Investigación y Desarrollo Tecnológico en  
Electroquímica (CIDETEQ), bajo la dirección**

**Dr. Adrián Rodríguez García**

INDICE DE TABLAS.....	V
INDICE DE FIGURAS .....	VI
INTRODUCCIÓN GENERAL .....	1
JUSTIFICACION .....	3
HIPOTESIS .....	4
OBJETIVO GENERAL.....	5
OBJETIVOS ESPECÍFICOS .....	5
Capítulo 1 Acondicionamiento de un sistema de tratamiento anaerobio basado en reactor anaerobio de flujo ascendente (UASB por sus siglas en inglés) a alta salinidad.....	6
1. INTRODUCCIÓN.....	7
1.1. Tipos de agua residual y sus características.....	7
1.2. Tratamiento de agua residual.....	8
1.2.1. Unidades utilizadas en el tratamiento de aguas residuales.....	9
1.3. Digestión anaerobia.....	11
1.3.1. Hidrólisis.....	12
1.3.2. Acidogénesis .....	13
1.3.3. Acetogénesis.....	14
1.3.4. Metanogénesis .....	15
1.4. Parámetros de control.....	16
1.5. Tóxicos inhibidores del proceso de tratamiento anaerobio.....	16
1.5.1. Amoníaco.....	18
1.5.2. Sulfuros.....	18
1.5.3. Metales pesados.....	19
1.5.4. Compuestos orgánicos tóxicos.....	19
1.5.5. Sodio, potasio, magnesio, calcio, aluminio ( <i>Na, K, Mg, Ca</i> y <i>Al</i> ).....	20



1.5.6.	Inhibición por presencia de sales.....	20
2.	ANTECEDENTES.....	22
2.1.	Medición de DQO en muestras con alta salinidad.....	22
2.2.	Acondicionamiento de sistemas de tratamiento a diferentes salinidades .....	23
2.3.	Uso de biomasa halófila o halotolerante .....	25
2.4.	Estudios sobre la presencia de bacterias halófilas o halotolerantes en muestras de agua. 27	
3.	METODOLOGÍA EXPERIMENTAL.....	30
3.1.	Acondicionamiento del lodo anaerobio.....	30
3.1.1.	Activación del lodo anaerobio.....	30
3.1.2.	Acondicionamiento del lodo anaerobio.....	30
3.2.	Inoculación del reactor con sedimento marino.....	34
3.3.	Incremento de la salinidad.....	35
3.4.	Estabilización del reactor y seguimiento de parámetros de control.....	35
3.5.	Determinación del rendimiento de biogás a diferentes concentraciones de sal.....	36
4.	RESULTADOS Y DISCUSIONES.....	38
4.1.	Activación del lodo anaerobio convencional y acondicionamiento a agua residual sintética.....	38
4.2.	Análisis de muestras de agua residual sintética con salinidad elevada.....	40
4.3.	Acondicionamiento del lodo a alta salinidad y alta carga orgánica.....	42
4.4.	Efecto de la salinidad en un lodo anaerobio acondicionado.....	47
4.5.	Especies de bacterias presentes en el reactor.....	50
5.	CONCLUSIONES.....	54
	REFERENCIAS .....	56

Capítulo 2 Desarrollo de un modelo de inteligencia artificial, basado en redes neuronales y algoritmos genéticos, para la optimización de un proceso de tratamiento de aguas residuales salinas.....	61
1. INTRODUCCIÓN.....	62
1.1. Uso de inteligencia artificial para optimización de procesos de tratamiento de aguas residuales. ....	62
1.2. Redes neuronales artificiales (RNA). ....	62
1.2.1. Arquitectura de la red. ....	63
1.2.2. RNA de capa única. ....	63
1.2.3. RNA multicapa. ....	64
1.3. Funciones de transferencia. ....	65
1.4. Tipos de RNA. ....	66
1.4.1. Perceptron. ....	66
1.4.2. Perceptron multicapa. ....	67
1.4.3. Red Back-propagation. ....	67
1.5. Aplicaciones de RNA.....	69
1.6. Algoritmos genéticos (AG). ....	69
1.7. Representación de un algoritmo genético.....	70
1.7.1. Selección.....	71
1.7.2. Recombinación o cruza. ....	72
1.7.3. Mutación. ....	74
1.8. Características principales de los AG. ....	74
2. ANTECEDENTES. ....	76
2.1. Modelos de IA aplicados a sistemas de tratamiento de aguas residuales. ....	76
2.2. Condiciones de operación y eficiencias reportadas en el tratamiento de aguas residuales salobres.....	78

3. METODOLOGIA EXPERIMENTAL .....	80
4. RESULTADOS Y DISCUSIÓN .....	82
4.1. Colecta de datos.....	82
4.2. Diseño de una RNA. ....	87
4.3. Optimización del sistema de tratamiento con AG. ....	93
5. CONCLUSIONES .....	102
REFERENCIAS .....	104
6. PERSPECTIVAS .....	108

## INDICE DE TABLAS.

Tabla 1. Concentración típica de contaminantes básicos en aguas residuales domésticas.....	7
Tabla 2. Concentración de contaminantes en algunas aguas residuales industriales. ....	8
Tabla 3. Unidades de pre-tratamiento utilizadas en las plantas de tratamiento de agua residual. .....	9
Tabla 4. Rutas metabólicas presentes en la acidogénesis.....	13
Tabla 5. Grupos de organismos metanogénicos y reacciones que llevan a cabo.....	15
Tabla 6. Parámetros básicos de control en un proceso anaerobio. ....	16
Tabla 7. Compuestos tóxicos y concentraciones inhibitorias en el proceso de digestión anaerobia. ....	17
Tabla 8. Efecto causado por metales ligeros en reactores anaerobios.....	20
Tabla 9. Diferentes estudios con adaptación de biomasa convencional. ....	25
Tabla 10. Reactivos y sus concentraciones en el agua residual sintética .....	31
Tabla 11. Preparación de agua residual sintética a base de vísceras de pescado .....	37
Tabla 12. Comparación de resultados del análisis de DQO en muestras sintéticas a diferentes salinidades mediante una modificación del método norma.....	41
Tabla 13. Funciones de transferencia más utilizadas en RNA.....	66
Tabla 14. Ejemplo de posibles soluciones para un problema cualquiera. ....	71
Tabla 15. Ventajas y desventajas de los algoritmos genéticos. ....	75
Tabla 16. Condiciones de operación y resultados en estudios previos donde se usaron sistemas anaerobios. ....	79
Tabla 17. Condiciones utilizadas en el reactor UASB durante la fase de recolección de datos. .....	84
Tabla 18. Máximos y mínimos de % remoción y biogás producido.....	85
Tabla 19. Valores de parámetros para la mejor RNA encontrada. ....	91
Tabla 20. Propiedades del AG. ....	94
Tabla 21. Grupos de combinaciones propuestas por el AG. ....	97
Tabla 22. Evaluación experimental del modelo de IA basado en AG y RNA. ....	100
Tabla 23. Condiciones experimentales y resultados obtenidos en estudios previos. ....	101

## INDICE DE FIGURAS

Figura 1. Esquema general de las etapas y reacciones ocurridas en la digestión anaerobia. ...	12
Figura 2. Formación de moléculas simples por hidrólisis (Deublein & Steinhauser, 2010). ..	13
Figura 3. Estructura del $\alpha$ -glucosilglicerol. ....	28
Figura 4. Estructura de la N-acetilglutamil-glutmina amida. ....	28
Figura 5. Estructura de la betaína. ....	28
Figura 6. Estructura de la ectoína. ....	29
Figura 7. Tabla de mareas para la ciudad de Mazatlán el día de la toma del sedimento marino. .....	32
Figura 8. Croquis de ubicación del punto de colecta de sedimento marino en la ciudad de Mazatlán. ....	33
Figura 9. Punto de colecta de lodo y condiciones del cuerpo de agua. ....	34
Figura 10. Metodología propuesta para acondicionamiento a alta salinidad. ....	35
Figura 11. Desempeño del reactor en la fase de activación.....	39
Figura 12. Desempeño del reactor frente agua sanitaria adicionada con azúcar. ....	39
Figura 13. Desempeño del reactor en el período de acondicionamiento con agua residual sintética. ....	40
Figura 14. Comportamiento del reactor en el acondicionamiento a agua residual sintética....	42
Figura 15. Acondicionamiento del reactor a alta salinidad. ....	44
Figura 16. Incremento de carga orgánica y eficiencia de remoción. ....	45
Figura 17. Efecto del pH en la eficiencia de remoción.....	46
Figura 18. Efecto de la temperatura sobre la eficiencia de remoción. ....	47
Figura 19. Curvas de producción de biogás a salinidades de 0, 10 y 20 g/L a proporciones lodo/sustrato de: A) 160L/80S, B) 125L/125S y C) 80L/160S.....	48
Figura 20. Desempeño del lodo anaerobio acondicionado: A) DQO inicial y DQO del efluente tratado, B) Remoción de DQO, C) Máxima producción de biogás y D) Rendimiento de producción de biogás.....	49
Figura 21. Bacilos cortos Gram positivos.....	51
Figura 22. Bacilos cortos Gram positivos y Gram negativos. ....	52
Figura 23. Bacilos alargados Gram positivos y Gram negativos, y cocos Gram negativos. ...	52

Figura 24. Bacilos alargados Gram positivos.....	53
Figura 25. Perceptron (Demuth, 2002).....	63
Figura 26. RNA de una capa. ....	64
Figura 27. Arquitectura de una red neuronal multicapa (Demuth, 2002).....	64
Figura 28. Modelo computacional de una neurona. ....	65
Figura 29. Perceptron. ....	67
Figura 30. Ruleta de posibles soluciones creada. ....	72
Figura 31. Cruce en un punto. ....	73
Figura 32. Cruce en dos puntos.....	73
Figura 33. Datos experimentales de OLR, pH, T°C y salinidad; monitoreados durante la experimentación.....	82
Figura 34. Variación del TRH y gasto durante la etapa experimental. ....	83
Figura 35. Valores de DQO de entrada y salida obtenidos durante la experimentación.....	84
Figura 36. Comportamiento de la eficiencia de remoción y la producción de metano durante la experimentación.....	86
Figura 37. Mejor entrenamiento en una RNA con 4 entradas y 2 salidas. A) Ajuste de entrenamiento y B) valor de R para la etapa de prueba de la red. ....	88
Figura 38. Mejor entrenamiento en una RNA con 4 entradas y 1 salida: A) Ajuste de entrenamiento y B) valor de R para la etapa de prueba de la red. ....	88
Figura 39. Mejor entrenamiento en una RNA con 3 entradas y 1 salida función de transferencia tangencial-tangencial: A) Ajuste de entrenamiento y B) valor de R para la etapa de prueba de la red. ....	88
Figura 40. Desempeño del entrenamiento de la RNA con 3 entradas y 1 salida funciones de transferencia tangencial-tangencial. ....	89
Figura 41. Mejor entrenamiento en una RNA con 3 entradas y 1 salida función de transferencia tangencial-logarítmica: A) Ajuste de entrenamiento y B) valor de R para la etapa de prueba de la red. ....	89
Figura 42. Desempeño del entrenamiento de la RNA con 3 entradas y 1 salida y funciones de transferencia tangencial-logarítmica.....	90
Figura 43. Arquitectura de la RNA para predicción del porcentaje de remoción.....	91

Figura 44. Mejor entrenamiento en una RNA con 3 entradas y 1 salida función de transferencia logarítmica-logarítmica: A) Ajuste de entrenamiento y B) valor de R para la etapa de prueba de la red.....	92
Figura 45. Desempeño de la RNA.....	93
Figura 46. Grupos de posibles combinaciones. ....	95
Figura 47. Grupos de combinaciones encontradas a partir del universo de soluciones.....	96
Figura 48. Datos modelados procesados. ....	98
Figura 49. Grupos de combinaciones encontradas después del procesado de datos. ....	99

## **INTRODUCCIÓN GENERAL**

En el presente estudio se propone el uso de un modelo de inteligencia artificial (IA) para la optimización de un sistema de tratamiento anaerobio basado en un reactor anaerobio de flujo ascendente (UASB) que trata un agua residual salobre. Para el uso del modelo de IA fue necesario, en primer lugar, acondicionar un lodo anaerobio a trabajar con alta carga orgánica volumétrica (OLR). Para lo cual se alimentó el reactor inicialmente con agua residual doméstica, seguido de un incremento de la OLR mediante el uso de un agua residual sintética, la cual fue elaborada con una receta reportada por Arango y López (2011).

Después de esta etapa el lodo fue inoculado con un sedimento extraído de un estero ubicado en la ciudad de Mazatlán, Sinaloa. Este estero por años ha recibido la descarga de una planta procesadora de harina de pescado, esta descarga y el hecho de encontrarse en la bahía de Mazatlán, que está bajo la influencia de las mareas, le dan al sedimento marino la cualidad necesaria para el uso de este en el sistema de tratamiento, ya que está provisto de una biomasa capaz de degradar altas cantidades de materia orgánica bajo condiciones de alta conductividad. La aclimatación del lodo se logró después de mezclar en proporción 1:1 un lodo anaerobio convencional y el sedimento marino, seguido de incrementos graduales de salinidad en el agua de alimentación. La salinidad del agua se incrementó hasta llegar a concentraciones por arriba de los 20 g/L.

Después de que el lodo fue acondicionado, se realizaron varios experimentos de manera aleatoria para simular el comportamiento que tendría una descarga de un agua residual industrial real. En estos experimentos se monitorearon los siguientes parámetros: OLR, salinidad, temperatura y su efecto en la producción de biogás y la eficiencia de remoción del sistema de tratamiento anaerobio.

Se hicieron poco más de 50 experimentos, los datos obtenidos a partir de esta experimentación se utilizaron para entrenar una red neuronal artificial, la cual sirvió para simular el comportamiento del reactor UASB bajo condiciones de operación no probadas durante la etapa de experimentación. El modelo de predicción con red neuronal se acopló a otro modelo de inteligencia artificial basado en algoritmos genéticos (modelos basados en la evolución natural de las especies) para encontrar las condiciones óptimas de operación del sistema de tratamiento.



El modelo de inteligencia artificial fue capaz de generar combinaciones de condiciones de operación a ensayar, experimentalmente para evaluar el desempeño del modelo inteligente. La experimentación demostró que el modelo de IA fue capaz de aportar condiciones de operación en las cuales se obtuvo la máxima eficiencia de remoción posible con el uso mínimo de recursos.

Finalmente, los datos obtenidos con el modelo y la experimentación, se compararon con la bibliografía existente. Se encontró que la eficiencia de remoción lograda por el modelo de inteligencia artificial produjo datos comparables con estudios anteriores. Aunque existen algunas variaciones marcadas en las condiciones utilizadas, se justifica la eficiencia lograda por la diferencia que existe entre la temperatura, los tiempos de retención hidráulica y el sustrato utilizado por muchos autores.

## **JUSTIFICACION**

El problema de contaminación ocasionado por la disposición de aguas residuales sin tratar o tratadas en forma deficiente en cuerpos de agua como: esteros, lagos, ríos, arroyos, bahías y mar, provoca problemas ambientales, además de problemas de salud, en el caso de aquellos cuerpos que se encuentran cercanos a zonas urbanas. Esto nos lleva a proponer procesos para la mejora de los sistemas de tratamiento de las aguas residuales. Existe poca información respecto a la depuración de las aguas residuales industriales salobres. Los sistemas de tratamiento biológico son una alternativa viable para el tratamiento de estas aguas residuales. El uso de un sistema biológico previamente acondicionado a estas aguas o el uso de biomasa halofílica permiten una depuración eficiente de estas aguas. Con esta investigación se pretende estudiar la eficiencia lograda por un sistema de tratamiento mediante un Reactor Anaerobio de Flujo Ascendente en el tratamiento de aguas residuales industriales salobres.

Los modelos de optimización para los sistemas de tratamiento de aguas residuales son una herramienta adecuada para comprender el efecto de las variables en la eficiencia de remoción de los contaminantes en estos procesos. Para poder aplicar modelos lineales, semi-empíricos y/o dinámicos, es necesario simplificar algunas variables, suponer valores y tener conocimientos avanzados del sistema que se está estudiando, a pesar de ello, la aplicación de estos modelos da resultados poco precisos. Mediante el uso de modelos de caja negra se puede hacer un modelado y predicción del comportamiento de un proceso, ya que se basan en un determinado conjunto de variables experimentales con las cuales se predice el comportamiento del sistema de tratamiento. Para conocer las condiciones óptimas de operación se requiere de largos y costosos periodos de experimentación para estudiar todas las interacciones no lineales que pueden presentarse. Para ello se utilizará un modelo de optimización con el cual se evaluaré el universo de soluciones y se seleccione solo un pequeño número para evaluarse de manera experimental. Los algoritmos genéticos (AG) son técnicas computacionales diseñadas para resolver problemas de optimización basándose en el proceso de selección natural. En un problema específico, los AG modifican un grupo de soluciones (padres) para crear una nueva generación de soluciones (hijos), este proceso se realiza hasta evolucionar en la solución óptima.

## **HIPOTESIS**

Mediante el uso un modelo de inteligencia artificial, basado en redes neuronales artificiales y algoritmos genéticos, se puede optimizar los parámetros de operación de un reactor anaerobio de flujo ascendente (UASB) para depurar aguas residuales salobres.

## **OBJETIVO GENERAL**

Acondicionar y optimizar un proceso de tratamiento de aguas residuales basado en un reactor UASB para tratar un agua residual salobre con alta carga orgánica, proteínas, grasas y aceites, mediante el uso de redes neuronales artificiales y algoritmos genéticos.

## **OBJETIVOS ESPECÍFICOS**

- Acondicionar un reactor UASB para el tratamiento de aguas residuales salobres.
- Estudiar el proceso anaerobio de tratamiento de agua residual para identificar las variables que afectan la eficiencia de remoción de los contaminantes.
- Generar datos experimentales reales para entrenar un modelo de inteligencia artificial basado en redes neuronales artificiales para la predicción del comportamiento del reactor bajo condiciones experimentales virtuales.
- Acoplar el modelo de inteligencia artificial basado en redes neuronales a un algoritmo genético.
- Aplicar el modelo computacional basado en redes neuronales artificiales y algoritmos genéticos para optimizar el proceso de tratamiento.
- Evaluar experimentalmente la validez del modelo de inteligencia artificial.

**Capítulo 1 Acondicionamiento de un sistema de tratamiento anaerobio basado en reactor anaerobio de flujo ascendente (UASB por sus siglas en inglés) a alta salinidad.**

# 1. INTRODUCCIÓN

## 1.1. Tipos de agua residual y sus características.

Existen diferentes tipos de agua residual, cada una tiene diferentes características las cuales varían de acuerdo a la actividad que la genera, así podemos encontrar:

- Aguas residuales domésticas: derivadas del uso en actividades de limpieza, aseo personal y/o preparación de alimentos. Son generadas en residencias, comercios o instituciones de servicio como: hospitales, escuelas, aeropuertos, hoteles, oficinas, centros comerciales, etc. La concentración de estas aguas se puede clasificar como baja, media o alta. En la **Tabla 1** se enlista la concentración los contaminantes básicos encontrados en estas aguas.

Tabla 1. Concentración típica de contaminantes básicos en aguas residuales domésticas.

Contaminantes	Unidades	Concentración		
		Baja	Media	Alta
SST	mg/L	390	720	1230
DBO	mg/L	110	190	350
DQO	mg/L	250	430	800
Nitrógeno	mg/L	20	40	70
Fósforo	mg/L	4	7	12
Grasas y aceites	mg/L	50	90	100
Coliformes totales	NMP/100ml	$10^6$ - $10^8$	$10^7$ - $10^9$	$10^7$ - $10^{10}$

(Tchobanoglous et al., 2003)

- Aguas residuales agrícolas: Son producto del escurrimiento producido en el riego de cultivos. Generalmente estas aguas terminan en algún cuerpo de agua sin ningún tratamiento previo a su disposición. Los contaminantes encontrados en estas aguas son sólidos suspendidos totales (SST), pesticidas y fertilizantes. En zonas de agricultura intensiva pueden aumentar los niveles de fósforo y nitrógeno en los cuerpos de agua cercanos a las áreas de cultivo.
- Aguas residuales industriales: generadas en cualquier actividad industrial, sus características varían ampliamente en cuanto a caudal y composición. Por ejemplo, las aguas residuales de la industria alimenticia tienen concentraciones elevadas de carga orgánica, grasas y aceites y SST, las aguas residuales de la industria

metalmecánica tienen una elevada concentración de metales pesados, las empresas textiles generan aguas residuales con una elevada concentración de color. El agua de la industria del curtido de piel genera agua residual con altas cargas orgánicas, SST y sales de cromo. En la **Tabla 2** se muestra algunas aguas residuales industriales reportadas en algunos estudios y la concentración de éstas.

Tabla 2. Concentración de contaminantes en algunas aguas residuales industriales.

Autor	Industria generadora	Contaminante y concentración (mg/L)				
		DBO	DQO	NT	PT	SST
Bustillo et al. (2015)	Rastro	150-4,635	500-15,900	50-841	25-200	270-6,400
Fall et al. (2012)	Parque industrial	568	5,459	87	10	-
Ioannou et al. (2015)	Efluente de vinaza	203-22,418	320-49,105	10-415	2.1-280	66-8,600
Meneses-Lácome et al. (2016)	Producción de tequila	600	25,000-120,000	20,000	1,100	40
	Producción de aceite de palma	400-660	35,000-90,000	100-1,500	-	5,000-60,000
	Purín	700	5,000-12,000	70-100	9	2,000
	Producción de etanol	500-600	20,000-65,000	>280	-	-
Qasim y Mane (2013)	Industria lechera*	442	8,960	120	-	253.6
	Dulces*	486.7	9,720	95.2	-	224.7
	Helado*	523.5	11,900	88.51	-	264.8
Vymazal (2014)	Refinería*	10-1000	50-4,000	-	-	10-300
	Destilería*	6,000-65,000	4,000-212,000	7,000	740-2,500	1,000-17,000
	Cervecería*	500-64,000	750-80,000	67-216	17-216	1,000-3,000
	Producción de aceite de oliva*	1,400-150,000	37,000-318,000	1540	410-840	6,000-83,700

\*Valores de nitrógeno total Kjeldhal (NTK).

## 1.2. Tratamiento de agua residual.

El objetivo principal del tratamiento del agua residual es el de remover de ésta la mayor cantidad posible de contaminantes con el fin de poder devolver el agua utilizada al cuerpo original de donde fue tomada sin afectar las condiciones físicas y biológicas de éste. Otra meta es el reúso de la mayor cantidad posible del agua residual generada, por lo que es importante tratar de manera adecuada la matriz problema. Generalmente las normas son las que establecen las características que debe de cumplir el agua residual tratada al final de un

tratamiento. Para elegir de manera adecuada el sistema a utilizar y los procesos que tendrá en este, es necesario tener en cuenta los siguientes factores:

- Disponibilidad de terreno
- Recursos económicos disponibles
- Nivel de tratamiento deseado
- Normas aplicables
- Tipo de agua y sus características.

### 1.2.1. Unidades utilizadas en el tratamiento de aguas residuales.

Las unidades de un sistema de tratamiento tienen diferentes funciones por lo que su utilización y ubicación en el tren de tratamiento definirá la eficiencia del proceso utilizado en la remoción de los contaminantes. Los sistemas de tratamiento convencionales tienen las siguientes unidades:

Unidades de pre-tratamiento: son procesos que nos ayudan a evitar los desechos de gran volumen, a través del uso de rejillas, tamices, desarenadores y micro-filtros, estos impiden el paso de los desechos voluminosos.

Tabla 3. Unidades de pre-tratamiento utilizadas en las plantas de tratamiento de agua residual.

Unidad	Objetivo
Rejillas	Evitar la entrada de objetos voluminosos que causen problemas de funcionamiento en los equipos.
Tamices	Evitar el paso de objetos flotantes finos que provoquen atascamiento en las tuberías.
Desarenadores	Retienen sólidos abrasivos que provocan deterioro en los equipos

**Tratamiento primario:** El objetivo principal es remover materiales que sedimentan en determinado tiempo a través de métodos físicos o fisicoquímicos. La sedimentación se puede obtener cuando se deja en reposo el agua residual, obteniendo así una sedimentación física o bien acelerar el proceso por medio de la adición de sustancias quelantes.

**Tratamiento secundario:** En esta etapa se remueve la mayor cantidad posible de materia orgánica y sólidos sedimentables mediante la aglomeración de éstos. Por lo general se utilizan reactores biológicos en los cuales se crean las condiciones necesarias para que los



microorganismos presentes en el agua residual puedan crecer hasta alcanzar ciertas concentraciones y permitan la remoción de materia orgánica soluble e insoluble presente en el agua residual. Los procesos biológicos pueden ser aerobios o anaerobios.

**Procesos aerobios:** El proceso más común es el proceso de lodos activados, en este los microorganismos se mantienen en suspensión mediante la agitación y oxigenación del medio por medios mecánicos. Mediante el uso de difusores o paletas mecánicas la biomasa suspendida se encuentra en contacto con el agua residual y consume la materia orgánica presente en el agua para realizar sus actividades metabólicas reduciendo así la concentración de los compuestos orgánicos que son medidos mediante demanda bioquímica de oxígeno (DBO), demanda química de oxígeno (DQO) o carbono orgánico total (COT).

**Procesos anaerobios:** Se caracterizan por llevarse a cabo en ausencia de oxígeno. La degradación de los compuestos orgánicos produce cantidades considerables de biogás y pequeñas cantidades de lodo. Estas dos últimas características son los que hacen que estos procesos sean muy utilizados en el tratamiento de aguas residuales industriales con alta carga orgánica. Los procesos más utilizados son:

- Reactor anaerobio de flujo ascendente (UASB por sus siglas en inglés): El lodo se encuentra en el fondo, se obliga un flujo ascendente del agua residual a tratar, al ascender el agua entra en contacto con el manto de lodos donde las comunidades de bacterias, que se encuentran formando flóculos o gránulos, degradan la materia orgánica presente en el agua residual. Como producto de este proceso se produce metano ( $\text{CH}_4$ ), dióxido de carbono ( $\text{CO}_2$ ) y pequeñas cantidades de lodo.
- Reactor anaerobio de mezcla completa: La biomasa se mantiene suspendida mediante agitación por medios mecánicos, esto permite que el agua residual entre en contacto con la biomasa que se encarga de la degradación de los contaminantes. Al igual que en los demás procesos los productos son  $\text{CH}_4$ ,  $\text{CO}_2$  y pequeñas cantidades de lodo.

**Tratamiento terciario:** Consta de varias unidades de tratamiento encargados de remover los contaminantes que permanecen en el agua residual después del tratamiento biológico. Están

enfocados principalmente a la remoción de nutrientes, sales disueltas, metales, organismos patógenos, sólidos coloidales, COV y pesticidas (Mara, 2003; Ramalho, 2003; Tchobanoglous et al., 2003).

Las unidades de tratamiento incluyen una serie de combinaciones de unidades de pre-tratamiento, tratamiento primario, secundario y terciario. Nuevamente las unidades utilizadas dependerán de las características del agua a tratar. En este caso enfocaremos nuestra atención en el proceso anaerobio, específicamente en el reactor UASB.

### **1.3. Digestión anaerobia.**

La digestión anaerobia consiste en la degradación y estabilización de compuestos orgánicos bajo condiciones anaerobias. El proceso se lleva a cabo en ausencia de oxígeno por microorganismos, que como producto de la descomposición de los compuestos orgánicos generan una mezcla de gases, compuestos en su mayoría por CO<sub>2</sub> y CH<sub>4</sub> (**Figura 1**), conocido como biogás. La digestión anaerobia es utilizada actualmente para la descomposición de desechos orgánicos provenientes de la industria alimenticia, enlatado, etc.; desechos orgánicos municipales y agrícolas. Ofrece varias ventajas frente a los sistemas de tratamiento aerobio como: baja producción de lodo, menor consumo de energía y posible generación de energía. Comparado con la contraparte mesofílica, la digestión termofílica permite una mejor estabilización de los residuos tratados, así como la eliminación organismos patógenos como bacterias, virus, protozoarios y helmintos (Chen et al., 2008).

La digestión anaerobia consta de cuatro etapas: hidrólisis, acidogénesis, acetogénesis y metanogénesis. Cada una de estas etapas se lleva a cabo de manera individual por diferentes grupos de microorganismos que forman parte de una relación sintrófica puesto que las poblaciones se benefician con el producto de otras. Las primeras dos etapas, así como las últimas 2 están intrínsecamente relacionadas. Por ello el proceso puede generalizarse en 2 etapas generales. Si la primera etapa se lleva a cabo muy rápido, la proporción de CO<sub>2</sub> en el biogás aumenta ocasionando una disminución del pH, en consecuencia, la segunda etapa se acidifica y reduce la producción de metano. En la primera etapa la capacidad hidrolítica es la variable limitante del proceso, mientras que en la segunda la acetogénesis es la etapa limitante de la degradación de los compuestos y la producción de biogás (Deublein & Steinhauser, 2010).

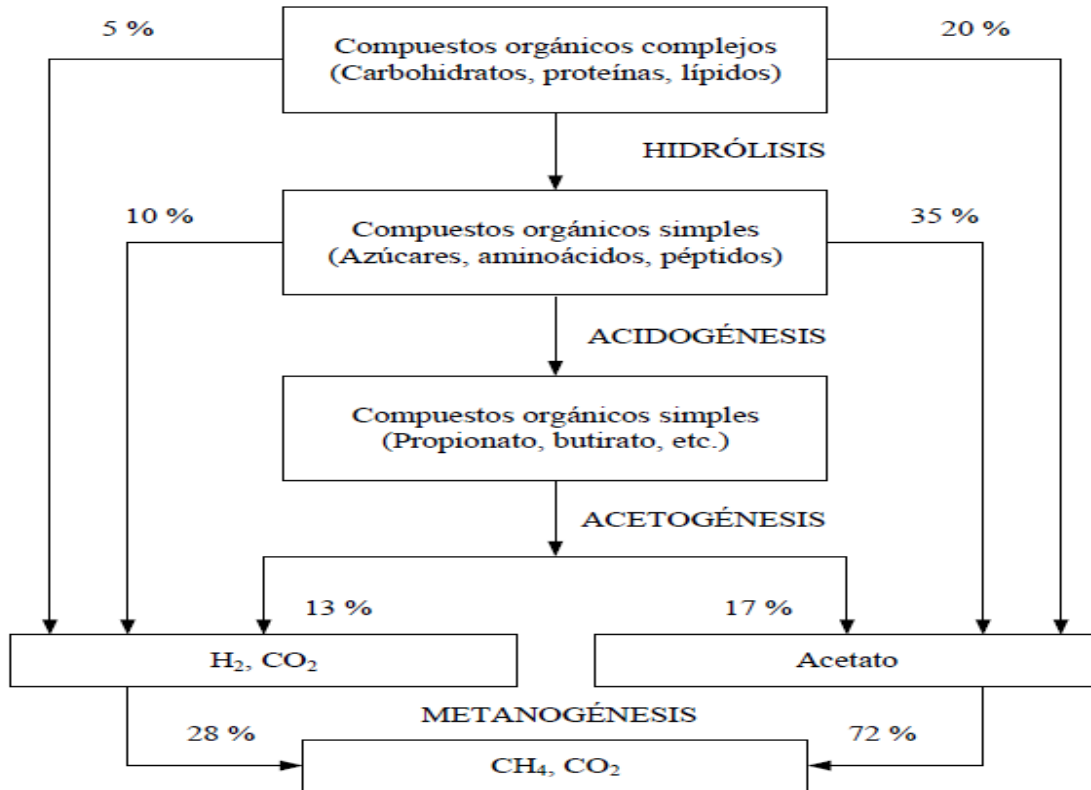


Figura 1. Esquema general de las etapas y reacciones ocurridas en la digestión anaerobia.

### 1.3.1. Hidrólisis.

La hidrólisis es el rompimiento de enlaces de un compuesto en agua. Este proceso lo llevan a cabo las bacterias hidrolíticas, anaerobias facultativas y bacterias anaerobias capaces de hidrolizar. En esta etapa los compuestos insolubles complejos como carbohidratos, lípidos y proteínas son hidrolizados y convertidos a compuestos solubles. Este proceso se logra gracias a la acción de exo-enzimas excretadas por las bacterias (hidrolasas), que actúan en este proceso. Los enlaces covalentes son rotos en una reacción química en presencia de agua (**Figura 2**). En este proceso los carbohidratos son hidrolizados completamente en el transcurso de unas cuantas horas, mientras que las proteínas y los lípidos, logran hidrolizarse por completo en algunos días. Cadenas complejas de carbohidratos como la lignina y la celulosa son degradadas lentamente y se hidrolizan parcialmente. (Gerardi, 2003)




Figura 2. Formación de moléculas simples por hidrólisis (Deublein & Steinhauser, 2010).

### 1.3.2. Acidogénesis

En esta etapa los productos generados en la hidrólisis son degradados a ácidos orgánicos de cadena corta (de 1 a 5 carbonos). Intervienen principalmente bacterias anaerobias facultativas y bacterias anaerobias. Los productos de esta etapa son: ácido propiónico, butírico, acético, acetato, alcoholes, hidrógeno y CO<sub>2</sub>. El compuesto más importante generado en esta etapa es el ácido acético. Es el principal compuesto utilizado por las bacterias formadoras de metano. Parte del CO<sub>2</sub> y el hidrógeno formado también pueden ser convertidos a acetato. En esta etapa la concentración de ácidos orgánicos se ve afectada por la presencia de iones intermediarios de hidrógeno. Mientras exista una presión de hidrógeno mayor, la cantidad de compuestos simples como el acetato es más baja. Algunas rutas metabólicas que ocurren en esta etapa se muestran en la **Tabla 4**.

Tabla 4. Rutas metabólicas presentes en la acidogénesis.

Compuesto	Degradación
Ácido propiónico	$CH_3(CH_2)COOH + 2H_2O \rightarrow CH_3COOH + CO_2 + 3H_2$
Ácido butírico	$CH_3(CH_2)_2COO^- + 2H_2O \rightarrow 2CH_3COO^- + H^+ + 2H_2$
Ácido valérico	$CH_3(CH_2)_3COOH + 2H_2O \rightarrow CH_3COO^- + CH_3COO^- + CH_3CH_2COOH + H^+ + 2H_2$
Ácido isovalérico	$(CH_3)_2CHCH_2COO^- + HCO_3^- + H_2O \rightarrow 3CH_3COO^- + H^+ + H_2$
Ácido caprónico	$CH_3(CH_2)_4COOH + 4H_2O \rightarrow 3CH_3COO^- + H^+ + 5H_2$
CO <sub>2</sub> /hidrógeno	$2CO_2 + 4H_2 \rightarrow CH_3COO^- + H^+ + 2H_2O$
Glicerina	$C_3H_8O_3 + H_2O \rightarrow CH_3COOH + 3H_2O + CO_2$
Ácido láctico	$CH_3CHOHCOO^- + 2H_2O \rightarrow CH_3COO^- + HCO_3^- + H^+ + 2H_2$
Etanol	$CH_3(CH_2)OH + H_2O \rightarrow CH_3COOH + 2H_2$

(Deublein & Steinhauser, 2010)

La degradación de los compuestos formados (ácidos grasos, azúcares y aminoácidos) ocurre mediante los siguientes procesos:

- Degradación de carbohidratos: Mediante la formación de ácido propiónico por bacterias propiónicas, mediante la vía del succinato; formación de ácido butírico por *Clostridium*; formación de butanol a partir de ácido acético.
- Ácidos grasos: son degradados por acetobacter mediante la  $\beta$ -oxidación. La co-enzima A está ligada al ácido graso, la degradación es escalonada. En cada etapa, dos carbonos son separados de la molécula en forma de acetato.
- Aminoácidos: son degradados mediante la reacción de Stickland por la bacteria *Clostridium botulinum*. Esta bacteria usa dos aminoácidos al mismo tiempo, donde uno actúa como donador de electrones y el otro como aceptor. La degradación de estos compuestos produce como resultado amoníaco, acetato,  $\text{CO}_2$  y sulfuro de hidrógeno.

(Deublein & Steinhauser, 2010; Gerardi, 2003)

### 1.3.3. Acetogénesis

Es la etapa siguiente de la acidogénesis. En el caldo de compuestos orgánicos nitrogenados, alcoholes y ácidos orgánicos, existen compuestos que pueden ser utilizados directamente por las bacterias metanogénicas para la formación de metano, pero también existen compuestos que pueden ser utilizados de manera indirecta para la degradación de algunos compuestos a acetato por la acción de bacterias fermentativas. Es una etapa que se lleva a cabo de manera simbiótica entre las bacterias acetogénicas y metanogénicas. Esto ocurre debido a que las bacterias acetogénicas son productoras de  $\text{H}_2$ , resultado de la oxidación de ácidos orgánicos de cadena larga (ácido propiónico o butírico). Esta degradación puede ocurrir solamente a presiones parciales de  $\text{H}_2$  bajas, es decir a concentraciones bajas de  $\text{H}_2$ . Debido a que la cantidad de  $\text{H}_2$  se acumula, es necesario reducirla pues de lo contrario este proceso será inhibido. Las bacterias metanogénicas solo pueden sobrevivir en presiones parciales de  $\text{H}_2$  elevadas y, en consecuencia, estos organismos remueven los metabolitos generados por los microorganismos acetogénicos, manteniendo las concentraciones de  $\text{H}_2$  bajas.

Cuando la presión de  $\text{H}_2$  es baja los compuestos predominantes son  $\text{H}_2$ ,  $\text{CO}_2$  y acetato, pero al aumentar la presión de  $\text{H}_2$ , aumenta la concentración de ácidos orgánicos como: butírico, capríónico, propiónico y valérico, así como etanol. De todos estos compuestos, los organismos formadores de metano solo pueden utilizar el acetato,  $\text{H}_2$  y  $\text{CO}_2$ . La degradación de ácidos grasos volátiles y etanol es llevada a cabo principalmente por los organismos metanogénicos

que a cambio reciben los sustratos necesarios para su desarrollo de las bacterias acetogénicas (Deublein & Steinhauser, 2010; Gerardi, 2003).

### 1.3.4. Metanogénesis

Es el paso final de la digestión anaerobia, el principal producto de interés de esta etapa es el CH<sub>4</sub> formado en su mayoría a partir de acetato, H<sub>2</sub> y CO<sub>2</sub>. Además de estos compuestos las bacterias metanogénicas utilizan algunos compuestos con dos átomos de carbono (Zambrano, 2012). No todas las bacterias degradan todos los sustratos disponibles, por lo tanto, las bacterias metanogénicas se clasifican de acuerdo al tipo de sustrato que utilizan (**Tabla 5**).

Tabla 5. Grupos de organismos metanogénicos y reacciones que llevan a cabo.

Grupo	Sustrato utilizado	Reacción
Consumidora de CO <sub>2</sub>	CO <sub>2</sub> , HCOO <sup>-</sup> , CO	4H <sub>2</sub> + HCO <sub>3</sub> <sup>-</sup> + H <sup>+</sup> → CH <sub>4</sub> + 3H <sub>2</sub> O
		CO <sub>2</sub> + 4H <sub>2</sub> → CH <sub>4</sub> + 2H <sub>2</sub> O
Consumidora de metil	CH <sub>3</sub> OH, CH <sub>3</sub> NH <sub>3</sub> , (CH <sub>3</sub> ) <sub>2</sub> NH <sub>2</sub> <sup>+</sup> , (CH <sub>3</sub> ) <sub>3</sub> , NH <sup>+</sup> , CH <sub>3</sub> SH, (CH <sub>2</sub> ) <sub>2</sub> S	4CH <sub>3</sub> OH + H <sub>2</sub> O → CH <sub>4</sub> + 3HCO <sub>3</sub> <sup>-</sup> + H <sup>+</sup> + H <sub>2</sub> O
		CH <sub>3</sub> OH + H <sub>2</sub> → CH <sub>4</sub> + H <sub>2</sub> O
		2CH <sub>3</sub> CH <sub>2</sub> OH + CO <sub>2</sub> → CH <sub>4</sub> + 2CH <sub>3</sub> COOH
Consumidora de acetato	CH <sub>3</sub> COO <sup>-</sup>	CH <sub>3</sub> COO <sup>-</sup> + H <sub>2</sub> O → CH <sub>4</sub> + HCO <sub>3</sub> <sup>-</sup>

(Deublein & Steinhauser, 2010)

En un reactor anaerobio la mayoría del CH<sub>4</sub> que se forma (cerca del 70%) es vía oxidación del ácido acético, mientras que el resto se forma mediante la reducción del CO<sub>2</sub> y el H<sub>2</sub>. La metanogénesis puede verse afectada cuando las bacterias acetogénicas tienen una simbiosis con otro tipo de bacterias diferentes a las metanogénicas. Por ejemplo, se puede formar una simbiosis con bacterias sulfato-reductoras (bacterias formadoras de H<sub>2</sub>S), sí esto ocurre estas bacterias consumen el H<sub>2</sub> generado por las bacterias acetogénicas, ocasionando una reducción en la concentración y presión de H<sub>2</sub>, reduciendo la disponibilidad para las bacterias metanogénicas y en consecuencia la generación de CH<sub>4</sub> (Deublein & Steinhauser, 2010). En esta etapa el factor limitante en la degradación de compuestos rápidamente biodegradables es la velocidad de formación de acetato.

#### 1.4. Parámetros de control.

Debido a que los sistemas de tratamiento biológico son unidades que contienen una población muy diversa de microorganismos, los cuales tienen una relación muy estrecha unos con otros, las condiciones de operación deben ser estrictamente controladas, de lo contrario el sistema puede llegar a tener fallas importantes como una baja producción de biogás o una reducción en la eficiencia de remoción de contaminantes, condiciones que pueden mantenerse durante 2 o 3 semanas debido a la baja actividad metabólica que tiene el sistema. Es importante entonces, en los sistemas de tratamiento anaerobio, mantener ciertos parámetros en un rango de operación que permite la correcta operación de un sistema de tratamiento de este tipo. Los parámetros a controlar en estos sistemas son: pH, temperatura, ácidos grasos volátiles, alcalinidad, relación Carbono, Nitrógeno, Fósforo y Azufre (C:N:P:S) contenido de materia seca, potencial redox, micro-nutrientes, entre otros (**Tabla 6**).

Tabla 6. Parámetros básicos de control en un proceso anaerobio.

Parámetro	Rango
Alcalinidad	1000-3000 (mg/L)
Temperatura	25-35°C
pH	6.6-7.6
Ácidos volátiles	50-200 (mg/L)
Relación C:N:P:S	500:15:5:3
Potencial Redox	+400 a -300mV
Materia seca	<30-40%
Trazas de elementos	Ni, Co, Mo, Se

(Deublein & Steinhauser, 2010; Gerardi, 2003)

#### 1.5. Tóxicos inhibidores del proceso de tratamiento anaerobio.

Además de los parámetros básicos de control, existen compuestos que inhiben la actividad de las bacterias anaerobias y que es necesario controlarlos. Debido a que existe una relación muy estrecha entre las bacterias acidogénicas y metanogénicas. Dado que estos dos grupos de bacterias difieren mucho en su fisiología, requerimientos de sustrato, cinéticas de crecimiento y necesidades ambientales. El no mantener las condiciones necesarias para el crecimiento balanceado de estos dos grupos de microorganismos es la principal causa de la caída de eficiencia de un reactor anaerobio. El principal causante de una baja calidad en el efluente, la mayoría de las veces, es la presencia de sustancias tóxicas (Chen et al., 2008). Existen

sustancias que son necesarias en bajas concentraciones para el correcto crecimiento de la biomasa en un reactor anaerobio, pero en concentraciones elevadas pueden causar inhibición de algunas etapas del proceso y en consecuencia una caída en la producción de metano o una baja calidad del efluente (Tchobanoglous et al., 2003). En la **Tabla 7** se muestran algunas sustancias, iones o compuestos orgánicos tóxicos para los microorganismos anaerobios.

Tabla 7. Compuestos tóxicos y concentraciones inhibitorias en el proceso de digestión anaerobia.


Compuesto	Concentración (mg/L)
Compuestos inorgánicos	
Amoniacó	1500-3000
Arsénico	1.6
Boro	2
Cadmio	0.02
Calcio	2500-4500 (8000)*
Cobre	1-10 (50-70)*
Cromo ( $Cr^{6+}$ )	5-50 (200-250)
Cromo ( $Cr^{3+}$ )	180-420
Cianuro	4
Hierro	5
Magnesio	1000-1500 (3000)*
Níquel	30
Potasio	2500-4500 (12000)*
Sodio	2500-5500 (8000)*
Sulfuro	50 (200)*
Zinc	5-20
Compuestos orgánicos	
Alcohol alilo	100
Alcohol octilo	200
Acrido-nitrilo	5
Bencidina	5
Cloroformo	10-16
Tetracloruro de carbono	10-20
Cloruro de metileno	100-500
1, 1, 1-Tricloroetano	1
Triclorofluorometano	20
Triclorofluoroetano	5

\*Altamente inhibitorio. (Gerardi, 2003; Tchobanoglous et al., 2003)



### 1.5.1. Amoníaco

Se produce principalmente por la biodegradación de compuestos nitrogenados (proteínas, aminoácidos y urea) presentes en el agua residual. De acuerdo a Tchobanoglous et al. (2003) la cantidad de amoníaco producido a partir de la biodegradación anaerobia se define por la **Ecuación 1.**



Ecuación 1. Producción de amoníaco

Existen varios mecanismos de inhibición por amoníaco en procesos anaerobios, cada uno de los casos se toman en cuenta además de la concentración de nitrógeno (amonio o amoníaco) otros factores como: sustrato, condiciones ambientales (temperatura, pH), presencia de otros compuestos tóxicos, etc. Se sugiere que la principal causa es debido a la capacidad hidrofóbica de la molécula de amonio ( $NH_4^+$ ) que puede difundirse pasivamente hacia dentro de la célula y provocar un desbalance de protones o provocar una deficiencia de potasio (Chen et al., 2008).

Las bacterias más sensibles a la toxicidad por amoníaco son los metanogénicos, mientras que los microorganismos acidogénicos son los más tolerantes. Existen factores que pueden controlar la inhibición por amoníaco como: concentración, pH, temperatura, presencia de otros iones ( $Ca^+$ ,  $Na^+$  y  $Mg^+$ ) y aclimatación (Chen et al., 2008).

### 1.5.2. Sulfuros.

Como se mencionó en la sección 1.3.4, existe una simbiosis entre las bacterias metanogénicas y acetogénicas. Esta simbiosis se ve afectada cuando existe una concentración elevada de sulfatos, ya que existen bacterias sulfato-reductoras que cuales compiten con los microorganismos metanogénicos, consumiendo el hidrógeno generado por las bacterias acetogénicas y generando sulfuro ( $H_2S$ ), disminuyendo la cantidad de metano producido por tres vías: la reducción de sustrato disponible, inhibición de las bacterias metanogénicas por la caída de presión de  $H_2$  y finalmente por inhibición debido a la caída del pH a causa del  $H_2S$  generado (Chen et al., 2008; Gerardi, 2003).

### **1.5.3. Metales pesados.**

Normalmente, se encuentran en concentraciones bajas en el agua residual municipal. Los metales de principal importancia son el hierro, cromo, cobalto, cobre, cadmio, níquel y zinc. En comparación con otras sustancias en el agua residual, estos compuestos no son biodegradables. El principal efecto tóxico de los metales pesados en las bacterias es la disrupción de procesos enzimáticos mediante la unión con grupos tioles y otros grupos en proteínas o mediante el reemplazo de metales presentes en las enzimas.

Las bacterias están constituidas de metales pesados, pero en concentraciones bajas, la composición de estos metales en orden descendente es de:  $Fe \gg Zn \geq Ni > Co = Mo > Cu$ . Entonces la capacidad tóxica de los metales pesados estará en función de: la concentración del metal en el medio, forma química en que se encuentre, el pH y el potencial redox. A pesar de que se cree que los organismos acidogénicos son más resistentes a la toxicidad por metales que aquellos metanogénicos. Se ha especulado sobre una afectación mayor en bacterias acidogénicas al adicionar de manera pulsada concentraciones elevadas de metales pesados (Gerardi, 2003).

### **1.5.4. Compuestos orgánicos tóxicos.**

En la **Tabla 7** se mostró algunos compuestos orgánicos tóxicos para los procesos anaerobios. El proceso anaerobio puede verse inhibido por un número mayor de estos compuestos. Los compuestos orgánicos tóxicos se pueden acumular en el lodo. Debido a que en su mayoría son compuestos no polares, se acumulan en la membrana bacteriana, causando un hinchamiento y fugas llevando eventualmente a la lisis de la célula.

La toxicidad de estos contaminantes varía ampliamente para algunos compuestos tóxicos. Esta toxicidad dependerá principalmente de: la concentración, concentración de biomasa, tiempo de exposición al contaminante, edad de la célula, patrón de alimentación, acondicionamiento y temperatura. En concentraciones bajas estos contaminantes pueden ser biodegradados por los microorganismos, pero conforme la concentración aumenta la inhibición del proceso se hace más evidente. Si se tienen grandes concentraciones de biomasa, el reactor puede trabajar de manera estable. Si la concentración de biomasa es menor, la biomasa joven soporta mejor la toxicidad por compuestos tóxicos (Chen et al., 2008).

### 1.5.5. Sodio, potasio, magnesio, calcio, aluminio (*Na, K, Mg, Ca y Al*)

Estos compuestos metálicos en general causan una plasmólisis de las células. Además, están asociados con la presencia de sales. Estos iones metálicos son necesarios para el crecimiento de las células microbianas, por lo tanto, en concentraciones adecuadas estimulan el correcto crecimiento de estas células, mientras que, en concentraciones elevadas, pueden inhibir su crecimiento. En la **Tabla 8**, se muestra el efecto que puede causar cada uno de estos compuestos metálicos a los microorganismos anaerobios.

Tabla 8. Efecto causado por metales ligeros en reactores anaerobios.

Compuesto	Efecto
Sodio	En concentraciones de 8.0 g/L causa toxicidad en bacterias degradadoras de ácidos grasos volátiles, ácido acético y metanógenas. La aclimatación, presencia de solutos compatibles como potasio, calcio, magnesio y betaína mejora el desempeño de reactores anaerobios con alta concentración de sodio.
Potasio	Causa un flujo pasivo hacia el interior de la célula, neutralizando el potencial de la membrana. Su efecto es más notorio en organismos termofílicos. La presencia de bajas cantidades $Na^+$ , $Mg^+$ y $NH_4^+$ inhibe el efecto tóxico del potasio. Siendo el $Na^+$ el principal inhibidor de su efecto tóxico.
Aluminio	Compite con hierro ( <i>Fe</i> ) y manganeso ( <i>Mn</i> ), se puede adherir a la pared celular. Disminuye la actividad acetogénica y metanogénica. Su efecto se puede disminuir si existe una aclimatación previa.
Magnesio	Lisis en bacterias y disminución de la actividad acetoclástica.
Calcio	Causa precipitación de fósforo ( <i>P</i> ) y carbonato ( $CO_3$ ) lo que produce azolve en reactores y taponamiento de tuberías. Reducción de actividad metanogénica. Pérdida de la capacidad buffer y nutrientes del reactor.

(Chen et al., 2008)

### 1.5.6. Inhibición por presencia de sales.

La principal preocupación de inhibición por sales es causada por la presencia de altas cantidades de cloruro de sodio (*NaCl*) en el agua residual (Kapdan & Boylan, 2009). La sal está presente en el agua residual debido a muchos factores: el uso de aguas salobres en el abastecimiento de servicios básicos, infiltración de agua de mar en el drenaje, uso en procesos industriales, etc. En el caso del agua residual industrial, los procesos con mayor volumen generado son: industria alimenticia, extracción de petróleo, farmacéutica y procesamiento de piel (Lefebvre & Moletta, 2006). En los sistemas de tratamiento de agua residual la sal tiene diferentes efectos. La eficiencia de estos procesos decae frente a altas concentraciones de sal

en sistemas aerobios, ya que el principal efecto es la reducción de la capacidad respirométrica de las bacterias, mientras que en los procesos anaerobios, el principal efecto es la inhibición de la metanogénesis a concentraciones de sal mayores a 10 g/L (Chowdhury et al., 2010).

## **2. ANTECEDENTES.**

El volumen de agua residual salobre representa el 5% del volumen total de agua residual generada a nivel mundial (Lefebvre et al., 2007). Este volumen es una cantidad considerable, además de que la regulación de las descargas de estas aguas, así como la cantidad de contaminantes que contienen, han generado que poco a poco el tratamiento de este tipo de aguas residuales haya ganado más interés entre los investigadores. Además de la alta carga contaminante, estas aguas tienen cantidades considerables de sal, que en concentraciones elevadas resulta inhibitorio para los procesos biológicos convencionales (Lefebvre et al., 2006). Los procesos físico químicos son una opción viable para el tratamiento de estas aguas, pero su implementación requiere de costos elevados de instalación, construcción y mantenimiento. Algunas investigaciones se centran en el uso de sistemas biológicos de tratamiento donde se utilizan períodos de aclimatación, consorcios bacterianos halófilos o el uso de sedimentos marinos para lograr una buena eficiencia de tratamiento de este tipo de aguas (Lefebvre & Moletta, 2006). En cuanto a la determinación de la carga contaminante, existen algunos estudios que utilizan un exceso de sulfato de mercurio ( $\text{HgSO}_4$ ) para inhibir el exceso positivo causado por los cloruros (Kayaalp et al., 2010; Vyrides & Stuckey, 2009).

### **2.1. Medición de DQO en muestras con alta salinidad.**

El método para la determinación de DQO es ampliamente usado para estimar la cantidad de carga orgánica que hay en una muestra de agua residual. Una de las complicaciones que encontramos en el análisis de aguas residuales con alta concentración de cloruros, es la interferencia por cloruros (Kayaalp et al., 2010). Para evitar esta interferencia, algunos autores evaluaron una modificación del método establecido por Clesceri (2012). Kayaalp et al. (2010) y Vyrides y Stuckey (2009) en su estudio presentaron diferentes propuestas que consistían en modificar la proporción del  $\text{HgSO}_4$  en los tubos para anular el efecto en la medición causado por los cloruros presente en las muestras analizadas. Probaron salinidades de 20 y 40 g NaCl/L (Vyrides & Stuckey, 2009) y varias concentraciones de mg  $\text{Cl}^-$ /L que van de 2,500 a 10,000 (Kayaalp et al., 2010). El  $\text{HgSO}_4$  agregado varió según: la concentración de DQO analizada y la salinidad del agua. Los mejores resultados se obtuvieron en muestras cuya proporción  $\text{HgSO}_4$ :  $\text{Cl}^-$  fue de 10:1 y 20:1

## **2.2. Acondicionamiento de sistemas de tratamiento a diferentes salinidades**

El uso de biomasa adaptada a condiciones salobres es importante para el sistema de tratamiento, ya que de esto dependerá la eficacia del mismo (Omil et al., 1995). Algunos autores sugieren que el incrementar gradualmente la sal del agua tiene efectos positivos en la biomasa (Chowdhury et al., 2010; Kimata-Kino et al., 2011; Luo et al., 2013). Estas estrategias de adaptación se han ensayado en aguas con diferente salinidad. Luo et al. (2013) utilizaron incrementos graduales de sal de  $0.26 \pm 0.15$  g/L para adaptar un sistema biológico a una salinidad de 10.5 g/L, la eficiencia de un reactor anaerobio por lotes se mantuvo por arriba del 90%, la producción de metano decayó totalmente cuando la salinidad del agua alcanzó una concentración de 8.7 g/L. Kimata-Kino et al. (2011) ensayaron varias estrategias en conjunto, como incrementos graduales y abruptos de salinidad en diferentes reactores. En aquellos reactores donde la salinidad fue incrementada gradualmente, la eficiencia se mantuvo por arriba del 90% a salinidades de 50 g/L, a salinidades mayores hubo resultados no favorables. En cuanto a la tasa de producción de metano a 50 g/L cayó de 5.8 g DQO/L.d hasta 3.5 g DQO/L.d. Los incrementos en este experimento fueron duplicando la salinidad cada semana. En otro reactor la salinidad se incrementó de 0-40 g/L de manera lineal. A salinidades menores de 35 g/L la eficiencia de remoción se mantuvo en 79%. A salinidades mayores de 40 g/L la máxima eficiencia alcanzada fue de 62%. En cuanto a la tasa de producción de biogás a salinidades menores de 35 g/L se alcanzó una producción de 7.5 g DQO/L.d, cantidad que disminuyó hasta 3.0 g DQO/L.d a salinidades mayores a 40 g/L. Es posible entonces acondicionar un sistema de tratamiento biológico convencional para tratar agua residual salobre al incrementar gradualmente la salinidad, pero tal como reporta Kimata-Kino et al. (2011) la eficiencia de adaptación varía según la metodología utilizada, el período de adaptación con esta metodología es largo.

Otra forma de adaptar la biomasa de un reactor convencional a cantidades considerables de sal y en periodos más cortos es mediante el incremento abrupto de salinidad. El incremento abrupto no causa ningún efecto inhibitorio en las poblaciones bacterianas debido a que existe una concentración limitante. Es necesario conocer este valor, de esta manera la concentración de sal puede incrementarse de manera abrupta. Una vez alcanzado el valor limitante, el

acondicionamiento de la biomasa a valores más elevados debe ser de manera gradual (Kimata-Kino et al., 2011).

Con una metodología similar se pudo adaptar un consorcio bacteriano a tratar un agua con una concentración de sal de 20 g/L sin tener ningún efecto inhibitorio significativo en la producción de biogás. Este efecto se logró al incrementar y mantener la salinidad de un agua residual sintética a 20 g/L, durante un período cercano a las 250 h, seguido de un periodo de exposición a salinidad 0 de 350 h, el procedimiento se repitió 2 veces y al someter el sistema por tercera vez a una salinidad de 20 g/L de sal, se alcanzó la misma producción de biogás que un proceso convencional a las 142 h. Se aplicó la misma metodología para agua residual sintética con salinidades de 30, 40 y 50 g/L, estas concentraciones resultaron ser inhibitorias (Stuckey, 2009). Kimata-Kino et al. (2011) obtuvieron el mismo resultado al incrementar la salinidad de 0 a 20, 30, 35, 40, 45 y 50 g/L. A una salinidad de 20 g/L la eficiencia de remoción decayó con el incremento, pero se recuperó y se mantuvo durante 50 días de operación por arriba del 90% y una tasa de producción de biogás entre 5.1 y 14.8 g DQO/L.d. Para salinidades mayores o iguales a 30 g/L la eficiencia de remoción se mantuvo en valores por debajo del 71% mientras que la tasa de producción de biogás por debajo de 1.0 g DQO/L.d.

Otros autores reportan diferentes estrategias de adaptación para acondicionar un sistema de tratamiento convencional a condiciones salinas. En la **Tabla 9** se muestra una recopilación de autores que utilizan esta metodología y los resultados obtenidos, así como las características del agua tratada.

Tabla 9. Diferentes estudios con adaptación de biomasa convencional.

Autor	Metodología de adaptación	Características del agua residual	Resultados
Prasertsan et al. (1994)	Incremento gradual	DQO=47 g/L, NT=0.456 g/L, PT=0.043 g/L Salinidad=0.5-4 g/L	Hasta 75% de eficiencia de remoción de DQO.
Boardman et al. (1995)	Incremento gradual	DQO=1.7 g/L, NTK=0.22 g/L, PT= 0.04 mg/L, Salinidad: 7.7-26.3 g/L	Hasta 77% de remoción de DQO
Omil et al. (1995)	Incremento gradual	DQO=12.36-55.9 g/L, Proteína=3.34-19.2 g/L, Salinidad=8-19 g/L	Eficiencias entre el 70 y 90% después del periodo de adaptación
Guerrero y Omil (1997)	Incremento gradual	DQO=10.4-34 g/L, N-NH <sub>4</sub> =0.4-1.1 g/L, Proteína=1.3-1.1 g/L, Salinidad: 7.5 g/L	Reducción de DQO arriba del 80%
Panswad y Anan (1999)	Incremento gradual	DQO=0.5 g/L, NT= 0.025 g/L y P= 0.015 g/L. Salinidad: de 0-30 g/L	Eficiencia de remoción de 68% a salinidad de 30 g/L
Lefebvre et al. (2007)	Incremento gradual	Lorg=0.5-4.9 Kg DQO/m <sup>3</sup> .d, salinidad: 0-60 g/L	A salinidad de 10 g/L, remoción de DQO del 93.9%.
Aloui et al. (2009)	Incremento gradual	DQO=3.4 g/L, NT=0.335 g/L Salinidad= 10-60 g/L	Hasta 97% de eficiencia de remoción a salinidad de 4%
El-sheikh et al. (2011)*	Incremento gradual	DQO=11 g/L, N-NH <sub>4</sub> =1.02 g/L	Hasta 90% de remoción.
Li et al. (2014)	Incremento abrupto	DQO=4.05 g/L, SO <sub>4</sub> =1.8 g/L, Salinidad:4-28 g/L	Eficiencia de remoción de 92.5% a salinidad de 12 g/L, de 78% a 16 g/L y de 52% a 28 g/L de salinidad

\*No se reportan valores de salinidad, sin embargo, se menciona un contenido considerable de sal en el agua problema.

### 2.3. Uso de biomasa halófila o halotolerante

Algunos autores han optado por el uso de consorcios bacterianos puros o biomasa ya acondicionada para el tratamiento de aguas residuales salobres, esto permite reducir el período de aclimatación. El uso de consorcios bacterianos ya adaptados maximiza la eficiencia de remoción frente al agua residual problema. Otros autores utilizaron consorcios bacterianos aislados a partir de un cultivo hecho mediante un muestreo microbiológico en el efluente a tratar. Abou-Elela et al. (2010) aislaron un microorganismo halotolerante identificado como



*Staphylococcus xylosus* a partir de un agua residual generada en el enlatado de pepinillos, cuya salinidad alcanzaba los 72 g/L. Con este microorganismo inocularon 2 reactores, uno en el cual se utilizó un lodo aerobio convencional y la cepa en partes iguales, otro reactor inoculado solo con la cepa pura y un reactor más inoculado solo con el lodo convencional. Al comparar el desempeño de los 3 reactores encontraron: a salinidades de 10 g/L los tres reactores se comportaron de manera similar. Al incrementar la salinidad a 20 y 30 g/L, la eficiencia de remoción se mantuvo por arriba del 90% en los reactores inoculados con *S. xylosus*, mientras que en el lodo convencional la eficiencia cayó hasta el 74% a una salinidad de 20 g/L. La eficiencia de remoción se mantuvo en 88% a salinidades de 72 g/L en el reactor inoculado con la cepa halotolerante.

En otro estudio el uso de un inóculo previamente adaptado para el tratamiento de agua salobre, dio buenos resultados en el tratamiento de agua residual con aminas y salinidades de hasta 70 g/L utilizando tiempos de reacción de 120 h (Campo et al., 2011). Es posible aislar bacterias halófilas de ambientes extremos. Paniagua et al. (2004) aislaron bacterias halófilas a partir de tanques de desalinización que contenían como fuente de carbono gasóleo. Las bacterias aisladas son capaces de degradar hidrocarburos. Los cultivos bacterianos halófilos son eficaces en el tratamiento de aguas residuales con alta salinidad. Al utilizar un cultivo de *Halanaerobium lacusrosei* se puede obtener buenas eficiencias de remoción en el tratamiento de un agua residual sintética con salinidades entre 30 y 100 g/L (Kapdan & Boylan, 2009).

El uso de cultivos puros tiene como limitante una baja biodiversidad en el sistema, algunos estudios centrados en el uso de cepas para el tratamiento de agua residual salina no tuvieron resultados satisfactorios. Kargi y Dincer (1997) utilizaron como principal organismo *Zooglea ramigera* para tratar un agua residual sintética hecha a partir de melaza, sales de nitrógeno y sulfato. La salinidad del agua residual sintética varió entre 0 y 50 g/L, la eficiencia de este sistema alcanzó el 60% a salinidades de 50 g/L. Para evitar el problema de la biodiversidad se ha estudiado el efecto de un sistema de tratamiento inoculado con varias cepas, utilizando *Acinetobacter sp.*, *Nitrosomonas*, *Nitrobacter* y *Acinetobacter calcoaceticus*, para tratar agua residual salina con intervalos de salinidad entre 0 y 60 g/L, se encontró que la eficiencia de remoción cae considerablemente a salinidades de 30 g/L (Uygur & Kargi, 2004).

El uso de biomasa ya adaptada es una opción viable como inóculo en el tratamiento de aguas residuales salobres (Lefebvre et al., 2006; Aspé et al., 2008; Mosquera-Corral et al., 2001). También es posible utilizar un sedimento marino como inóculo (Vidal et al., 1997). El uso de sedimento marino como inóculo debe de cumplir con ciertas características al momento de su recolección (Das, 2011).

#### **2.4. Estudios sobre la presencia de bacterias halófilas o halotolerantes en muestras de agua.**

Algunas especies de bacterias se pueden encontrar en ambientes con baja salinidad, pero al mismo tiempo, estas mismas especies se pueden encontrar en ambientes con salinidades que superan los 200 g/L (Kunte, 2013; Russell, 1989; Shivanand & Mugeraya, 2011). Los organismos halófilos son aquellos que dependen de la presencia de altas concentraciones de cloruros en el agua. (Russell, 1989). Se ha estudiado la dependencia de algunas especies de bacterias al ion  $\text{Cl}^-$  para su crecimiento. Se encontró que en concentraciones bajas (5.8g/L), estas especies necesitan de ciertas concentraciones del ion para su óptimo crecimiento. También se encontró que pueden crecer a concentraciones de sal de 5.8, 23.2, 46.4 70.2 y cerca de 90 g/L. Entre las bacterias estudiadas podemos encontrar *Vibrio*, *Pseudomonas*, *Staphylococcus*, entre otras (Roebler et al., 2003).

La capacidad de crecimiento de estos microorganismos en medio salino se debe a 2 mecanismos de adaptación llamados: mecanismo “*salt-in*” y “osmolito regulador” (Kunte, 2013; Oren, 2002; Shivanand and Mugeraya, 2011; Zahran, 1997). El mecanismo “*Salt-in*” consiste en incrementar la presión osmótica dentro del citoplasma mediante la acumulación de cloruro de potasio (KCl). Este mecanismo solo se ha visto en un grupo de bacterias llamado *Halanaerobiales*. Este grupo consiste principalmente en bacterias fermentativas y homoacetogénicas (Oren, 2002).

El otro mecanismo denominado “osmolito regulador”, consiste en la exclusión total de sales dentro del citoplasma. En vez de ello se acumulan solutos orgánicos para equilibrar la presión osmótica. Los compuestos más utilizados van desde azúcares, glicerol, amino-ácidos y algunos derivados de estos como la glicina, betaína y ectoína; hasta algunos alcoholes. El compuesto orgánico más utilizado es la ectoína (Oren, 2002).

Entre la familia de organismos que utilizan estos solutos compatibles encontramos algunas especies de *Pseudomonas* (Como *Pseudomona putida*), que pueden sintetizar o tomar del medio compuestos como el manitol (Shivanand & Mugeraya, 2011). Otras especies como *P. mendocina* y *P. pseudoalcaligenes* utilizan compuestos como el  $\alpha$ -glucosilglicerol (**Figura 3**). También se conoce que *P. aeruginosa* PAO1 utiliza como osmolito regulador al N-acetilglutaminil-glutamina amida (**Figura 4**), un di-péptido formado a partir de la síntesis con glutamato (Roberts, 2005).




Figura 3. Estructura del  $\alpha$ -glucosilglicerol.




Figura 4. Estructura de la N-acetilglutamil-glutmina amida.

Algunas especies de *Vibrio* como *V. cholerae* y *V. costocicola* son capaces de acumular ectoína y betaína tomándola a partir del medio que las rodea. La betaína (es una amina cuaternaria mientras que la ectoína es una tetrahidropirimidina (**Figura 5** y **Figura 6**); ambas moléculas pueden encontrarse en bacterias halófilas y utilizarse como bio-marcadores. Este mecanismo permite la sobrevivencia de esta bacteria en agua dulce o salada (Roberts, 2005).




Figura 5. Estructura de la betaína.




Figura 6. Estructura de la ectoína.

### **3. METODOLOGÍA EXPERIMENTAL.**

#### **3.1. Acondicionamiento del lodo anaerobio.**

##### **3.1.1. Activación del lodo anaerobio.**

Se montó un reactor anaerobio UASB, fabricado en acrílico con un volumen de 7 L. El reactor fue inoculado con un lodo anaerobio granulado, procedente de una industria cervecera. El reactor se alimentó con un agua residual de baja carga orgánica para su activación. El agua a tratar era del tipo doméstico con una DQO de  $0.603 \pm 0.178$  g/L, el agua residual utilizada para alimentar el reactor se tomó a la entrada de la planta de tratamiento de del Centro de Investigación y Desarrollo Tecnológico en Electroquímica. El período de aclimatación de esta agua fue de 20 días. El agua se alimentó por la parte inferior del reactor mediante una bomba peristáltica que tomaba el agua de un contenedor de polietileno de 19 L de capacidad.

##### **3.1.2. Acondicionamiento del lodo anaerobio.**

Una vez activado el lodo convencional se procedió con la aclimatación de la biomasa a salinidad y a alta carga orgánica. Se utilizó agua residual doméstica y se le añadió azúcar común para incrementar su DQO. El agua residual obtenida tenía variaciones de carga muy marcadas, por lo que se optó por el uso de un agua residual sintética. El agua fue elaborada con productos comunes y reactivos de laboratorio (**Tabla 10**). Se realizaron concentrados de esta agua residual sintética y se prepararon diluciones para alimentar el reactor.

Tabla 10. Reactivos y sus concentraciones en el agua residual sintética

<b>Ingrediente</b>	<b>g/L</b>	<b>DQO</b>
Azúcar	47	50.0
Comida para perros	40	20.0
Leche en polvo	12	30.0
DQO		<b>100.0</b>
NH <sub>4</sub> Cl	8	-
KH <sub>2</sub> PO <sub>4</sub>	2	-
<b>Min. I</b>		-
FeCl <sub>2</sub>	4	-
CoCl <sub>2</sub>	0.25	-
MnCl <sub>2</sub>	0.05	-
ZnCl <sub>2</sub>	0.025	-
Na <sub>2</sub> SeO <sub>4</sub>	0.025	-
NiCl <sub>2</sub> .6H <sub>2</sub> O	0.025	-
H <sub>3</sub> BO <sub>3</sub>	0.025	-
CuCl <sub>2</sub> .2H <sub>2</sub> O	0.007	-
Na <sub>2</sub> MoO <sub>4</sub>	0.005	-
<b>Min II</b>		-
CaCl <sub>2</sub>	15	-
MgCl <sub>2</sub> .6H <sub>2</sub> O	20	-

(Arango y López, 2011).

El lodo anaerobio fue sometido a un período de aclimatación a cargas orgánicas superiores a las del agua residual doméstica (Valores de DQO de 1.104 a 3.7 g/L) y salinidades de 0 g/L. El período de aclimatación del lodo a estas características fue de 30 días. Después de este período, el lodo se sometió a cargas orgánicas y salinidades más elevadas. Con el fin de reducir el tiempo de aclimatación a la salinidad, se añadió un sedimento marino como inóculo.

El sedimento marino se colectó en un estero de la ciudad de Mazatlán, Sinaloa, conocido como estero La Sirena. El estero recibe todo el año descargas de agua residual con alta carga orgánica por parte una industria procesadora de harina de pescado, además de otras industrias del ramo alimenticio, así como aguas residuales domésticas. La salinidad del

cuerpo es idéntica a la del agua de mar, debido a que al utilizarse este cuerpo de agua como canal de navegación, la entrada del agua de mar es permanente. La colecta del sedimento se hizo a una profundidad de 30 cm de la superficie del sedimento marino. Para la colecta del sedimento se accedió al estero en el momento de pleamar baja, para ello se consultó el calendario de mareas de la ciudad que se muestra en la **Figura 7** (Das, 2011; Vidal et al., 1997).

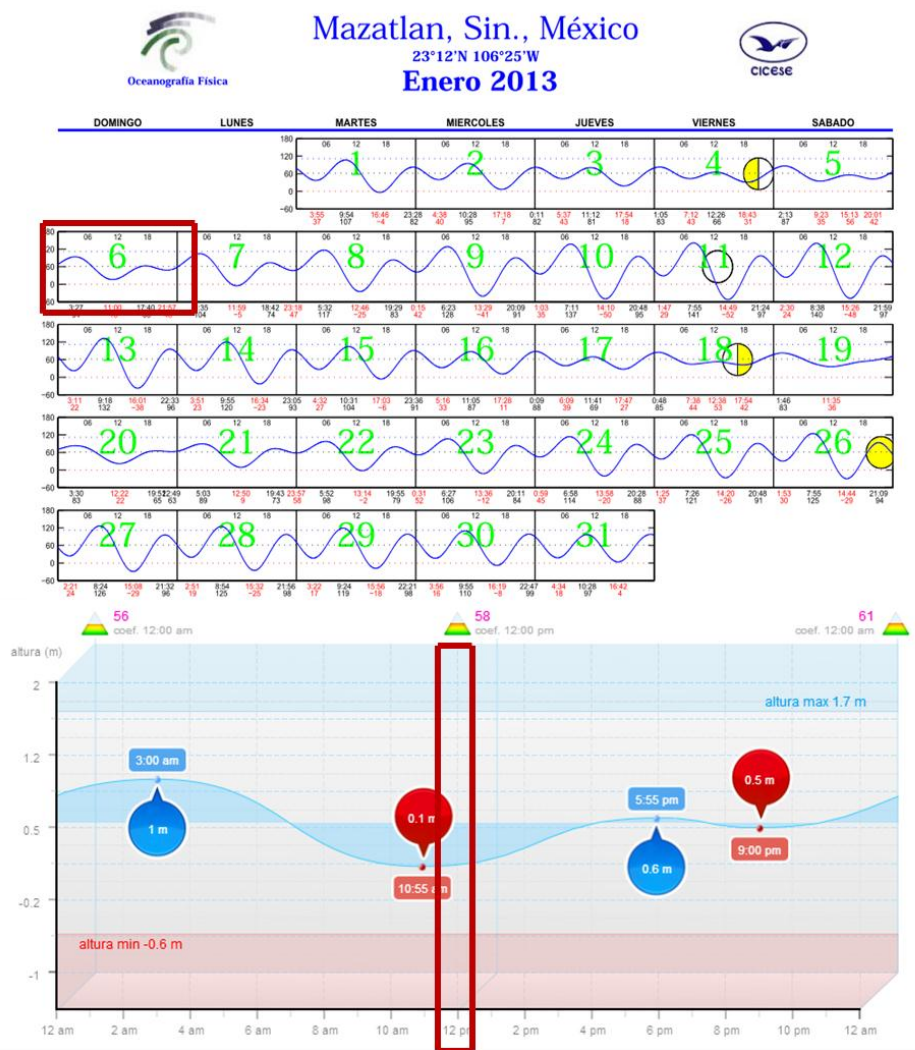


Figura 7. Tabla de mareas para la ciudad de Mazatlán el día de la toma del sedimento marino.

El sedimento marino fue colectado en una vena a la que se puede acceder sin ningún problema cuando la marea es baja y donde se observó con claridad las condiciones del cuerpo de agua. El sedimento colectado se almacenó en frascos de vidrio de boca ancha recubierto con papel aluminio. El transporte de los frascos se hizo en hielera a una temperatura de 4 °C. El punto de muestreo del sedimento y el croquis de localización del mismo, se muestran en la **Figura 8 y 9**.



Figura 8. Croquis de ubicación del punto de colecta de sedimento marino en la ciudad de Mazatlán.





Figura 9. Punto de colecta de lodo y condiciones del cuerpo de agua.

Das (2011) y Vidal (1997) mencionan que existe biomasa en los sedimentos de cuerpos de agua salobre. Esta biomasa es capaz de degradar la materia orgánica depositada en ellos y los subproductos que se obtienen a partir de esta degradación es biogás,  $\text{CO}_2$  y  $\text{H}_2\text{S}$ . A partir de esto se colectó un sedimento marino para inocular el reactor anaerobio con biomasa halófila. Los sedimentos de los estuarios son una buena alternativa para su uso en tratamiento de aguas salobres ya que en estos hay una alta deposición de sedimentos orgánicos que son eficientemente degradados por los microorganismos, además las necesidades de nutrientes son satisfechas a partir de una simbiosis muy estrecha que estos microorganismos desarrollan unos con otros (Stuckey, 2009).

### **3.2. Inoculación del reactor con sedimento marino.**

El sedimento marino se tamizó para remover la mayor cantidad posible de material inorgánico: hojas, ramas, grava fina y/o gruesa. El lodo tamizado se lavó con agua destilada solo 1 vez y se dejó reposar, el sobrenadante se desechó y el precipitado se caracterizó. Se determinó sólidos volátiles totales (SVT) tanto al lodo convencional como al sedimento marino. Para la inoculación del reactor se utilizó una proporción aproximada de 50:50. Para ello se determinó la cantidad de SVT en el reactor, así como los contenidos en el sedimento. A partir de estos valores se inoculó el lodo en el reactor. Al terminar la estabilización del reactor se hizo un análisis microbiológico para estimar las especies de

bacterias que se encuentran dentro de este y verificar si son especies halófilas o halotolerantes.

### 3.3. Incremento de la salinidad.

En la sección 2.2 se mencionó las diferentes metodologías para la aclimatación de un lodo anaerobio a altas cantidades de sal, para ello fue necesario utilizar una metodología basada en las presentadas por Kartal et al. (2006) y Stuckey (2009). La metodología propuesta es el uso de pulsos salinos, pero en este caso la biomasa no se re-expone a una concentración igual a la inicial, en vez de eso la salinidad se disminuye a un valor menor al inicial, después se re-expone a una salinidad mayor a la inicial y así sucesivamente hasta alcanzar la salinidad deseada (**Figura 10**).

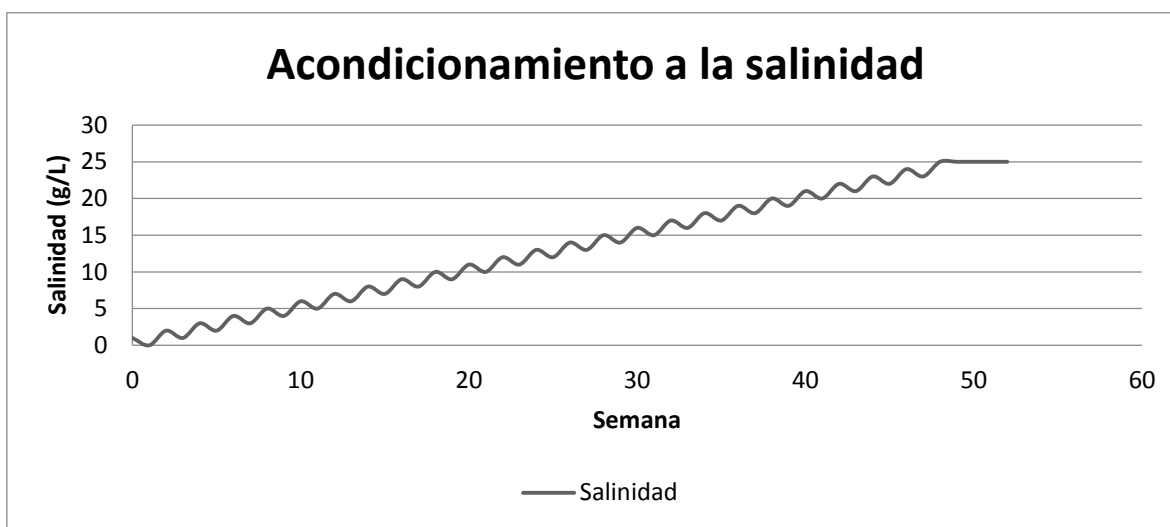


Figura 10. Metodología propuesta para acondicionamiento a alta salinidad.

### 3.4. Estabilización del reactor y seguimiento de parámetros de control.

Una vez inoculado el reactor se monitorearon los parámetros de DQO, temperatura, conductividad, salinidad y pH. La salinidad fue incrementada a la par con la carga orgánica. La salinidad máxima alcanzada fue de 23 g/L y mientras que la carga orgánica de 11.75 Kg DQO/m<sup>3</sup>. d. La metodología utilizada para la determinación de DQO fue una adaptación de las Normas Mexicanas: NMX-AA-030/1 y 030/2-SCFI-2012; y la metodología propuesta por Kayaalp et al. (2010) y Vyrides (2009) para su determinación en aguas residuales salobres. La metodología consistió en agregar cantidades extras de sulfato de mercurio a los

tubos de digestión de DQO para inhibir el efecto positivo en la medición causado por la sal. SVT, temperatura, pH y conductividad fueron determinados por los métodos establecidos en las Normas Mexicanas: NMX-AA-034-SCFI-2001, NMX-AA-007-SCFI-2000, NMX-AA-008-SCFI-2000 y NMX-AA-093-SCFI-2000 respectivamente.

### 3.5. Determinación del rendimiento de biogás a diferentes concentraciones de sal.

Después del período de aclimatación del reactor, se estudió el efecto causado por diferentes salinidades en el lodo acondicionado frente a un agua residual sintética hecha a base de vísceras de pescado, la cual simula un efluente de una industria procesadora de pescado. El agua fue preparada a partir de vísceras de pescado recolectadas en un mercado municipal, licuadas y tamizadas para eliminar la mayor cantidad posible de sólidos insolubles. A partir de este concentrado, se hicieron diluciones para alcanzar una DQO de  $2.71 \pm 0.52$  g/L. Las características del concentrado se muestran en la **Tabla 11**.

Para las pruebas de producción de biogás, se utilizaron botellas de vidrio de 250 ml acopladas a un módulo ANKOM® Gas Production System para medición continua de producción de biogás y temperatura. Se agregó a cada botella lodo anaerobio acondicionado y sustrato (Relación L/S). Se utilizaron 3 diferentes proporciones de L/S (Relación alimento microorganismo o F/M): 80L/160S (F/M =  $0.071 \pm 0.013$ ), 125L/125S (F/M =  $0.112 \pm 0.034$ ) y 160L/80S (F/M =  $0.287 \pm 0.055$ ).

Se hicieron 3 experimentos a salinidades de 0, 10 y 20 g/L para ver el comportamiento del lodo. La temperatura utilizada en estos experimentos fue de  $35.0 \pm 0.5$  °C, la cual se logró con un. Se hicieron mediciones de biogás cada hora, mientras que la DQO se determinó al inicio y al final del experimento. Con estos datos se calculó: Eficiencia de remoción de DQO (**Ecuación 2**) y rendimiento de producción de biogás (**Ecuación 3**)

$$Ef \text{ de remoción } (\%) = \left( \frac{DQO_{entrada} - DQO_{salida}}{DQO_{entrada}} \right) \times 100$$

Ecuación 2. Determinación de la eficiencia de remoción.

$$Y_{biogás} \left( \frac{L_{biogás}}{g DQO_{rem.}} \right) = \frac{L_{biogás prod}}{\left( \frac{ml AR_{sint} [DQO_{ent} - DQO_{sal}]}{1000} \right)}$$

Ecuación 3. Determinación del rendimiento de producción de biogás.

Tabla 11. Preparación de agua residual sintética a base de vísceras de pescado

Parámetro	Concentración	Unidades
DQO	176.5	g/L
pH	7.28	-
Conductividad	1.004	mS/cm
ST	22.91	g/L
SVT	28.68	g/L
Total Nitrógeno	1.2	g/L

## **4. RESULTADOS Y DISCUSIONES.**

### **4.1. Activación del lodo anaerobio convencional y acondicionamiento a agua residual sintética.**

El desempeño del reactor frente a un agua residual doméstica se muestra en la **Figura 11**, se observa que desde un principio el lodo mostró un buen desempeño en cuanto a eficiencia de remoción frente al agua residual doméstica. El desempeño del reactor UASB mostró pocas variaciones significativas al ser alimentado con agua residual doméstica. Este comportamiento no fue el mismo cuándo la concentración de DQO se incrementó repentinamente con el uso de azúcar de mesa ocasionando algunas complicaciones en su desempeño (**Figura 12**). La primera de ellas fue debido a la caída del pH por la azúcar agregada, esto provocó una acidificación en el reactor causando una disminución en la eficiencia de remoción. Este efecto fue corregido mediante la adición de bicarbonato de sodio para mantener la alcalinidad dentro del reactor. Otro problema causado fue la extensión del período de aclimatación del reactor. La adición de azúcar al agua residual doméstica no fue una buena alternativa por lo que se optó por la sustitución de esta por el uso de un concentrado de agua residual sintética (VerTabla 10).

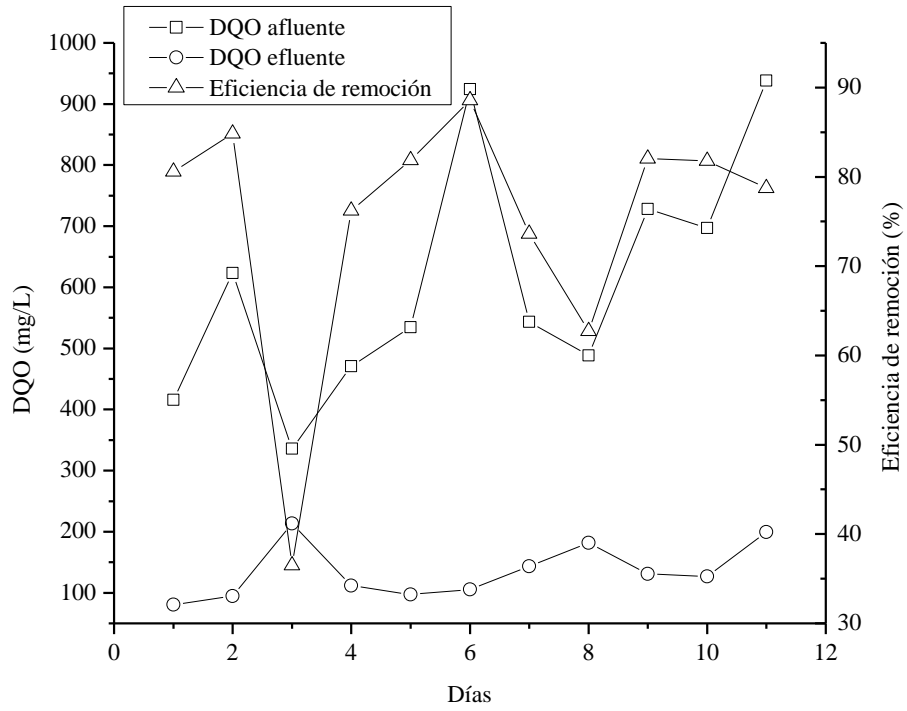


Figura 11. Desempeño del reactor en la fase de activación.

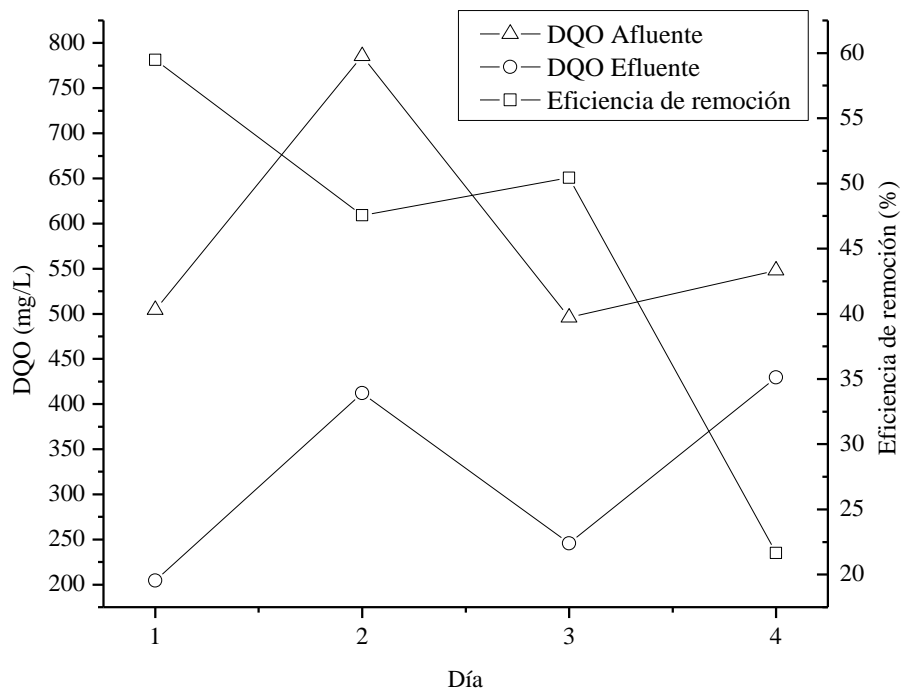


Figura 12. Desempeño del reactor frente agua sanitaria adicionada con azúcar.

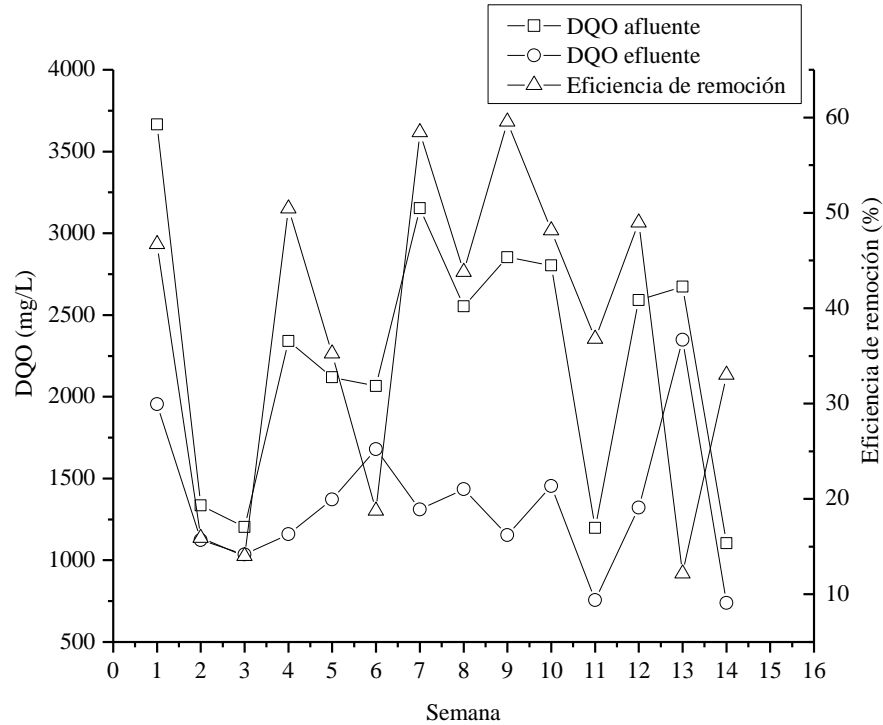


Figura 13. Desempeño del reactor en el período de acondicionamiento con agua residual sintética.

En el período de acondicionamiento del reactor a agua residual sintética se observó una variación muy marcada en la eficiencia de remoción (**Figura 13**), para lo cual fue necesario disminuir considerablemente la concentración de DQO a la entrada e ir incrementando gradualmente esta, hasta alcanzar un valor adecuado para introducir sal. Antes de comenzar con los incrementos de salinidad se analizaron muestras sintéticas, para verificar la precisión del método utilizado.

#### 4.2. Análisis de muestras de agua residual sintética con salinidad elevada.

Después de haber sometido el reactor al agua sintética el incremento de salinidad comenzó, previo a esta etapa, se hizo una verificación de la metodología a utilizar para la determinación de DQO en aguas salobres. Los resultados obtenidos se muestran en la **Tabla 12**, donde podemos observar las mediciones hechas en tubos comerciales de DQO para medio y alto rango, así como tubos preparados de acuerdo a la metodología establecida en la Norma Mexicana.

Tabla 12. Comparación de resultados del análisis de DQO en muestras sintéticas a diferentes salinidades mediante una modificación del método norma.

Metodología	Proporción de HgSO <sub>4</sub> *	DQO teórica (mg/L)	Salinidad (g/L)	DQO promedio medida (mg/L)	Error promedio	
NMX-AA-030/1 y 030/2-SCFI-2012	1:20	250	1, 3 y 5	221.33	11.47%	
			10 y 15	254.25	1.70%	
	1:10		1, 3 y 5	230	8.13%	
	1:20		500	1, 3 y 5	458	8.4%
				10 y 15	499.25	0.15%
	1:10			1, 3 y 5	493.4	1.32%
	1:20	750		1, 3 y 5	607.5	10.6%
				10 y 15	756.75	0.90%
	1:10			1, 3 y 5	763	1.73%

\*La cantidad agregada para mantener una proporción de HgSO<sub>4</sub> 20:1 en los tubos es de 0.03025, 0.09075, 0.1512, 0.3025 y 0.4538 g HgSO<sub>4</sub> para salinidades 1, 3, 5, 10 y 15 respectivamente. En cuanto a la proporción 10:1 las cantidades es de 0.01512, 0.04538 y 0.0756 gHgSO<sub>4</sub> para salinidades 1, 3 y 5 respectivamente (Vyrides & Stuckey, 2009).

En el presente estudio solo se probaron 3 concentraciones de DQO (250, 500 y 750 mg/L) y diferentes concentraciones de sal. Mientras que Stuckey (2009) y Kayaalp et al. (2010) solo algunas salinidades y varias concentraciones cloruros. Se utilizaron las mismas proporciones de g HgSO<sub>4</sub>:g Cl<sup>-</sup> a las mencionadas por estos autores. Los valores de DQO medidos con esta técnica modificada tuvieron un error similar a los presentados por ambos autores: menor al 10%, al analizar muestras de agua residual con baja carga orgánica.

Para concentraciones de DQO de 250, 500 y 750 mg/L, en el presente estudio se encontraron los mayores errores de medición al utilizar proporciones de 20:1 de g HgSO<sub>4</sub>:g Cl<sup>-</sup>, para salinidades de 1, 3 y 5 g NaCl/L, (Error mayor al 10%). Para proporciones 10:1, el error resultó menor al 10%. En contraste, es necesario disminuir la cantidad de K<sub>2</sub>Cr<sub>2</sub>O<sub>7</sub> en los tubos de digestión y mantener una proporción g HgSO<sub>4</sub>:g Cl<sup>-</sup> de 20:1, algo que resulta complicado por la cantidad de reactivos utilizados en la preparación de las soluciones para DQO. Se optó por utilizar una proporción 10:1 para salinidades menores a 5. Para superiores a 10 y 15 g NaCl/L, los resultados mostrados por el análisis de las muestras sintéticas fueron satisfactorios, ya que se obtuvieron errores de medición cercanos al 1% a proporciones de g HgSO<sub>4</sub>:g Cl<sup>-</sup> de 20:1.



### 4.3. Acondicionamiento del lodo a alta salinidad y alta carga orgánica.

Antes de incrementar la salinidad en el reactor, este fue inoculado con el sedimento marino el cual tenía una concentración de 27 mg SVT/g de lodo seco. Mientras que el lodo convencional una concentración de 16.7 g SVT/L de lodo. Se necesitaron 2.1 Kg de sedimento marino para conseguir una proporción 50:50 para la inoculación del reactor anaerobio. El reactor con sedimento marino y lodo convencional tuvo un buen desempeño frente a un agua residual sintética salobre.

Una vez adaptado el reactor a tratar agua residual sintética, el desempeño de este fue bueno frente al incremento de salinidad, el monitoreo de las variables de control como pH, temperatura así como los incrementos de carga orgánica y salinidad se muestran en las **Figuras 14 a 18**. Los datos obtenidos en esta etapa de la experimentación fueron de utilidad para la siguiente fase del presente proyecto, que consiste en la optimización del proceso mediante inteligencia artificial. El desempeño del reactor frente a las diferentes concentraciones de DQO, se muestra en la **Figura 14**.

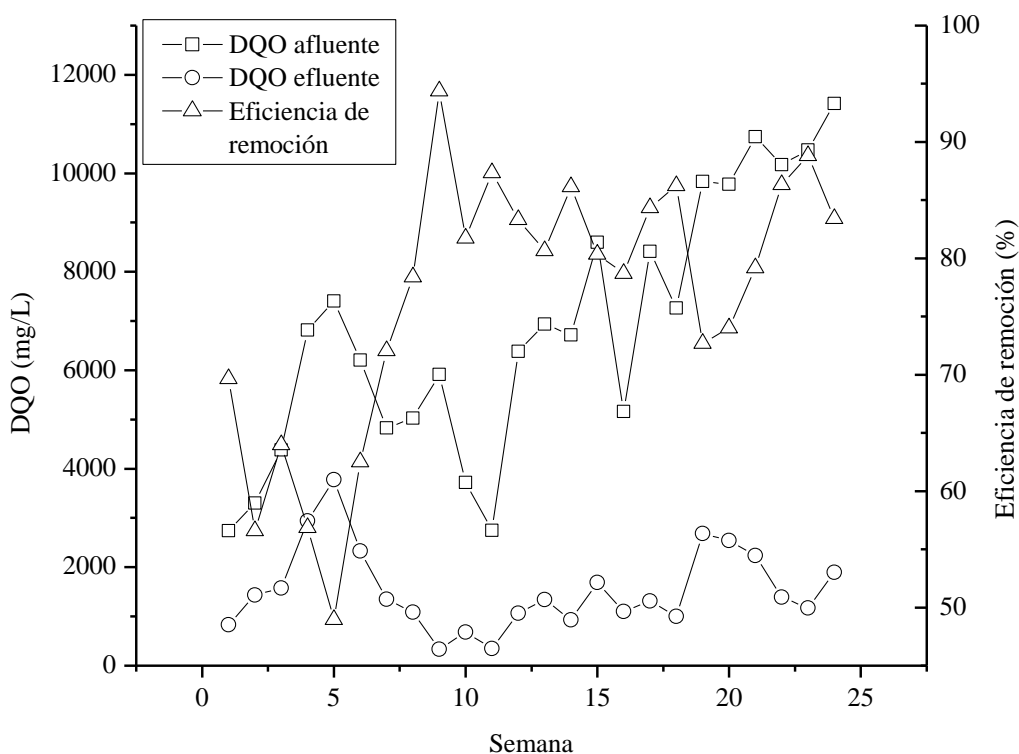


Figura 14. Comportamiento del reactor en el acondicionamiento a agua residual sintética.

Se observa tal como se esperaba, el reactor responde favorablemente frente a una elevada DQO. El incremento gradual permitió la adaptación periódica de los microorganismos al nuevo sustrato. Se observa en la **Figura 14** que este incremento de DQO permite una adaptación gradual del reactor, el cual presentó un buen desempeño a partir del octavo día de operación. Al mismo tiempo el reactor fue inoculado con sedimento marino, tomado en la ciudad de Mazatlán, para permitir la adaptación tanto del sedimento al nuevo sustrato, como del lodo convencional al incremento de salinidad en el reactor. Se monitoreó la eficiencia de remoción en el agua residual sintética para estimar el efecto inhibitorio del incremento de salinidad sobre la eficiencia de remoción. Además del efecto de otras variables como la temperatura ambiente y el incremento de carga orgánica volumétrica. La carga orgánica volumétrica dentro del reactor se utilizó como un parámetro de monitoreo ya que se observó en el período de acondicionamiento, que incrementos repentinos de este parámetro, causan acidificación en el reactor, aumentando la concentración de DQO en el efluente.

El desempeño del reactor frente al incremento de salinidad se muestra en la **Figura 15**, donde se puede observar que hay efectos leves en la eficiencia de remoción, al incrementar la salinidad del agua residual de entrada. Al incrementar la salinidad de 4 a 5 g/L, hay una caída en la eficiencia de remoción de 94% hasta un 81%, al disminuir la salinidad de 5.1 g/L a 4.6, el reactor muestra un desempeño aceptable al remover un 87% de la DQO del agua residual sintética. Al incrementar de nuevo la salinidad del agua residual de 4.6 a 6.1 g/L, la eficiencia de remoción cae de nuevo, pero esta vez la caída de remoción de DQO llegó a 83%. Al comparar los resultados de acondicionamiento del reactor con aquellos presentados por otros autores, se encontró que el tiempo de aclimatación se pudo reducir gracias a que se utilizaron incrementos repentinos de salinidad en el agua residual, seguidos de una disminución en la concentración de la misma. Esta metodología permitió también la estabilidad del reactor a cambios abruptos de salinidad (Stuckey, 2009).




Figura 15. Acondicionamiento del reactor a alta salinidad.

El reactor mantuvo una tendencia similar durante todo el período de aclimatación, pero algo que es importante mencionar es la poca variación en la eficiencia de remoción al aumentar y disminuir gradualmente la salinidad del agua residual de 0-10 g/L. Cuando el umbral en la concentración superó esos valores, la remoción de DQO, a pesar de recuperarse no logró sobrepasar el 88% a una concentración 19 g/L y después de 24 semanas de aclimatación. Al final del período, la concentración de sal máxima a la que se expuso el reactor fue de 23 g/L, alcanzándose una remoción de DQO del 83%.

Como se comentó arriba, el reactor no presentó cambios significativos a valores de salinidad menores a 10 g/L. La eficiencia de remoción alcanzada con esta salinidad es similar a los encontrados por Li et al. (2014) y Kimata-Kino et al. (2011). Por arriba de salinidades de 10 g/L el efecto inhibitorio causado por la sal fue mayor. Debajo de estas concentraciones la biomasa puede soportar sin mostrar ningún efecto marcado, a valores mayores de esta concentración, será necesario un acondicionamiento gradual (Kimata-Kino et al., 2011).

Los valores de carga orgánica volumétrica dentro del reactor fueron elevados gracias a que se utilizó un tiempo de residencia (TRH) de 18 h. Este TRH permitió cargas orgánicas entre 2.82 y 11.75 Kg DQO/m<sup>3</sup>.d (**Figura 16**). Estos valores se encuentran por arriba de los que se mencionan en algunos estudios de tratamiento de aguas residuales salobres reales como las de la industria de procesamiento de pescado, harina de pescado o enlatado de atún (El-sheikh et al., 2011; Guerrero & Omil, 1997; Li et al., 2014; Luo et al., 2013; Omil et al., 1995; Prasertsan et al., 1994).




Figura 16. Incremento de carga orgánica y eficiencia de remoción.

Los incrementos repentinos de carga orgánica influyeron en la disminución de pH y como consecuencia, una disminución en la eficiencia de remoción (Ver **Figura 16** y **Figura 17**). A pesar de la disminución de la eficiencia de remoción, el reactor tuvo la capacidad de recuperarse. Pero se consideró el incremento gradual de carga orgánica dentro del reactor, pues el incremento repentino de este parámetro causó un incremento en la concentración de AGV, medido indirectamente mediante una medición de pH (**Figura 17**). La acumulación de AGV dentro del reactor provocó una caída de la eficiencia, pero después de un tiempo el

reactor recuperó su eficiencia (Guerrero & Omil, 1997). La disminución del pH se debió al incremento repentino de la carga orgánica desde valores 4.5 hasta 7.01 Kg DQO/m<sup>3</sup>.d.

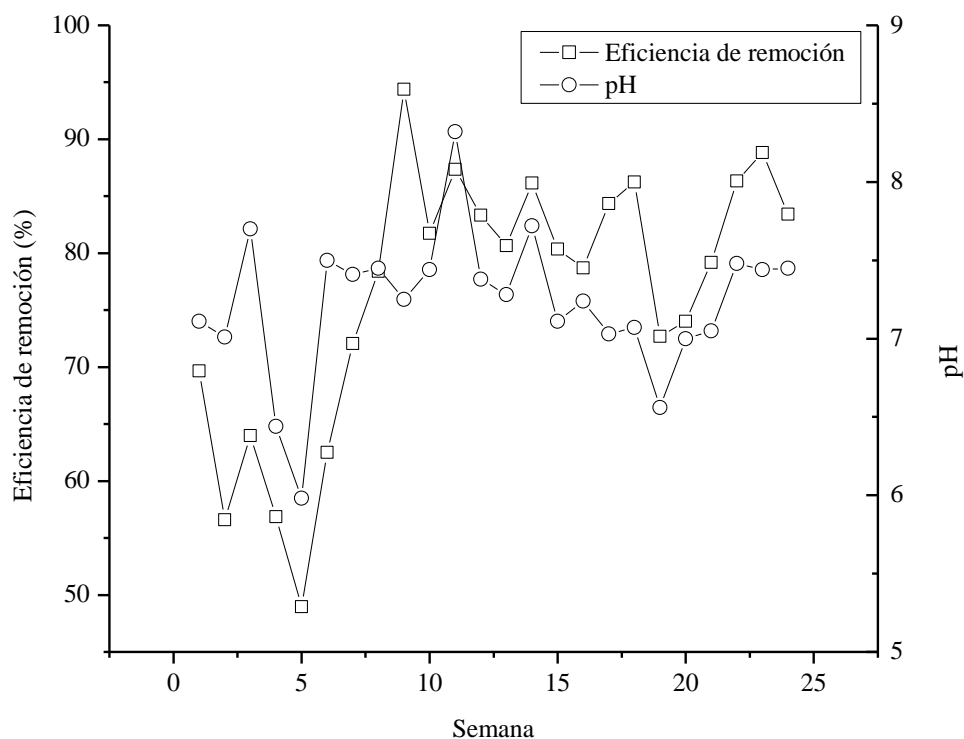


Figura 17. Efecto del pH en la eficiencia de remoción.

En el presente estudio se analizó también el efecto que tiene la temperatura sobre la eficiencia del sistema al tratar agua residual salina. No se observó una relación directa entre el aumento o disminución de la temperatura y la eficiencia de remoción del sistema (Ver **Figura 18**). El reactor operó a temperatura ambiente, puesto que se busca obtener los mejores resultados con el mínimo de insumos. Se observa no hay una relación directa entre la temperatura y la eficiencia de remoción del reactor. Solo existe un punto el cual no tiene relación con los parámetros estudiados. En este caso se observa que la máxima eficiencia se alcanzó a una temperatura cercana a los 25°C.

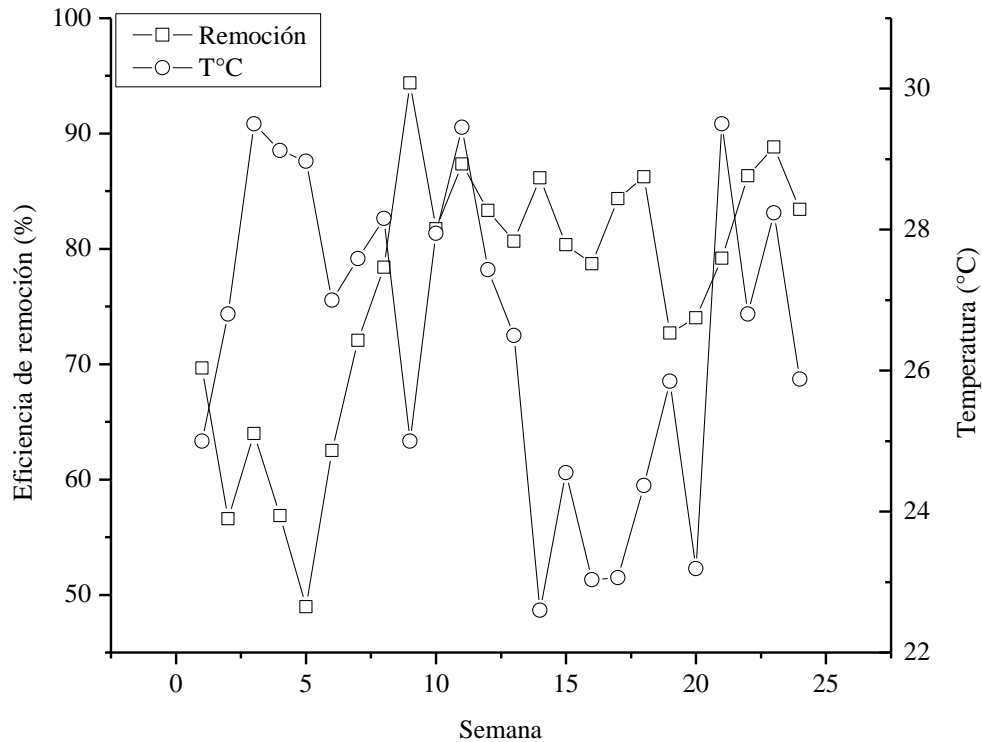


Figura 18. Efecto de la temperatura sobre la eficiencia de remoción.

#### 4.4. Efecto de la salinidad en un lodo anaerobio acondicionado.

La **Figura 19** y **Figura 20B** muestran el desempeño del lodo anaerobio aclimatado a la sal frente al agua residual con vísceras de pescado y a diferentes salinidades. Se observa que la producción de biogás se ve afectada significativamente por la salinidad. A salinidades de 0 g/L, la producción de biogás varío de 262.71-334 ml. Al aumentar la salinidad a 10 g/L la producción se redujo significativamente, alcanzado valores de 128.85 y 134.12 ml, lo que representa una caída del 50-60 % en la producción con respecto a los valores alcanzados a en condiciones de 0 salinidad. Para salinidades de 20 g/L la producción cayó de un 62 a 72 alcanzando valores máximos de producción de 98.1 a 114.5 ml. Este efecto se debe principalmente a la inactivación de las bacterias metanogénicas causada por la alta presión osmótica que existe en el medio (Chen et al., 2008; Lefebvre & Moletta, 2006).

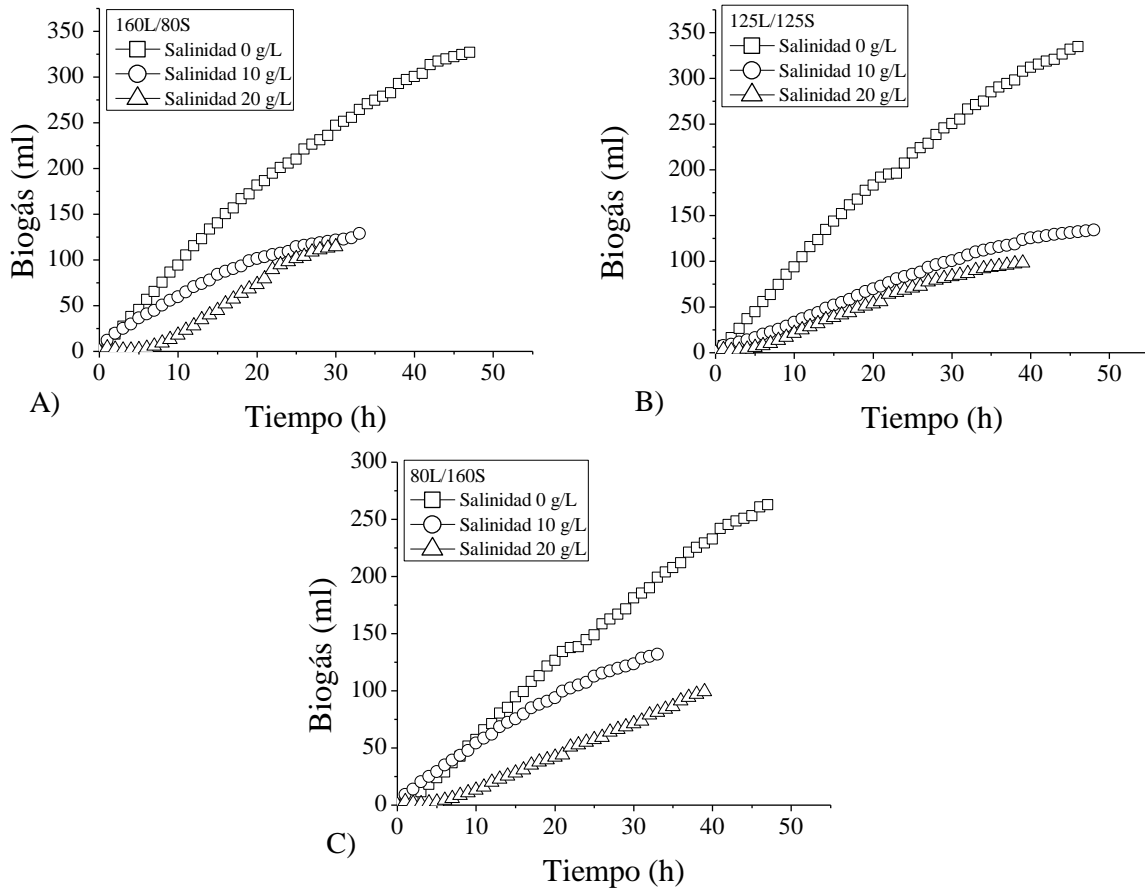


Figura 19. Curvas de producción de biogás a salinidades de 0, 10 y 20 g/L a proporciones lodo/sustrato de: A) 160L/80S, B) 125L/125S y C) 80L/160S.

En la **Figura 20** se muestra la remoción de DQO alcanzada por el lodo a las diferentes relaciones L/S. Se observa que a salinidades de 0 g/L se logran remociones de DQO entre 87.5 y 94.7 %, en tiempos de 46 h. Para salinidades de 10 g/L las eficiencias de remoción logradas fueron de 90.9 a 96.2% en tiempos de retención de 33 a 48 h, estos tiempos son más bajos que los reportados por Guerrero et al. (1997), Prasertsan et al. (1994), Aspé et al. (1997) y Gebauer (2004), autores que reportaron el uso de tiempos de retención entre 4 y 30 días para el tratamiento de efluentes de la industria pesquera. Finalmente a salinidades de 20 g/L se encontraron eficiencias de remoción entre 83 y 90% en tiempos de 31 a 40 h. Los tiempos encontrados son similares a los utilizados por Mosquera-Corral et al., (2001) y Puñal y Lema (1999).

Como ya se mencionó el lodo tuvo su buen desempeño en las 3 salinidades utilizadas, lo que prueba su acondicionamiento a la alta salinidad, lo que prueba que el uso de sedimento

marino, cultivos puros o mixtos de microorganismos halófilos o inóculos ya acondicionados mejoran el desempeño del sistema de tratamiento. (Abou-Elela et al., 2010; Kapdan & Boylan, 2009; Omil et al., 1995; Panswad & Anan, 1999; Vidal et al., 1997).

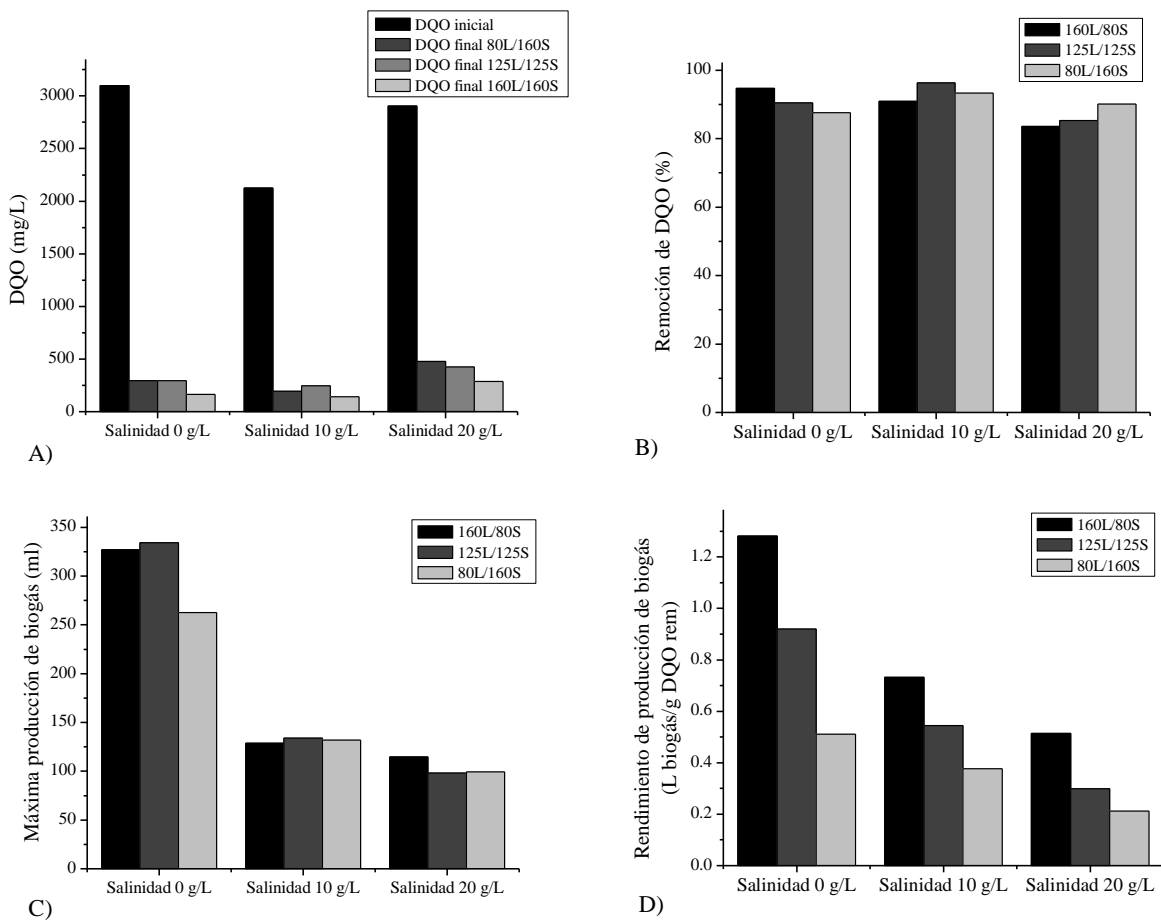


Figura 20. Desempeño del lodo anaerobio acondicionado: A) DQO inicial y DQO del efluente tratado, B) Remoción de DQO, C) Máxima producción de biogás y D) Rendimiento de producción de biogás.

Se observa en la figura que el rendimiento de producción de biogás disminuyó considerablemente conforme la salinidad aumentó. A salinidades de 0 g/L, el rendimiento de producción de biogás alcanzado fue de 0.51 a 1.28 L de biogás/Kg DQO<sub>rem</sub>. Para salinidades de 10 g/L el rendimiento alcanzado fue de 0.376 a 0.732 L de biogás/Kg DQO<sub>rem</sub>, esto representa una caída del 26.5 al 42%. A salinidades de 20 g/L la reducción en el rendimiento debido a la inhibición por la sal alcanzó un 58 al 68 %, ya que el rendimiento alcanzado varió de 0.211 a 0.513 L de biogás/Kg DQO<sub>rem</sub>.



A pesar de estas reducciones tan significativas, los valores de rendimiento de producción de biogás están por encima del 0.75 L de biogás/Kg DQO<sub>rem</sub> reportado por Prasertsan et al. (1994) y el 0.184 L de biogás/Kg DQO<sub>rem</sub> reportado por Gebauer (2004), probando que a pesar de la inhibición generada por la alta salinidad, el desempeño del lodo es comparable al de aquellos sistemas que tratan aguas residuales de la industria procesadora de pescado.

#### **4.5. Especies de bacterias presentes en el reactor.**

Finalmente, después de analizar el efecto de los diferentes parámetros medidos sobre la eficiencia de remoción. Además de lograr la estabilización del reactor a una alta salinidad y carga orgánica elevada, se analizó la microbiología del lodo anaerobio, para verificar que los organismos encontrados correspondan a bacterias halófilas o halotolerantes. Este estudio, se hizo con el fin de respaldar el desempeño del reactor a variaciones de salinidad. Las familias de bacterias encontradas dentro del reactor fueron: *Vibrios sp.*, *Proteus sp.*, *Pseudomonas sp.*, *Archanobacterium sp.*, *Aureobacterium sp.* y *Staphylococcus aureus*.

Las familias de bacterias identificadas corresponden a organismos ligeramente halófilos, en el caso de *Vibrios sp.*, *Proteus sp.* y *Pseudomonas sp.* (Kunte, 2013; Russell, 1989; Shivanand & Mugeraya, 2011). Aunque algunas especies de *Vibrios* y *Pseudomonas* suelen encontrarse en ambientes con concentraciones elevadas de sal de hasta >200g/L, como *Vibrio costicola* y *Pseudomonas halosaccharolytica*. La presencia de *Vibrio* indica la presencia de organismos halófilos en el medio. (Russell, 1989).

De acuerdo a Roeßler et al. (2003) algunas especies de *Proteus* (*P. mirabilis* y *P. vulgaris*) han desarrollado una dependencia al ion Cl<sup>-</sup> para su crecimiento. En concentraciones bajas estas especies necesitan de ciertas concentraciones del ion para su óptimo crecimiento. Aunque también pueden crecer a concentraciones cercanas a la del agua de mar. Los *Vibrio* son un género de bacteria que pueden crecer en concentraciones de salinidad que van desde 5.8 g Cl/L hasta cerca de 90 g Cl/L de sal. En cuanto a la bacteria *Staphylococcus aureus*, su halotolerancia le permite desarrollarse en concentraciones de sal desde 5.8 hasta 90 g Cl/L.

No se encontró alguna referencia sobre la capacidad halotolerante o halófila de *Archanobacterium*. En el caso de *Aureobacterium* se encontraron algunos estudios que

asocian sus características a la de otras bacterias donde se explica la capacidad de crecimiento de estas bacterias en concentraciones considerables de sal además resaltan su amplia distribución (Acuña et al., 2010)

En las ~~Figuras 21 a 24~~ se observan imágenes de bacterias encontradas en el lodo acondicionado a la sal. Se observan en su mayoría bacilos cortos y alargados Gram positivos y Gram negativos. Las especies y familias de los microorganismos observados en las fotografías no fueron identificadas. Las imágenes se tomaron en un microscopio electrónico con un aumento de 100X.




Figura 21. Bacilos cortos Gram positivos.




Figura 22. Bacilos cortos Gram positivos y Gram negativos.




Figura 23. Bacilos alargados Gram positivos y Gram negativos, y cocos Gram negativos.




Figura 24. Bacilos alargados Gram positivos.

Se encontraron varios estudios donde se mencionan las características de las bacterias halotolerantes. Estos estudios centran su atención en describir la morfología de bacterias halotolerantes o halófilas. Se mencionan algunas pruebas bioquímicas para identificación de especies (Aishvarya, Jena, Pradhan, Panda, & Sukla, 2015; Molina, 2008; Wood, 1967). Desafortunadamente, no se pudieron relacionar con los organismos mostrados en las figuras por la falta de información. Pues lo único que se tiene es la tinción Gram que estos bacilos o cocos presentaron.

## 5. CONCLUSIONES.

El lodo se adaptó rápidamente al nuevo sustrato utilizado en la etapa de activación. Al momento de incrementar la concentración de materia orgánica fue necesario utilizar un nuevo sustrato para poder acondicionar el lodo. Esto debido a que había muchas variaciones de carga en el agua residual. Al usar un agua residual sintética, estas variaciones se pudieron controlar.

En la etapa de aclimatación el lodo no presentó problemas para adaptarse a concentraciones bajas de salinidad (hasta 12 g NaCl/L). Cuando la salinidad se incrementó arriba de estos valores se observó una disminución en la eficiencia de remoción máxima alcanzada por el sistema. La máxima eficiencia fue de 95% valor que no volvió a alcanzarse en la etapa de aclimatación. Al final el lodo pudo trabajar a 23 g NaCl/L sin ningún problema.

Este buen desempeño se le atribuye a dos factores, el primero de ellos, la capacidad halotolerante de los microorganismos presentes en el lodo convencional. La segunda razón, el uso de un sedimento marino para inocular el reactor con biomasa halófila. A pesar de la similitud de la metodología con otros autores, respecto al uso de sedimento marino, el sedimento utilizado en este experimento se obtuvo directamente de un cuerpo que por muchos años ha recibido descargas de aguas residuales industriales con alta carga orgánica. Esto quiere decir que la biomasa, con la cual se inoculó el reactor, tiene la capacidad de depurar aguas residuales con alta carga orgánica. A diferencia de un sedimento marino, que, si bien tiene una gran cantidad de microorganismos halófilos, la cantidad de materia orgánica que recibe es menor en comparación al de un cuerpo que recibe aguas residuales industriales.

El uso de la metodología utilizada para el muestreo del lodo resultó efectiva, a pesar de que fue propuesta solo para el análisis de microorganismos presentes en el lodo. En el presente estudio se utilizó para la colecta de biomasa halófila.

Se observaron afectaciones directas a la eficiencia de remoción causados por la modificación de los parámetros de control: carga orgánica, pH, salinidad y temperatura. Por lo tanto, en la siguiente etapa de este estudio, estos parámetros fueron considerados para usarse como parámetros de monitoreo.

El incremento de carga orgánica ocasionó problemas de adaptación al lodo anaerobio. Se presentaron períodos en los cuales hubo una disminución del pH en el efluente tratado del reactor. Esta disminución de pH se atribuye al incremento repentino de la carga orgánica. Por esta razón, el incremento de carga orgánica tuvo que ser de la misma manera que los incrementos de salinidad: escalonados.

En comparación con las metodologías utilizadas por otros autores, se observó que la mayoría utiliza incrementos de salinidad o de carga orgánica. En algunos estudios previos analizaron la capacidad de reactores anaerobios a incrementos de carga orgánica y salinidad. Los resultados obtenidos por estos autores fueron satisfactorios, pero el período de aclimatación fue muy extenso comparado con el utilizado en este estudio.

La temperatura del reactor se mantuvo en el rango mesofílico. No se pudo observar un efecto significativo en la eficiencia de remoción, debido al aumento o disminución de temperatura. Se espera que el efecto se más notable al incrementar la temperatura.

Finalmente, la caracterización de algunas familias de bacterias probó la presencia de microorganismos halófilos o halotolerantes. De acuerdo a la bibliografía consultada, algunas de las bacterias halotolerantes encontradas son capaces de soportar concentraciones por arriba de los valores utilizados en los experimentos del presente estudio. Otras familias de bacterias encontradas probaron la presencia de biomasa halófila dentro reactor anaerobio.

## REFERENCIAS

- Abou-Elela, S. I., Kamel, M. M., & Fawzy, M. E. (2010). Biological treatment of saline wastewater using a salt-tolerant microorganism. *Desalination*, 250(1), 1–5.
- Acuña, a J., Pucci, G. N., & Pucci, O. H. (2010). Caracterización de tres cepas bacterianas capaces de fijar nitrógeno y biodegradar hidrocarburos aisladas de un suelo de la Patagonia. *Ecosistemas - ISSN 1132-6344*, 19(2), 125–136.
- Aishvarya, V., Jena, J., Pradhan, N., Panda, P. K., & Sukla, L. B. (2015). *Environmental Microbial Biotechnology*.
- Aloui, F., Khoufi, S., Loukil, S., & Sayadi, S. (2009). Performances of an activated sludge process for the treatment of fish processing saline wastewater. *Desalination*, 246(1–3), 389–396.
- Arango, L. and López, J. (2011) Estudio a escala de laboratorio de los efectos de la forma de alimentación y de la cantidad de inóculos sobre el hinchamiento de los lodos de reactores aerobios de mezcla completa en etapa de arranque. [Enlínea] <http://hdl.handle.net/11407/1232> (Consultado Febrero 21, 2016)
- Aspé, E., Marti, M. C., & Roeckel, M. (1997). Anaerobic treatment of fishery wastewater using a marine sediment inoculum. *Water Research*, 31(9), 2147–2160.
- Boardman, G. D., Tisinger, J. L., & Gallagher, D. L. (1995). Treatment of clam processing wastewaters by means of upflow anaerobic sludge blanket technology. *Water Research*, 29(6), 1483–1490.
- Bustillo-Lecompte, C. F., & Mehrvar, M. (2015). Slaughterhouse wastewater characteristics, treatment, and management in the meat processing industry: A review on trends and advances. *Journal of Environmental Management*, 161, 287–302.
- Campo, P., Platten, W., Suidan, M. T., Chai, Y., & Davis, J. W. (2011). Aerobic biodegradation of amines in industrial saline wastewaters. *Chemosphere*, 85(7), 1199–1203.
- Chen, Y., Cheng, J. J., & Creamer, K. S. (2008). Inhibition of anaerobic digestion process: A review. *Bioresource Technology*, 99(10), 4044–4064.
- Chowdhury, P., Viraraghavan, T., & Srinivasan, A. (2010). Biological treatment processes for fish processing wastewater - A review. *Bioresource Technology*, 101(2), 439–449.
- Clesceri, L. S., Rice, E. W., Baird, R. B., & Eaton, A. D. (2012). *Standard Methods for the*

- Examination of Water and Wastewater. American Water Works Association/American Public Works Association/Water Environment Federation, (1), 1469.
- Das, S. (2011). Salt tolerant culturable microbes accessible in the soil of the Sundarban Mangrove forest, India. *Open Journal of Ecology*, 1(2), 35–40.
- Deublein, D., & Steinhauser, A. (2010). *Biogas from Waste and Renewable Resources: An Introduction, Second Edition*. *Biogas from Waste and Renewable Resources: An Introduction, Second Edition*.
- El-sheikh, M. A., Saleh, H. I., Flora, J. R., & Abdel-ghany, M. R. (2011). Biological tannery wastewater treatment using two stage UASB reactors. *DES*, 276(1–3), 253–259.
- Fall, C., Millán-Lagunas, E., Bâ, K. M., Gallego-Alarcón, I., García-Pulido, D., Díaz-Delgado, C., & Solís-Morelos, C. (2012). COD fractionation and biological treatability of mixed industrial wastewaters. *Journal of Environmental Management*, 113, 71–77.
- Gebauer, R. (2004). Mesophilic anaerobic treatment of sludge from saline fish farm effluents with biogas production. *Bioresource Technology*, 93(2), 155–167.
- Gerardi, M. H. (2003). *The Microbiology of Anaerobic Digesters*. Vasa.
- Guerrero, L., & Omil, F. (1997). Treatment of Saline Wastewaters From Fish Meal Factories in an Anaerobic Filter Under Extreme Ammonia Concentrations, 61, 69–78.
- Guerrero, L., Omil, F., Méndez, R., & Lema, J. M. (1997). Treatment of saline wastewaters from fish meal factories in an anaerobic filter under extreme ammonia concentrations. *Bioresource Technology*, 61(1), 69–78.
- Ioannou, L. A., Puma, G. L., & Fatta-Kassinos, D. (2015). Treatment of winery wastewater by physicochemical, biological and advanced processes: A review. *Journal of Hazardous Materials*, 286, 343–368.
- Kapdan, I. K., & Boylan, B. (2009). Batch treatment of saline wastewater by *Halanaerobium lacusrosei* in an anaerobic packed bed reactor. *Journal of Chemical Technology and Biotechnology*, 84(1), 34–38.
- Kargi, F., & Dincer, A. R. (1997). Biological treatment of saline wastewater by fed-batch operation. *Journal of Chemical Technology and Biotechnology*, 69(2), 167–172.
- Kartal, B., Koleva, M., Arsov, R., van der Star, W., Jetten, M. S. M., & Strous, M. (2006).



- Adaptation of a freshwater anammox population to high salinity wastewater. *Journal of Biotechnology*, 126(4), 546–553.
- Kayaalp, N., Ersahin, M. E., Ozgun, H., Koyuncu, I., & Kinaci, C. (2010). A new approach for chemical oxygen demand (COD) measurement at high salinity and low organic matter samples. *Environmental Science and Pollution Research*, 17(9), 1547–1552.
- Kimata-Kino, N., Ikeda, S., Kurosawa, N., & Toda, T. (2011). Saline adaptation of granules in mesophilic UASB reactors. *International Biodeterioration and Biodegradation*, 65(1), 65–72.
- Kunte, H. J. (2013). Osmoregulation in halophilic bacteria. *Extremophiles*, II.
- Lefebvre, O., & Moletta, R. (2006). Treatment of organic pollution in industrial saline wastewater: A literature review. *Water Research*, 40(20), 3671–3682.
- Lefebvre, O., Quentin, S., Torrijos, M., Godon, J. J., Delgenès, J. P., & Moletta, R. (2007). Impact of increasing NaCl concentrations on the performance and community composition of two anaerobic reactors. *Applied Microbiology and Biotechnology*, 75(1), 61–69.
- Lefebvre, O., Vasudevan, N., Torrijos, M., Thanasekaran, K., & Moletta, R. (2006). Anaerobic digestion of tannery soak liquor with an aerobic post-treatment. *Water Research*, 40(7), 1492–1500.
- Li, J., Yu, L., Yu, D., Wang, D., Zhang, P., & Ji, Z. (2014). Performance and granulation in an upflow anaerobic sludge blanket (UASB) reactor treating saline sulfate wastewater. *Biodegradation*, 25(1), 127–136.
- Luo, G. zhi, Li, P., Tan, H. xin, Du, J., & Liang, W. yan. (2013). The start-up and saline adaptation of mesophilic anaerobic sequencing batch reactor treating sludge from recirculating aquaculture systems. *Aquacultural Engineering*, 54, 9–15.
- Mara, D. (2003). Domestic wastewater treatment in developing countries.
- Mariángel, L., Aspé, E., Cristina Martí, M., & Roeckel, M. (2008). the Effect of Sodium Chloride on the Denitrification of Saline Fishery Wastewaters. *Environmental Technology*, 29(8), 871–879.
- Meneses-Jácome, A., Diaz-Chavez, R., Velásquez-Arredondo, H. I., Cárdenas-Chávez, D. L., Parra, R., & Ruiz-Colorado, A. A. (2016). Sustainable Energy from agro-industrial wastewaters in Latin-America. *Renewable and Sustainable Energy Reviews*, 56,

1249–1262.

- Molina, L. (2008). Influencia de la salinidad, Irradiancia y concentración de nutrientes sobre el crecimiento de la microalga *Rhodospirillum rubrum*. Universidad de Zulia.
- Mosquera-Corral, A., Sanchez, M., Campos, J. L., Mendez, R., & Lema, J. M. (2001). Simultaneous methanogenesis and denitrification of pretreated effluents from a fish canning industry. *Water Research*, 35(2), 411–418.
- Omil, F., Mendez, R., & Lema, J. M. (1995). Anaerobic treatment of saline wastewaters under high sulphide and ammonia content. *Bioresource Technology*, 54(3), 269–278.
- Oren, A. (2002). Diversity of halophilic microorganisms: environments, phylogeny, physiology, and applications. *Journal of Industrial Microbiology & Biotechnology*, 28(1), 56–63.
- Paniagua, D., Borgne, S. Le, Vázquez-duhalt, R., Biotecnología-unam, I. De, Universidad, A., & Cuernavaca, C. C. (2004). Aislamiento Y Caracterización De Bacterias Halofilas Degradadoras De Hidrocarburos, (2000), 2002.
- Panswad, T., & Anan, C. (1999). Impact of high chloride wastewater on an anaerobic/anoxic/aerobic process with and without inoculation of chloride acclimated seeds. *Water Research*, 33(5), 1165–1172.
- Prasertsan, P., Jung, S., & Buckle, K. a. (1994). Anaerobic filter treatment of fishery wastewater. *World Journal of Microbiology & Biotechnology*, 10(1), 11–3.
- PUNAL, A., & LEMA, J. (1999). Anaerobic treatment of wastewater from a fish-canning factory in a full-scale upflow anaerobic sludge blanket (UASB) reactor. *Water Science and Technology*, 40(8), 57–62.
- Qasim, W., & Mane, A. V. (2013). Characterization and treatment of selected food industrial effluents by coagulation and adsorption techniques. *Water Resources and Industry*, 4, 1–12.
- Ramalho, R. S. (2003). *Tratamiento de Aguas Residuales*. Quebec, Canada: Editorial Reverté.
- Roberts, M. F. (2005). Organic compatible solutes of halotolerant and halophilic microorganisms. *Saline Systems*, 30, 1–30.
- Roeßler, M., Sewald, X., & Müller, V. (2003). Chloride dependence of growth in bacteria. *FEMS Microbiology Letters*, 225(1), 161–165.

- Russell, N. J. (1989). Adaptive modifications in membranes of halotolerant and halophilic microorganisms. *Journal of Bioenergetics and Biomembranes*, 21(1), 93–113.
- Shivanand, P., & Mugeraya, G. (2011). Halophilic bacteria and their compatible solutes - osmoregulation and potential applications. *Current Science*, 100(10), 1516–1521.
- Stuckey, I. V. & D. C. (2009). Effect of fluctuations in salinity on anaerobic biomass and production of soluble microbial products (SMPs), 165–175.
- Tchobanoglous, G., Burton, F. L., & Stensel, H. D. (2003). *Wastewater Engineering: Treatment and Reuse*. Metcalf & Eddy, Inc. Engineering (Vol. 4).
- Uygur, A., & Kargi, F. (2004). Salt inhibition on biological nutrient removal from saline wastewater in a sequencing batch reactor. *Enzyme and Microbial Technology*, 34(3–4), 313–318.
- Vidal, G., Aspé, E., Martí, M. C., & Roeckel, M. (1997). Treatment of recycled wastewaters from fishmeal factory by an anaerobic filter. *Biotechnology Letters*, 19(2), 117–121.
- Vymazal, J. (2014). Constructed wetlands for treatment of industrial wastewaters: A review. *Ecological Engineering*, 73, 724–751.
- Vyrides, I., & Stuckey, D. C. (2009). A modified method for the determination of chemical oxygen demand (COD) for samples with high salinity and low organics. *Bioresource Technology*, 100(2), 979–982.
- Wood, E. (1967). *Microbiology of Oceans and Estuaries*. Elsevier Oceanography Series. Elsevier Publishing Company.
- Zahran, H. H. (1997). Diversity, adaptation and activity of the bacterial flora in saline environments. *Biology and Fertility of Soils*, 25(3), 211–223.
- Zambrano, R. (2012). Tratamiento anaerobio de aguas residuales provenientes de la industria del descarte. Centro de Investigación y Desarrollo Tecnológico en Electroquímica.

**Capítulo 2 Desarrollo de un modelo de inteligencia artificial, basado en redes neuronales y algoritmos genéticos, para la optimización de un proceso de tratamiento de aguas residuales salinas.**

## **1. INTRODUCCIÓN.**

### **1.1. Uso de inteligencia artificial para optimización de procesos de tratamiento de aguas residuales.**

Es necesario resaltar que, a pesar de la capacidad de biodegradación de algunos procesos biológicos frente a aguas residuales salobres con diferentes características, estos no son del todo eficientes en la remoción de los contaminantes, por lo que se recomienda el uso de un post-tratamiento para dar al agua residual la calidad necesaria para cumplir con la normativa aplicable. Además del tratamiento previo es necesario maximizar la eficiencia de tratamiento de los sistemas utilizados. Esto se puede lograr mediante experimentación, que en el caso de los procesos anaerobios es tardada, por lo tanto, se recomienda explorar otras alternativas para la optimización del proceso. Una opción viable es el uso de modelos computarizados, como aquellos especializados en el tratamiento de aguas residuales. La adquisición de software especializado (Hydromantis GPS-X®, EDAR®) representa un costo considerable, además de que son de difícil manejo Otra alternativa es el uso de inteligencia artificial (IA), que consiste en el uso de computadoras para emular la inteligencia humana (Takeyas, 2007). Dentro de la diversidad de técnicas de IA que se emplean para el modelado y optimización de sistemas se destacan las redes neuronales artificiales acoplados y los algoritmos genéticos.

### **1.2. Redes neuronales artificiales (RNA).**

Una red neuronal es un modelo de IA que está inspirado en las redes neuronales biológicas. Se trata de una serie de neuronas interconectadas entre sí que poseen información de entrada. Estas neuronas procesan esta información y por una serie de métodos numéricos producen una respuesta basada en la relación que tienen los valores de entrada. Las RNAs requieren de un proceso de entrenamiento análogo a las redes neuronales biológicas, éste aprendizaje se adquiere a través de un método de supervisión, la RNA actualiza valores numéricos internos de forma iterativa buscando encontrar las relaciones no lineales entre la información de entrada (variables manipuladas y la respuesta de salida (variable monitoreada. Generalmente se utiliza un porcentaje (entre 60 y 80%) de una serie de datos

para entrenar la red. El resto de los datos (20-30%) son utilizados para probarla y validarla. En la **Figura 25**, se muestra la unidad fundamental de una RNA: el perceptron. Este cuenta con un vector de entrada ( $p$ ) y un valor de peso ( $w$ ) asociado a cada entrada. La suma del producto de cada entrada y su peso asociado generan una entrada neta ( $n$ ) que es evaluada por una función de transferencia ( $f$ ) definiendo el valor de salida  $a$  (Demuth, 2002).




Figura 25. Perceptron (Demuth, 2002).

### 1.2.1. Arquitectura de la red.

La red puede tener una o varias entradas, estas normalmente están definidas por el sistema y representan las variables manipulables de interés, la capacidad de procesamiento de la RNA depende del número de unidades de procesamiento, es por ello que pueden incluirse capas ocultas y podrán tener un número variable de neuronas de acuerdo a la complejidad del sistema a modelar. Las salidas son el resultado que se busca, por tanto, puede haber tantas salidas como valores se busca.

### 1.2.2. RNA de capa única.

En estas RNA (**Figura 26**) el vector de entrada  $p$  está conectado a cada una de las neuronas mediante la matriz de peso  $w$ . La neurona  $i$ -ésima tiene una función que suma el peso de su entrada y su parcialidad para formar su propia salida escalar  $n(i)$ . Todas las salidas  $n(i)$  forman una red de elementos de entrada  $S$ . Finalmente la capa de neuronas de salida forma una columna de vectores  $a$ . Las variables  $R$  y  $S$  representan: el número de elementos en el vector de entrada y el número de neuronas en cada capa respectivamente (Demuth, 2002).




Figura 26. RNA de una capa.

### 1.2.3. RNA multicapa.

En las RNA multicapas cada capa tiene un peso  $w$ , un vector de parcialidad  $b$  y un vector de salida  $a$ . En la **Figura 27** se muestra una red multicapa, para distinguir entre cada una de las capas se ha colocado un superíndice indicando el número de capa. La RNA tiene entradas  $p^1_R$  y salidas  $a^1_R$ . Esta salida será la entrada de la siguiente capa, la cual producirá la salida  $a^2_R$ , que al mismo tiempo será la entrada para la siguiente capa y así sucesivamente.

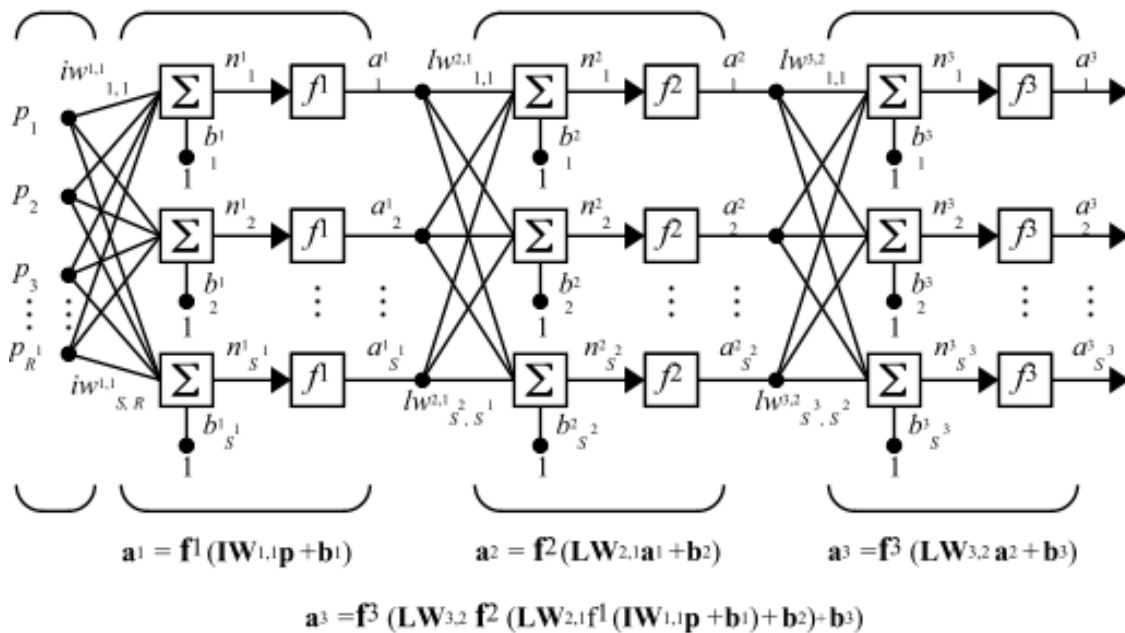


Figura 27. Arquitectura de una red neuronal multicapa (Demuth, 2002).

Cada una de las capas de una RNA multicapa tiene diferentes funciones. La primera capa es la capa de entrada, el resto se conocen como capas ocultas y la capa que produce las salidas de la red es conocida como capa de salida. La RNA de la figura superior muestra una red de 3 capas: una capa de salida y 2 capas ocultas. Algunos autores se refieren a la entrada como 4 capa.

Una manera más simplificada en la cual podemos estudiar lo que sucede en cada una de las neuronas es en el esquema de la **Figura 28**, donde la salida total de la neurona  $a$  esta dada por el resultado de la función de transferencia aplicada a la variable  $n$ , que es la suma ponderada de todas sus entradas (Demuth, 2002; Moctezuma, 2006)




Figura 28. Modelo computacional de una neurona.











### 1.3. Funciones de transferencia.

La función de transferencia se encarga de calcular el nivel de activación de la neurona en función de la entrada total, también expresa la salida. Las funciones se clasifican en tres tipos principales: funciones de transferencia de umbral (donde el valor de salida es un valor discreto que supera o no un valor establecido), funciones lineales y no lineales.

Tienen como objetivo: en primer lugar, limitar la salida de la neurona a un valor, para evitar que dicha salida no alcance valores demasiado grandes y segundo proporcionar características de no linealidad a la RNA lo cual es muy importante. Algunas de las funciones de transferencia más utilizadas se muestran en la **Tabla 13**.



Tabla 13. Funciones de transferencia más utilizadas en RNA.

Nombre	Símbolo	Relación entrada/salida
Limitador fuerte		$a=0 \quad n<0$ $a=1 \quad n\geq 0$
Limitador fuerte simétrico		$a=-1 \quad n<0$ $a=1 \quad n\geq 0$
Transferencia lineal positiva		$a=0 \quad n<0$ $a=n \quad n\geq 0$
Transferencia lineal		$a=n$
Logarítmica Sigmoide		$a = \frac{1}{1+e^{-n}}$
Base radial		$a = e^{-n^2}$
Transferencia saturado		$a=0 \quad n<0$ $a=n \quad 0\leq n\leq 1$ $a=1 \quad n>1$
Transferencia simétrico saturado		$a=-1 \quad n<-1$ $a=n \quad -1\leq n\leq 1$ $a=1 \quad n>1$
Tangencial hiperbólica Sigmoide		$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$
Base triangular		$a=1- n  \quad -1<n<1$ $a=0 \quad \text{otro caso}$

(Demuth, 2002; Moctezuma, 2006)

#### 1.4. Tipos de RNA.

En general las RNA se pueden clasificar de varias formas, estas clasificaciones dependerán de: forma de aprendizaje, tipos de funciones de activación y valores de entrada. La forma de aprendizaje de las RNA puede ser supervisada o no supervisada. Las funciones de activación se mencionaron en la sección anterior. Por último, los valores de entrada pueden ser binarios o continuos. Las principales RNA que podemos encontrar son: perceptron, ADALINE y Back-propagation.

##### 1.4.1. Perceptron.

Consiste en una sola capa de neuronas  $s$ , conectadas por  $R$  entradas mediante una serie de pesos  $w_{i,j}$  (**Figura 29**). La única neurona de salida procesa la información mediante una función de transferencia de tipo limitador fuerte o limitador simétrico fuerte. Aunque normalmente se utiliza el segundo para apresurar el aprendizaje de la red (Demuth, 2002).




Figura 29. Perceptron.

Se puede monitorear el desempeño del perceptron mediante un mapa de las regiones de decisión creadas por la red. Mediante este mapa se puede analizar los patrones de decisiones creados por la red. El perceptron separa las regiones en un hiperplano cuya ecuación está en función de los pesos de las entradas y el valor límite de la función de transferencia (Tanco, 2010).

#### 1.4.2. Perceptron multicapa.

Una variante del perceptron es el perceptron multicapa, que consiste en una RNA con varias capas ocultas y con alimentación hacia adelante. Esta red permite establecer regiones de decisión más complejas que las de dos semiplanos como lo hace el perceptron de un solo nivel. El perceptron simple solo puede establecer dos regiones separadas por una frontera lineal. En comparación un perceptron multicapa puede generar varias regiones convexas que se forman por las interacciones entre cada neurona de cada una de las capas siguientes. Cada uno de estos elementos se comporta como un perceptron simple.

La interrogante más grande, a la hora de diseñar este tipo de RNA es el criterio de selección del número de capas ocultas y las neuronas que cada una de estas contendrá. Estos números deben ser lo suficientemente grandes como para formar un área compleja y resolver el problema en cuestión y al mismo tiempo no debe ser demasiado grande, pues los pesos no serán confiables para los datos de entrada utilizados. Esta selección depende principalmente de la experiencia del diseñador (Demuth, 2002).

#### 1.4.3. Red Back-propagation.

Es una red con aprendizaje de tipo supervisado que utiliza un ciclo de propagación. Una vez que se aplica un patrón de entrada a la red como estímulo, este se propaga a las

siguientes capas, hasta generar una salida. La señal de salida deseada (target) se compara con la entrada y se calcula una señal de error para cada una de las salidas.

Las salidas de error se retro-propagan desde las neuronas de salida hacia cada una de las neuronas en las capas ocultas. En este proceso cada neurona de las capas anteriores recibe una señal en función de su contribución al error total de cada una de las salidas. El error de la capa de salida  $\eta$  es calculado de la siguiente manera:

$$e \triangleq \frac{1}{2} \sum_k (d_k - Y_k)^2$$

Ecuación 4. Cálculo del error  $e$  en la capa de salida.

Dónde:  $k$  es el número de neuronas en la capa de salida,  $d$  representa la salida deseada y  $Y$  la salida dada por la RNA. Un gradiente de  $e$  es considerado en el reajuste de los pesos, donde:

$$\Delta w_{kj}(m) = -\eta \frac{\partial e}{\partial w_{kj}}$$

Ecuación 5. Cálculo del gradiente de error.

$$w_{kj}(m + 1) = w_{kj}(m) + \Delta w_{kj}(m)$$

Ecuación 6. Cálculo de los nuevos pesos.

La tasa de aprendizaje  $\eta$  permite ajustar la velocidad y la precisión y el signo menos (-) indica una disminución del error hacia el mínimo. De la definición de perceptron, cada neurona recibe información numérica de los nodos de entrada, internamente la procesa y da una salida. Este proceso se realiza en dos etapas, cada unidad es pesada y sumada y la salida es representada por:

$$z_k = \sum_k w_{kj} x_j$$

Ecuación 7. Cálculo de salida con el reajuste de los pesos.

Finalmente, el resultado es utilizado como un argumento de una función de salida lineal o no-lineal ( $f_N$ ). (Chávez-Ramírez et al., 2010)

Este proceso tiene como función principal el aprendizaje de las neuronas de las capas intermedias, de manera que cuando reciben una entrada con ciertas características, las

neuronas lo pueden reconocer. Cuando las neuronas reciban una entrada que presente ruido o este incompleto, las neuronas de la capa oculta responderán con una salida activa, sí esta entrada contiene un patrón. Caso contrario, si la entrada no contiene el patrón que las neuronas han aprendido a reconocer, no generan una salida activa.

(Basogain-Olabe, 2005)

### 1.5. **Aplicaciones de RNA.**

Las RNA pueden ser aplicadas principalmente para resolver problemas relacionados con el reconocimiento de patrones, predicción, codificación, clasificación, control, optimización, etc. En el ramo comercial las RNA han sido utilizadas para estabilizar señales de ruido en llamadas de larga distancia.

En la industria aeroespacial como un piloto automático de alto desempeño, sistemas de control de tráfico aéreo, análisis de riesgo de vuelos, entre otras aplicaciones. Las aplicaciones varían dependiendo de las necesidades del ramo. En general, como se mencionaba anteriormente, son utilizadas en el reconocimiento de patrones y predicción de datos. Para aplicaciones más complejas requieren del apoyo de otros sistemas de inteligencia artificial.

### 1.6. **Algoritmos genéticos (AG).**

Son métodos de búsqueda probabilísticos basados en el proceso de selección natural y recombinación. Combinan la supervivencia de los más compatibles con una información ya aleatorizada, intercambiada para construir un algoritmo de búsqueda que tiene algunas de las capacidades de innovación de la búsqueda humana (Rodríguez-Piñero, 1960). Estos métodos de búsqueda utilizan información histórica para buscar un nuevo resultado que se espera, produzca mejores resultados. Pueden ser aplicados a problemas lineales o no lineales (Čepin, 2011).

En la naturaleza, los organismos vivos resuelven problemas de adaptabilidad a problemas cotidianos sin siquiera proponérselo, ejemplo de este tipo de problemas son el eludir a un depredador, o el depredador atrapar a su presa. Este tipo de “problemas” naturales son resueltos durante generaciones mediante la evolución, al final los organismos que desarrollan este tipo de capacidades son aquellos que sobreviven, ya sea porque escapan del

depredador, o porque atrapan a su presa y aseguran su supervivencia. Este proceso es conocido como el proceso de la selección natural, sigue la teoría de Darwin en la que se indica que solo sobrevivirán los organismos más fuertes.

La IA basada en AG es una técnica robusta que puede tratar con éxito una gran variedad de técnicas para resolver problemas específicos de diferentes áreas. Sí bien no siempre encuentran la solución al problema buscado, en general dan una solución a un nivel aceptable. Para dar la solución al problema el programador dará a los algoritmos las reglas de selección para llegar a la mejor solución. Estas reglas pueden ser alteradas para llegar a un resultado esperado o bien, para analizar múltiples hipótesis acerca de cómo opera un sistema (Coello, 1995).

### 1.7. **Representación de un algoritmo genético.**

En la naturaleza los organismos están compuestos de células. Estas células tienen toda la información genética del organismo en los cromosomas, que a su vez se pueden dividir en genes (Rodríguez-Piñero, 1960). En los AG los cromosomas representan un candidato a la mejor solución que se busca. Sus genes están representados por una codificación de la información del cromosoma, esta codificación puede mostrarse de dos maneras: mediante codificación binaria o por los valores reales (Čepin, 2011). Para aplicar un AG es necesario establecer el tipo de codificación que se utilizará.

Una vez seleccionada la representación numérica del AG se selecciona la función de adaptación de cada uno de los “organismos” (posibles soluciones). Esta función de adaptación proporciona a un organismo un valor numérico. Este valor está relacionado directamente con la solución que se busca, donde el óptimo global recibe la mayor puntuación, mientras más cercano al óptimo global es la solución, mayor puntaje recibe.

Una vez seleccionadas estas dos variables, es necesario generar una población inicial. La población inicial normalmente es creada mediante generación aleatoria, cada uno de los individuos de esta población inicial representa una posible solución al problema a analizar (MathWorks, 2005). Después de que la población inicial es creada la reproducción de las poblaciones tiene lugar mediante la selección, cruce y mutación. Estos operadores son utilizados para asegurar la reproducción de los individuos (Čepin, 2011).

### 1.7.1. Selección.

Este operador selecciona un individuo de la población en función de su capacidad, cuanto más capaz es el individuo mayor su probabilidad de selección para reproducción. Existen algunos métodos de selección utilizados en esta etapa. Los métodos pueden ser de ruleta, rango o torneo.

En el método de ruleta cada uno de las posibles soluciones tiene asignada un área en una ruleta, esta área está definida por el valor de la función de adaptación de cada uno de los individuos, así aquel con mayor valor tendrá un área mayor. En la **Tabla 14** se muestra una serie de datos que pueden ser solución de un problema cualquiera, cada uno de estas posibles soluciones tiene un valor de aptitud definido. Con estos valores se construye la **Figura 30**.

Tabla 14. Ejemplo de posibles soluciones para un problema cualquiera.

Cromosoma	Cadena	Aptitud	% del total
1	11010110	254	24.5
2	10100111	47	4.5
3	00110110	457	44.1
4	01110010	194	18.7
5	11110010	85	8.2
Total		1037	100

Con los porcentajes mostrados en la columna 4 se puede crear la ruleta. Una vez creada la ruleta se procede a girarla un número determinado de veces. Debido a que cada uno de los individuos ocupa un área dentro de la ruleta, todos tienen una probabilidad de ser seleccionados, pero para aquellos que ocupan un área mayor se espera que sean seleccionados más veces (Coello, 1995).




Figura 30. Ruleta de posibles soluciones creada.

El método de selección por rango es una variante del método de ruleta. Está diseñado para prevenir una convergencia prematura como alternativa a la selección por aptitud proporcional. La probabilidad de selección de cada individuo dependerá principalmente del rango y no del valor de aptitud. La selección por rango tiene algunas ventajas frente a la selección por ruleta, por ejemplo, el uso de este método puede llevar a una convergencia prematura. La exclusión también puede ser una desventaja, pues en algunos casos es importante conocer que un individuo es mucho más apto que el individuo con el valor de aptitud más cercano a este (Čepin, 2011).

En el método de selección por torneo los individuos compiten de manera aleatoria unos contra otros en grupos de pares. De esta manera los individuos con el valor de aptitud mayor son los seleccionados. Una vez realizada la selección de los mejores individuos, tiene lugar el cruce de estos. En esta etapa los individuos ganadores intercambiarán material cromosómico y darán lugar a la nueva generación (Rodríguez-Piñero, 1960).

### 1.7.2. Recombinación o cruce.

La cruce de los individuos puede ser mediante el cruce en un punto en específico, donde se establece de manera aleatoria un punto de cruce en la cadena de genes del individuo (**Figura 31**). Otra forma de cruce es mediante 2 puntos de cruce, donde se seleccionan dos puntos de manera aleatoria para intercambiar material genético entre dos individuos (**Figura 32**).




Figura 31. Cruce en un punto.




Figura 32. Cruce en dos puntos.

Una desventaja de estos métodos de cruce es que no se agrega nueva información al problema, es decir cada dato que se introdujo al modelo es pasado a las siguientes generaciones en diferentes combinaciones. Estos métodos de cruce funcionan bien en aquellos casos donde se utiliza una representación binaria. En estos casos, la adición de nueva información al problema recae solamente en la mutación. Para solucionar estos problemas se propuso un método donde se combinan valores aleatorios de los dos padres para producir nuevos valores en la descendencia que estos producen (**Ecuación 8**)

$$x_{1nuevo} = x_{mn} - r \times (x_{mn} - x_{dn})$$

$$x_{2nuevo} = x_{dn} + r \times (x_{mn} - x_{dn})$$

Ecuación 8. Método para introducir nuevos valores al problema.

Donde  $r$  es una variable aleatoria entre 0 y 1 y  $x_{mn}$  y  $x_{dn}$  son las diferentes variables que encontramos en los padres. La creación de nuevos valores puede realizarse utilizando el mismo valor de  $r$  para cada variable o utilizando un valor diferente de  $r$ .



### **1.7.3. Mutación.**

Es un operador que permite la reaparición del material genético, que se perdería si solo se utiliza la recombinación. Este operador asegura que la convergencia del algoritmo no se limite solamente al mínimo local. El número de mutaciones se establece en el algoritmo y generalmente se utiliza un porcentaje muy bajo del total de individuos.

Se recomienda que en la solución de problemas de gran escala se utilice un valor variable de mutación. Se recomienda que en las primeras generaciones este valor sea elevado, pues permitirá una exploración amplia del universo de soluciones. En el caso de generaciones posteriores se recomiendan valores más bajos, pues de lo contrario un gran número de organismos mutados podrían provocar la pérdida de un buen material genético (Čepin, 2011).

### **1.8. Características principales de los AG.**

Los AG son capaces de trabajar con una codificación de un conjunto de parámetros y no con los parámetros mismos. Trabajan con un conjunto de puntos y no con un solo punto y su entorno. Algo importante que es necesario mencionar es la capacidad de estos a trabajar sin necesidad de conocimientos específicos del problema, pues en ocasiones se pueden obviar algunas posibles soluciones. En la **Tabla 15** se muestra algunas ventajas que tienen este tipo de modelos de IA frente a otros métodos de optimización como métodos numéricos y diseño experimentos.

Tabla 15. Ventajas y desventajas de los algoritmos genéticos.

<b>Ventajas</b>	<b>Desventajas</b>
Buscan varias soluciones al mismo tiempo	Es necesario hacer una representación del problema y elegir una buena función objetivo
Pueden resolver tanto problemas lineales como no lineales	Es necesario seleccionar correctamente los parámetros del algoritmo genético: población, ritmo y mutación de cruzamiento tipo y fuerza de selección
Manejan muchos parámetros al mismo tiempo	Pueden dar a lugar a falsos positivos o falsos negativos, en caso de no seleccionar de manera adecuada la función objetivo
Carecen de lógica o conocimiento del problema, por lo tanto analizan el universo de posibilidades, desde la más lógica hasta la menos probable.	Pueden dar a lugar a óptimos prematuros, ocasionando la convergencia del algoritmo en el óptimo local en vez del óptimo global
	No son recomendados para resolver problemas analíticos.

(MathWorks, 2004)

## **2. ANTECEDENTES.**

### **2.1. Modelos de IA aplicados a sistemas de tratamiento de aguas residuales.**

Como ya se mencionó, la inteligencia artificial es una metodología que recientemente se utiliza para la optimización o predicción en numerosas industrias como en el ramo bancario, industrial, farmacéutico, etc. (Demuth, 2002). Recientemente se ha dado importancia a la aplicación de estos modelos dentro del tratamiento de aguas residuales, en la predicción del comportamiento de un sistema bajo ciertas condiciones de operación, diseño y optimización. Los resultados que se pueden obtener son aceptables, además al ser modelos de predicción pueden trabajar con datos históricos sin necesidad de realizar experimentación. Otro uso de estos modelos de IA es en la optimización de las diferentes unidades que tiene una planta de tratamiento de aguas residuales. Se ha comprobado que el uso de modelos de inteligencia artificial (basados en RNA y AG) pueden emplearse para encontrar las condiciones óptimas de operación de un sistema de tratamiento de aguas residuales, sin necesidad de invertir tiempo ni costos en experimentación (Soleimani et al., 2013).

Los modelos de IA se han empleado en el diseño de diferentes sistemas de tratamiento de aguas residuales como humedales (Akratos et al., 2008), mediante el uso de datos históricos experimentales de sistemas de tratamiento similares. Incluso existen modelos de IA que pueden aplicarse en la selección de sistemas de tratamiento que traten un efluente con cierta concentración de contaminantes y que al mismo tiempo, las unidades seleccionadas generen un efluente que cumpla con la normatividad (Castro et al., 2007).

El desempeño de un sistema de tratamiento puede ser estimado mediante un perceptron multicapa. Los diferentes parámetros medidos en estos sistemas como: la demanda química y bioquímica de oxígeno (DQO y DBO respectivamente), nitrógeno Kjeldahl y sólidos suspendidos totales (SST); parámetros que utilizan reactivos tóxicos, son costosos y requieren un tiempo de experimentación, en el caso de la DBO de hasta 5 días. Para reducir tanto costos, reactivos y tiempo, Ráduly (2007) utilizó un perceptron multicapa para estimar el desempeño de una planta de tratamiento de lodos activados de mezcla completa.

También se han utilizado modelos que utilizan RNA acopladas a AG para la predicción del desempeño de una planta de tratamiento a escala real. El sistema de IA puede estimar el comportamiento de los próximos meses sin ningún problema (Fang et al., 2010). Utilizando una RNA entrenada con datos históricos reales, Mjalli et al. (2007) elaboraron un modelo capaz de predecir la composición de DQO, DBO y SST en el efluente al introducir un valor de DQO. En otro caso similar una RNA fue entrenada para simular y predecir la composición de DQO, carbono orgánico total (TOC), sólidos suspendidos en el licor mezclado (SSLM), grasas y aceites en el efluente generado por un bio-reactor de membrana, que trata un agua residual aceitosa. Los datos simulados y los reales tuvieron una buena correlación (Pendashteh et al., 2011). Estos modelos también pueden ser utilizados para predecir el desempeño de sistemas de tratamiento al remover contaminantes muy específicos como nutrientes. Aguado et al. (2009) utilizaron una RNA en la predicción del desempeño de un reactor biológico secuencial que remueve fósforo y nitrógeno del agua residual. Estos modelos también se han empleado para describir la cinética de degradación de fenol en un agua residual sintética tratada por un reactor de lecho fluidizado, inoculado con *Pseudomonas sp.* (Venu-Vinod et al., 2009).

La IA también se ha utilizado para optimizar sistemas de tratamiento. En estos modelos se ha predicho el comportamiento de una planta a escala real. Además el modelo generado fue capaz de ofrecer valores de ciertas condiciones de operación, en las cuales el sistema generó el efluente con mejor calidad y al más bajo costo de operación (Dragoi et al., 2013; Iqbal & Guria, 2009).

Las RNA también se han aplicado en la predicción de la eficiencia de remoción de compuestos de difícil descomposición como los antibióticos que son removidos mediante sistemas de tratamiento por oxidación avanzada como el proceso Fenton (Elmolla et al., 2010). La variante del proceso Fenton (Foto-electro Fenton) también se optimizó mediante el uso de IA con RNA, el modelo maximizó la degradación de colorantes azo (Zarei et al., 2010).

El uso de los sistemas de IA se extiende a la mayoría de los procesos, los procesos biológicos aerobios y de oxidación avanzada se han optimizado, diseñado o emulado su comportamiento mediante RNA, AG o combinación de estos. Existen estudios que

probaron que estos modelos también fueron eficientes en la predicción del comportamiento de procesos anaerobios. Rangasamy et al. (2007) emplearon una RNA para predecir eficientemente: la alcalinidad, el pH en el efluente, producción de biogás y DQO en el efluente, utilizando como entradas solo el pH y DQO del afluente en un reactor anaerobio de lecho empacado. Otro caso donde se pudo predecir la producción de residuos de interés como el hidrógeno, producto de la degradación de la materia orgánica, fue presentado por Mu y Yu (2007). Usando un modelo basado en RNA acopladas a AG lograron predecir la producción de hidrógeno por un lodo granular en un reactor UASB. No solo la producción de hidrógeno se ha podido estimar. Singh (2010) utilizó RNA para predecir la cantidad de DQO y DBO en un efluente tratado por un UASB, utilizando solo 4 variables de entrada.

## **2.2. Condiciones de operación y eficiencias reportadas en el tratamiento de aguas residuales salobres.**

Los modelos de IA fueron utilizados, en su mayoría para la predicción del comportamiento de sistemas de tratamiento de aguas residuales con el fin de evitar o disminuir el tiempo de experimentación. Pero como se mencionó anteriormente, los modelos de IA pueden usarse para la optimización de procesos. Existen algunos estudios que se realizaron de manera experimental. Las condiciones experimentales utilizadas como: agua residual tratada, temperatura utilizada, OLR, salinidad y los resultados obtenidos, se resumen en la **Tabla 16**.

Tabla 16. Condiciones de operación y resultados en estudios previos donde se usaron sistemas anaerobios.

Autor	Efluente	Proceso	Condiciones			Inóculo	Eficiencia de remoción (%)
			T°C	OLR (KgCOD/m <sup>3</sup> .d)	Salinidad (g/L)		
Boardman et al. (1995)	Procesado de Almeja	UASB	32	13.8	7.7-26.3	Convencional	77
Guerrero y Omil (1997)	Procesado de Pescados	ACS	37	1-8	13.6-33.7	Convencional	70-90
Habets et al. (1997)	Inulina	UASB	35	23-32	10	Convencional	65-80
Kimata-Kino et al. (2011)	Sintética, base sacarosa y acetato	UASB	35	18.3	20	Convencional	>90
Lefebvre et al. (2007)	Sintética	AR	37	8.08	20	Convencional	99.9
Lefebvre et al. (2006)	Licor de remojo de curtiduría	UASB	≈30	0.5	72	Lodo que trata un AR similar	78
Li et al. (2014)	Sintética (base sacarosa). Alto contenido de sulfatos	UASB	35	0.25	12-28	Convencional	52
Mosquera-Corral et al. (2001)	Efluente tratado de industria de enlatado de pescado	USBF	37	1-1.25	-	Lodo que trata un AR similar	70-90
Prasertsan et al. (1994)	Procesado de mariscos	AF	30-35	0.3-1.8	0.4-4.0	Lodo que trata un AR similar	65-75
Vidal et al. (1997)	Procesado de mariscos	AF	37	14.3	30	Sedimento marino	80

UASB: Reactor anaerobio de flujo ascendente; AF: Filtro anaerobio; ACS: Sistema de contacto anaerobio; USBF: Filtro híbrido anaerobio y de lecho de lodos de flujo ascendente r; UAF: Filtro anaerobio de flujo ascendente.

### **3. METODOLOGIA EXPERIMENTAL**

El primer paso para crear una red neuronal es la recolección de los datos (reales o históricos), es necesario tener una serie de datos reales que contengan tanto los valores de entrada que queremos utilizar como los valores de salida. Estos datos tienen que ser suficientes para poder usar un gran porcentaje de ellos en el entrenamiento, evaluación y validación de una RNA. Los datos fueron colectados mediante experimentación en un reactor UASB donde se monitoreó, carga orgánica volumétrica (OLR), temperatura (T°C) y salinidad o conductividad; como variables de entrada y como variable de salida la eficiencia de remoción.

Una vez colectados los datos se probaron diferentes configuraciones de RNA donde se varió el número de capas y el número de neuronas en las capas ocultas; esto con el fin de conocer la arquitectura de la red. Debido a que no hay una metodología establecida para seleccionar estos parámetros, la arquitectura de la RNA se definió a prueba y error. La arquitectura de la RNA seleccionada fue aquella que al validarla tuvo el menor error cuadrático medio (MSE) y porcentaje de error medio absoluto (MAPE).

Una vez obtenida la RNA se estableció a esta como función de adaptación del AG, para generar vectores aleatorios virtuales de OLR, T°C y salinidad o conductividad, para evaluar las posibles combinaciones en el rango de operación definido en la etapa de experimentación. Esta función tuvo el objetivo de alimentar un AG que buscó la combinación de OLR, T°C y salinidad que produjo el menor error, o en este caso, la mayor eficiencia de remoción.

Se monitorearon de manera experimental los parámetros de entrada y el efecto de estos en la eficiencia de remoción. Para ello se obtuvo combinaciones que permitieron la máxima eficiencia de remoción, así como aquellas mezclas donde la eficiencia de remoción fue la más baja. Esta búsqueda de condiciones óptimas y pésimas de operación fue necesaria para entrenar a la RNA, de esta manera se pudo encontrar una relación no lineal entre estas combinaciones y la remoción de DQO.

Con la RNA acoplada al AG se realizaron 100 corridas que fueron clasificadas en grupos de combinaciones, las cuales representaban a aquellas combinaciones de condiciones, que

virtualmente produjeron las mejores de eficiencias de remoción. Una vez obtenidas las diferentes combinaciones se seleccionó aquella que se adecuó a lo que se buscaba, aquella que de acuerdo al modelo de IA generó la mayor eficiencia de remoción, con la menor cantidad de insumos.

Se monitoreó también la producción de biogás en el sistema, medida como  $\text{m}^3\text{CH}_4/\text{Kg DQOrem.}$ , pues debido a que este subproducto de la descomposición de la materia orgánica es aprovechable, se buscó encontrar una combinación que además de permitir una alta remoción de DQO, permitió una alta producción de biogás. Los resultados obtenidos mostraron que la cantidad de metano que se obtuvo era demasiado baja, tanto como para descartar su aprovechamiento.

Finalmente, una vez obtenidas las condiciones óptimas de operación propuestas por el AG, se evaluó experimentalmente la eficacia del AG. Para ello, se introdujo al reactor el agua residual sintética con los valores de OLR,  $T^\circ\text{C}$  y salinidad propuestos por el modelo de IA. La calidad del efluente fue evaluada para medir la cantidad de DQO removida. Se hizo una prueba más modificando los valores de las condiciones propuestas, para analizar el efecto de este aumento en la variable de respuesta.



## 4. RESULTADOS Y DISCUSIÓN

### 4.1. Colecta de datos.

Utilizando la receta del agua residual sintética que se empleó en el acondicionamiento del reactor a alta salinidad y alta carga orgánica, se alimentó al reactor UASB usando diferentes concentraciones de OLR, T°C y salinidad. Los valores utilizados fueron aleatorios. Los datos obtenidos en esta etapa se muestran en la **Figura 33**.

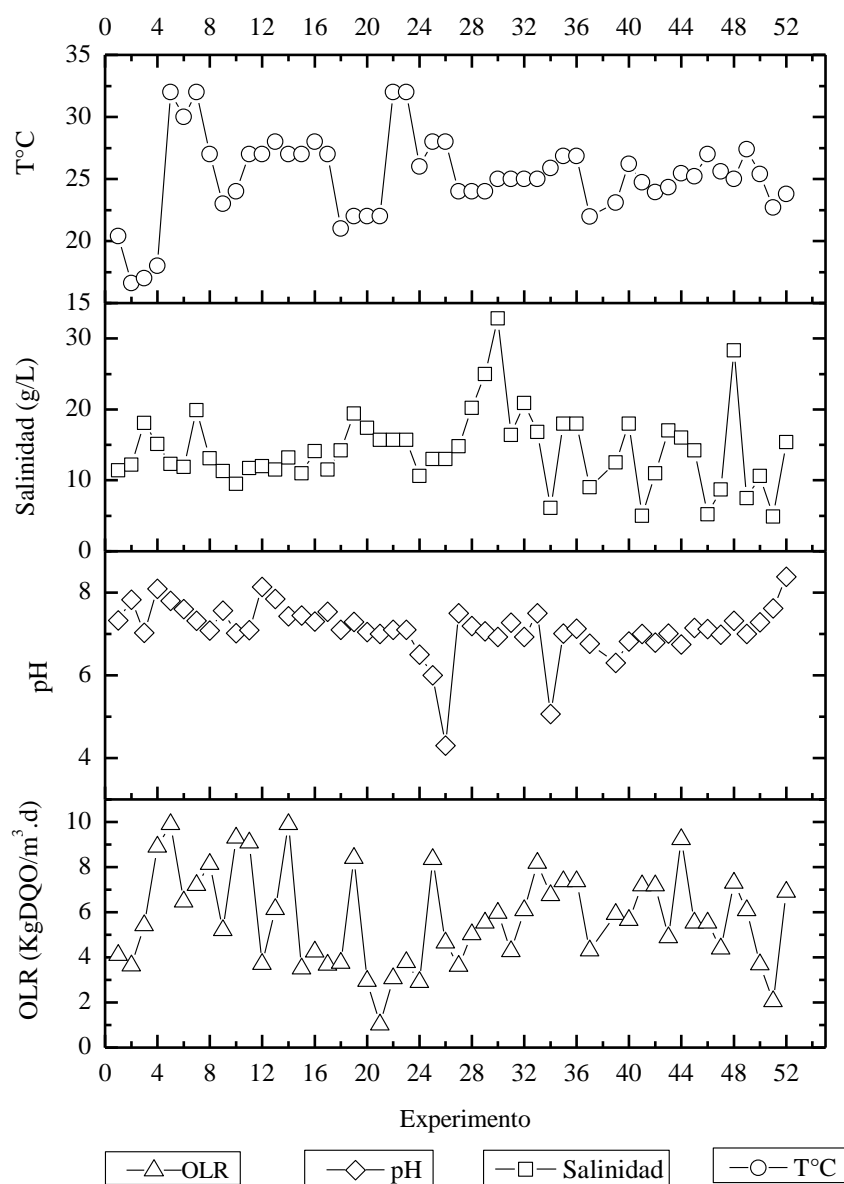


Figura 33. Datos experimentales de OLR, pH, T°C y salinidad; monitoreados durante la experimentación.

El pH del reactor también fue monitoreado, pues una disminución de este parámetro dentro del reactor significaba una caída abrupta de la cantidad de biogás producida, así como de la eficiencia de remoción. Este valor estaba ligado directamente a la OLR, razón por la cual no se consideró como variable de entrada para la RNA. Se observó que al igual que en la etapa de experimentación, aumentos repentinos en la OLR ocasionaban disminución del pH a valores por debajo de 6.

Otros valores ligados directamente a la OLR son la cantidad de sustrato utilizado (DQO) y el TRH. Para variar los valores de OLR durante la experimentación, se varió DQO, TRH y gasto. La variación de estos valores se muestra en la **Figura 34 y 35**.




Figura 34. Variación del TRH y gasto durante la etapa experimental.




Figura 35. Valores de DQO de entrada y salida obtenidos durante la experimentación.

Los rangos de valores utilizados durante la experimentación fueron se muestran en la **Tabla 17**.

Tabla 17. Condiciones utilizadas en el reactor UASB durante la fase de recolección de datos.

Parámetro	Rango
Datos recolectados	51
Carga orgánica volumétrica (Kg DQO/m <sup>3</sup> .d)	1.02-9.9
Temperatura (°C)	16.6-32
Conductividad (mS/cm)	5.0-32.8
Eficiencia de remoción (%)	20.71-89.01
Producción de biogás (m <sup>3</sup> CH <sub>4</sub> /Kg DQO removido)	0-0.109

Esta parte del estudio consistió en la generación de datos experimentales reales, aun así, se encontró algunas condiciones a las cuales el valor de eficiencia de remoción y producción

de biogás fueron máximos. La **Tabla 18** muestra las condiciones a las que se obtuvieron los mejores y los valores mínimos.

Tabla 18. Máximos y mínimos de % remoción y biogás producido.

Valores	Parámetro entrada			Parámetro salida	
	OLR (KgDQO/m <sup>3</sup> .d)	T°C	Salinidad (g/L)	% Remoción	Biogás (m <sup>3</sup> CH <sub>4</sub> /KgDQOrem)
Máximos	4.25	28	14.1	89.01	-
	9.2	25.45	16.2	-	0.108
Mínimos	2.05	22.7	4.9	22.79	-
	7.36	26.86	18	-	0

Los resultados obtenidos muestran valores de respuesta muy variados. Se observa en la **Figura 36**, que la máxima eficiencia de remoción alcanzada fue disminuyendo gradualmente. Pues después del 89.01% la remoción de DQO más alta, lograda después de este valor fue de 81%, en cuanto a la producción de biogás, los valores obtenidos fueron muy bajos con respecto a los valores presentados por Kimata-Kino et al., (2011) y Stuckey (2009).




Figura 36. Comportamiento de la eficiencia de remoción y la producción de metano durante la experimentación.

Como se mostró aquí, la cantidad de metano obtenida depende mucho de la carga orgánica utilizada y la temperatura. Debido a que la cantidad de DQO reportada en los estudios anteriores son valores muy elevados, se utilizan TRH muy elevados para disminuir la OLR ya que pues las mejores producciones de metano se obtuvieron a OLR bajas. Además, el tiempo de aclimatación también es elevado. Estas consideraciones hacen inviable el diseño de un sistema de tratamiento anaerobio para una buena producción de biogás, pues el volumen del reactor, necesario para alcanzar estas OLR es demasiado, incrementando los costos de construcción considerablemente. A esto, hay que añadir el costo de un sistema que mantenga la temperatura del reactor valores entre 35 y 37°C.

Los valores de eficiencia de remoción obtenidos durante la etapa experimental del presente estudio son valores similares a los que obtuvieron: Boardman et al. (1995) de 83% a

concentraciones de cloruro de 8.5 g/L y OLR de 13.8 Kg DQO/m<sup>3</sup>.d; al 80% obtenido por Guerrero y Omil (1997) a 7.5 g/L de Cl<sup>-</sup> y OLR de 5 Kg DQO/m<sup>3</sup>.d; el 80 % que logró Mosquera-Corral (2001) en un agua residual de la industria de enlatado de pescado con cargas orgánicas entre 1 y 1.25 Kg DQO/m<sup>3</sup>.d; a la remoción de DQO alcanzada por Omil et al. (1995; 1996) con valores entre 25 y 70% en un agua con DQO entre 10 y 60 g/L y salinidad cercana a la del agua de mar (30 g/L); al 75% que logró Prasertsan et al., (1994) con una OLR de 1 Kg DQO/m<sup>3</sup>.d en un agua con 3 g Cl<sup>-</sup>/L y al de Vidal et al. (1997) que obtuvieron eficiencias del 70% a salinidades de 30 g/L y OLR de 9.5 y 14.3 Kg DQO/m<sup>3</sup>.d aunque estos autores trabajaron con aguas residuales reales de difícil tratamiento. Las eficiencias reportadas por Lefebvre et al. (2007, 2006), quienes trataron agua residual sintética, fueron de hasta un 99%. Las condiciones de todos estos autores no se asemejan a las que se establecieron en la etapa experimental del presente estudio, pero si las condiciones de conductividad, OLR y temperatura usadas por algunos de estos autores, así como la respuesta producida en la eficiencia de remoción.

#### 4.2. **Diseño de una RNA.**

El primer paso para crear una RNA es la colecta de datos, (obtenidos en la sección 4.1); el siguiente paso es el diseño de la red. No existe una metodología establecida que permita definir las neuronas que tendrá la RNA en cada una de las capas, ni la cantidad de capas a utilizar (Mjalli et al., 2007). Aunque se pueden estimar, para encontrar una adecuada arquitectura, será necesario probar varias configuraciones y seleccionar aquella con menor MAPE y MSE. Cada una de las arquitecturas de la RNA se ensayó a prueba y error con el fin de encontrar el mejor ajuste de pesos dentro de la red. Recordemos que estos pesos se ajustan para que la RNA encuentre los valores que mejor representan la relación entre las variables de entrada y la salida. Algunas configuraciones probadas se muestran a continuación en las **Figuras 37, 39, 41 y 42**. En un principio se consideraba como una variable de salida a la producción de biogás, pero la cantidad producida fue muy baja, por lo tanto, se descartó como una de las variables a optimizar en el proceso. También fue considerado al pH en el efluente como variable de entrada, pero finalmente se decidió

probar con una RNA con 3 variables de entrada y 1 salida. En estas redes se varió el número de capas, neuronas y funciones de transferencia.

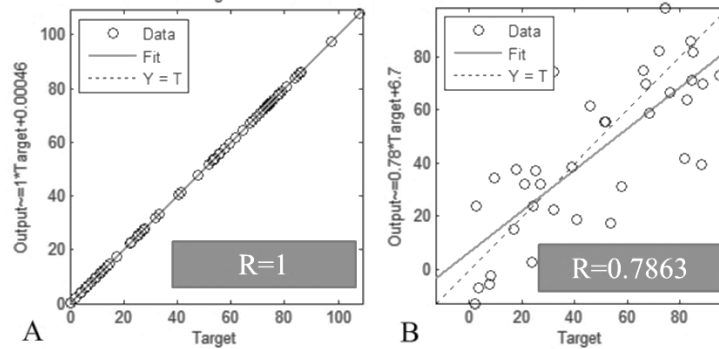


Figura 37. Mejor entrenamiento en una RNA con 4 entradas y 2 salidas. A) Ajuste de entrenamiento y B) valor de R para la etapa de prueba de la red.

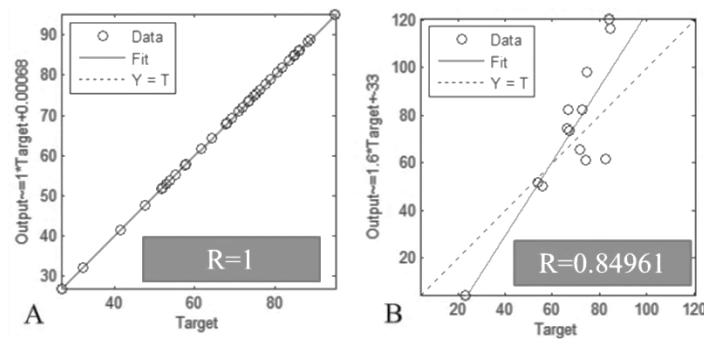


Figura 38. Mejor entrenamiento en una RNA con 4 entradas y 1 salida: A) Ajuste de entrenamiento y B) valor de R para la etapa de prueba de la red.

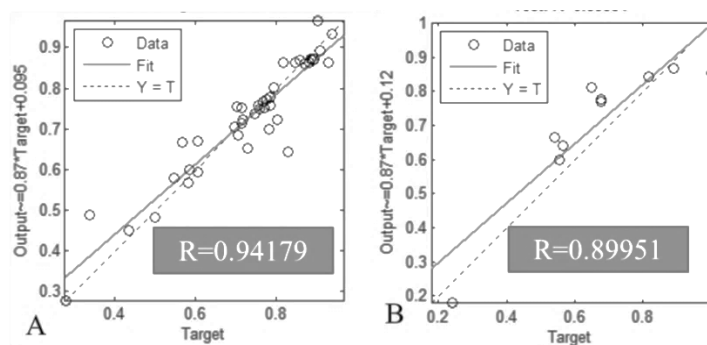


Figura 39. Mejor entrenamiento en una RNA con 3 entradas y 1 salida función de transferencia tangencial-tangencial: A) Ajuste de entrenamiento y B) valor de R para la etapa de prueba de la red.




Figura 40. Desempeño del entrenamiento de la RNA con 3 entradas y 1 salida funciones de transferencia tangencial-tangencial.

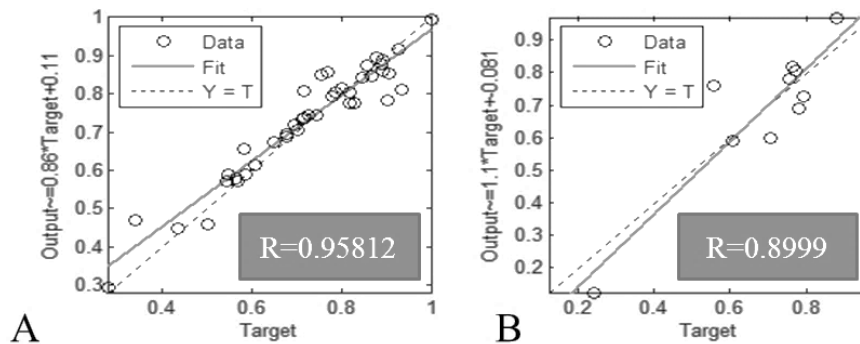


Figura 41. Mejor entrenamiento en una RNA con 3 entradas y 1 salida función de transferencia tangencial-logarítmica: A) Ajuste de entrenamiento y B) valor de R para la etapa de prueba de la red.






Figura 42. Desempeño del entrenamiento de la RNA con 3 entradas y 1 salida y funciones de transferencia tangencial-logarítmica.

En el presente estudio, la RNA seleccionada tiene la siguiente arquitectura: una RNA tipo Feed-Forward (RN-FF) de 4 capas: Una capa de entrada, con 3 variables (OLR, salinidad y temperatura); dos capas ocultas, una primera capa con 10 neuronas y una segunda capa con 5 neuronas; finalmente una capa de salida donde se utiliza a la eficiencia de remoción como las variables de respuesta. Para entrenar la RNA se utilizó el algoritmo Levenberg-Marquardt. Las funciones de transferencia utilizadas fueron del tipo logarítmicas. La relación datos de entrenamiento-prueba fue de 80/20 (Ver **Figura 43**). Un resumen de la arquitectura de la RNA, así como los parámetros que se utilizaron para validar su eficacia en la predicción de datos de eficiencia de remoción, se muestran en la

**Tabla 19.**

Tabla 19. Valores de parámetros para la mejor RNA encontrada.

Parámetro	Configuración
Neuronas en la primera capa oculta	10
Neuronas en la segunda capa oculta	5
Salidas	1
Mejor R	0.90039
RMSE	6.376
MAPE	9.226

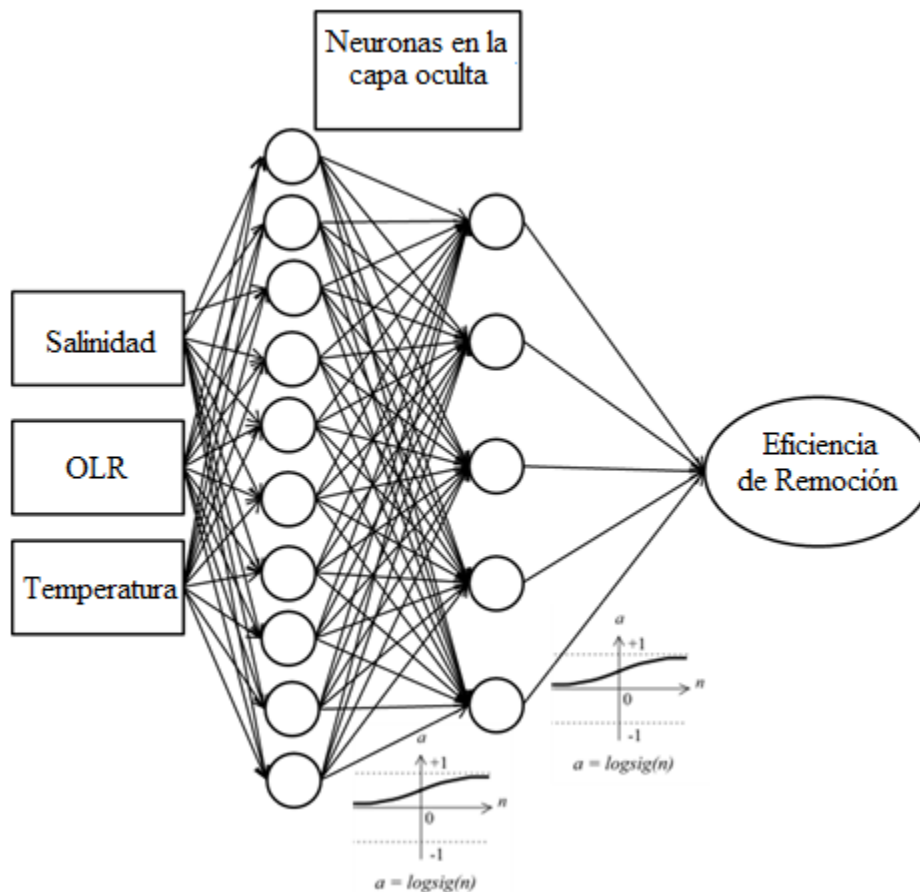


Figura 43. Arquitectura de la RNA para predicción del porcentaje de remoción.

En la **Figura 44** se muestran 2 gráficos, en el gráfico A, el entrenamiento de la RNA y en el gráfico B, la RNA crea datos similares a los datos reales y compara los resultados obtenidos

con los datos reales. Finalmente en la **Figura 45** la RNA realiza un gráfico del desempeño de la RNA en el entrenamiento y la evaluación de los datos, donde podemos ver como los datos evaluados por la RNA se ajustan a los datos de entrenamiento de la RNA. Uno de los criterios de selección de la RNA fue el gráfico de desempeño (**Figuras 40, 42 y 45**). En aquellas RNA, donde se obtuvieron los mejores valores de R, fue necesario analizar los gráficos de desempeño de cada una de las RNA con los mejores resultados. La RNA con el mejor desempeño produjo un gráfico cuya línea de tendencia de entrenamiento se ajustó a la línea de prueba de la red.

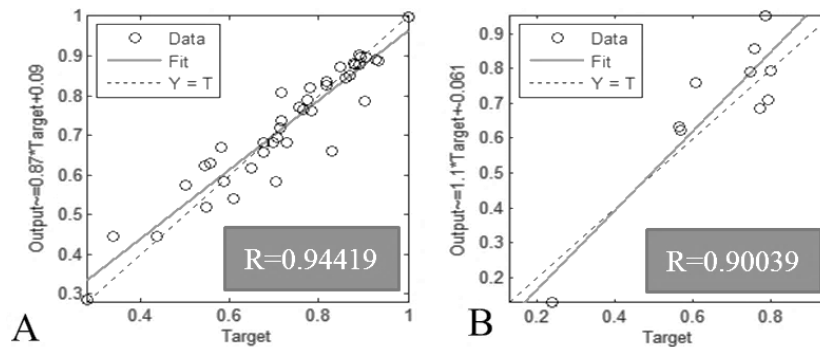


Figura 44. Mejor entrenamiento en una RNA con 3 entradas y 1 salida función de transferencia logarítmica-logarítmica: A) Ajuste de entrenamiento y B) valor de R para la etapa de prueba de la red.

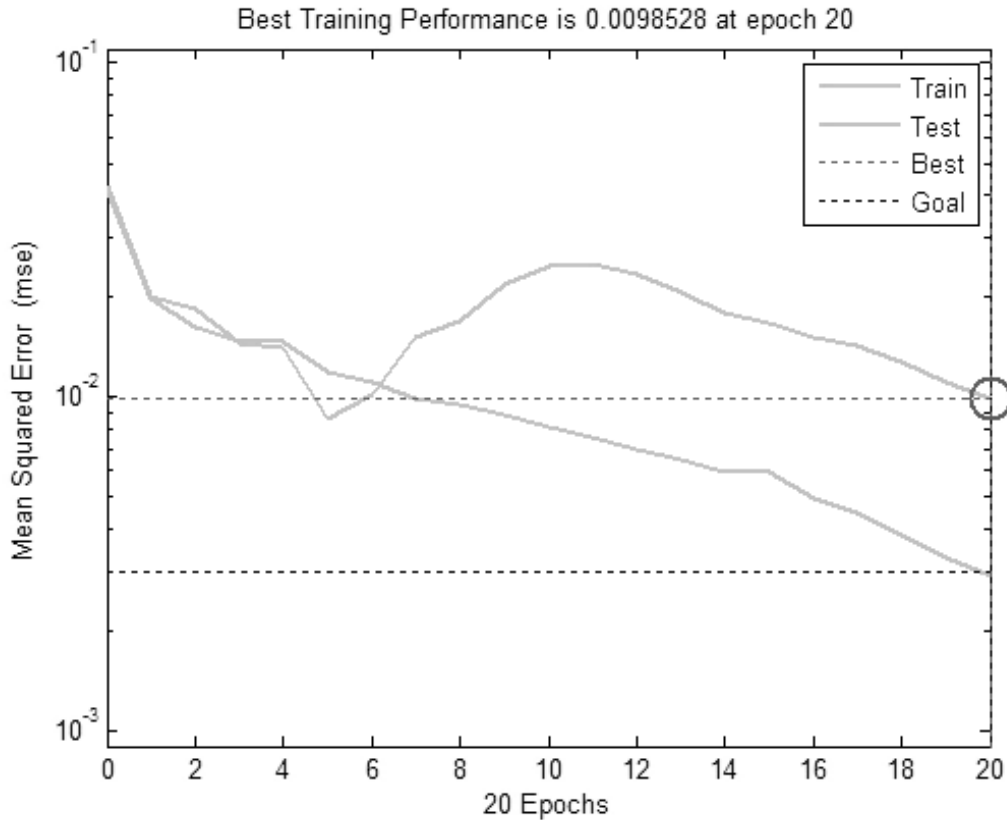


Figura 45. Desempeño de la RNA

#### 4.3. Optimización del sistema de tratamiento con AG.

El objetivo principal del AG fue encontrar las condiciones de operación óptimas en las cuales el reactor UASB alcanzó la máxima eficiencia al tratar un agua residual salobre con alta OLR y cuyos requerimientos de energía fueron mínimos. Una vez definida la arquitectura de la RNA y su eficacia en la predicción de eficiencia de remoción a partir de datos virtuales, se definió esta RNA como función, la cual alimentó al AG. Para la implementación del AG fue necesario definir ciertos parámetros (**Tabla 20**).

Tabla 20. Propiedades del AG.

Parámetro	Valor
Número de variables	3
Tamaño de la población inicial	20
Probabilidad de cruce	0.8
Conteo de organismos elite	2
Hijos	2
Tipo de cruce	Dispersa
Probabilidad de mutación	0.2
Valor inferior límite (Temperatura, OLR, Conductividad)	16.6, 1.02, 7.7
Valor superior límite (Temperatura, OLR, Conductividad)	32, 9.9, 39.3

Con estas condiciones, se hicieron alrededor de 100 simulaciones. Los datos obtenidos a partir de estas simulaciones se agruparon de acuerdo a las condiciones propuestas por el AG. Cada uno de estos grupos representó una posible solución al problema buscado: las condiciones óptimas de operación del reactor UASB.

El gráfico 3D mostrado en la **Figura 46** muestra la distribución espacial de cada una de las soluciones en el universo de soluciones. Se observa en el gráfico 4 grupos de combinaciones de condiciones de operación. Cada grupo, es virtualmente, la mejor solución a la búsqueda de la máxima eficiencia.




Figura 46. Grupos de posibles combinaciones.

Para seleccionar una combinación para evaluar el AG de manera experimental, fue necesario considerar las condiciones propuestas en cada uno de los grupos. Se graficaron los grupos por separado para observar de manera más detallada su distribución (**Figura 47**). En ocasiones los AG generan datos que es necesario analizar para la selección de una solución.

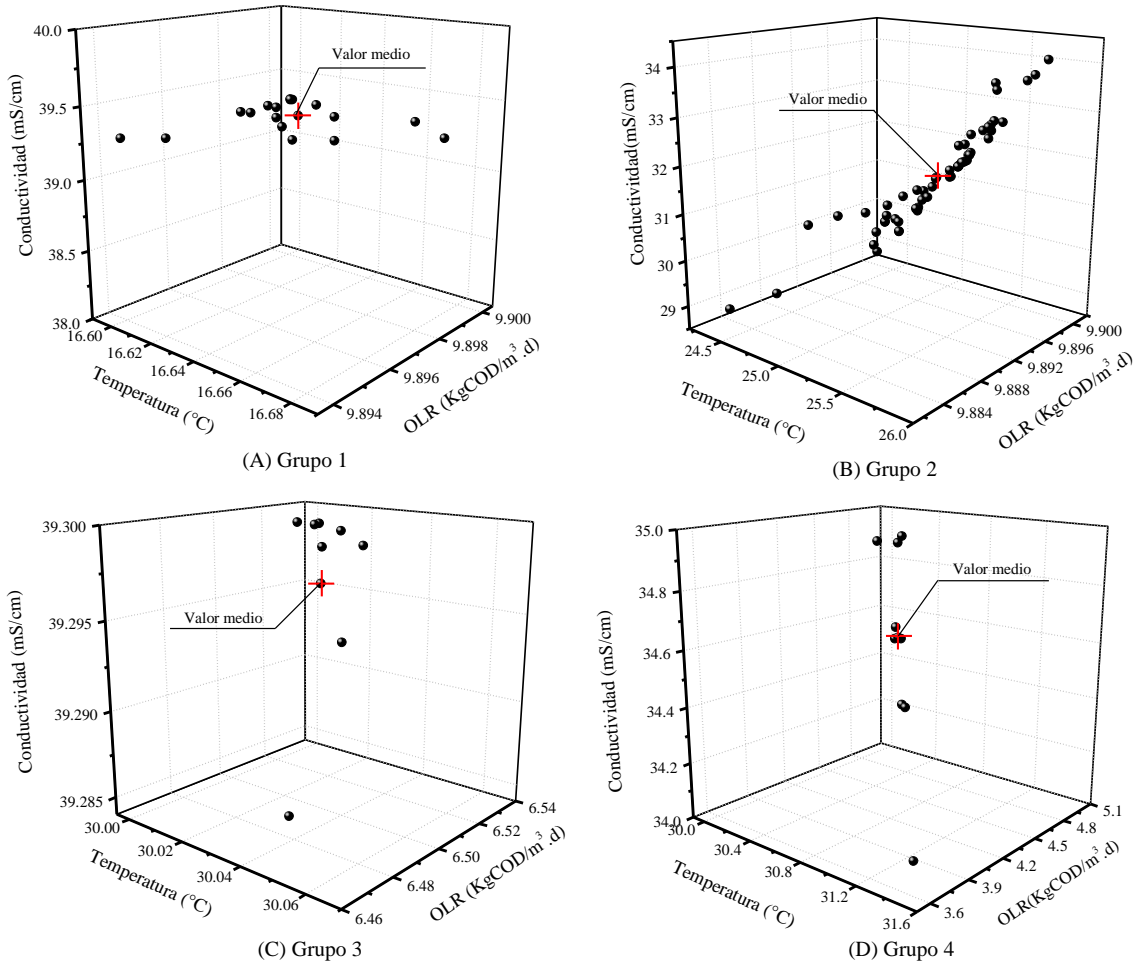


Figura 47. Grupos de combinaciones encontradas a partir del universo de soluciones.

A partir de las simulaciones hechas por el AG se encontraron tres grupos de combinaciones. Cada uno de estos grupos se clasificó en rangos de condiciones de operación. Los valores se sometieron a un análisis de intervalo de confianza para facilitar la selección de los valores a validar. Los valores seleccionados para validar el modelo de IA se muestra en la **Tabla 21**. Tanto los datos simulados crudos y aquellos sometidos a un análisis de intervalo de confianza fueron graficados.

Tabla 21. Grupos de combinaciones propuestas por el AG.

Grupo	Valores	Temperatura (°C)	OLR (Kg DQO/m <sup>3</sup> .d)	Conductividad (mS/cm)
A	Mínimo	16.601	9.898	38.975
	Medio	16.605	9.899	39.299
	Máximo	16.614	9.900	39.245
B	Mínimo	24.642	9.898	30.001
	Medio	25.053	9.899	31.368
	Máximo	25.478	9.900	32.674
C	Mínimo	30.001	6.492	39.299
	Medio	30.030	6.503	39.300
	Máximo	30.045	6.529	39.300
D	Mínimo	30.0223	3.671	34.085
	Medio	30.471	4.635	34.568
	Máximo	31.431	4.978	34.911

A partir de la tabla anterior se pudo observar la distribución de cada grupo y se identificó a la temperatura como el parámetro que presentó variaciones significativas en las condiciones propuestas. Mientras que la OLR y conductividad apenas presentaron diferencias de algunas décimas entre cada uno de los grupos de combinaciones.

Para seleccionar un rango de datos se discriminó algunos grupos de datos de la **Figura 46** y **Figura 47**. Con los datos seleccionados se realizó un nuevo gráfico tridimensional (**Figura 48**) que muestra de manera más clara los grupos de datos que se analizaron. A partir de este gráfico, se tomó la combinación de condiciones de operación para el reactor UASB.






Figura 48. Datos modelados procesados.

Los grupos de datos que se observan en la figura fueron graficados por separado con el fin de poder ver detalladamente la distribución de cada uno de los puntos. De acuerdo a lo que se busca y a la bibliografía, se seleccionó el grupo B de la **Figura 49** para validar experimentalmente el modelo de IA basado en AG y RNA. El criterio de selección fue el siguiente: la temperatura seleccionada corresponde a valores mesofílicos (Tchobanoglous et al., 2003), probados durante la etapa de experimentación, por lo tanto no requiere de adición de energía; la OLR es elevada y la salinidad, aunque no es la mayor cantidad probada durante la experimentación, es un valor considerable a probar.

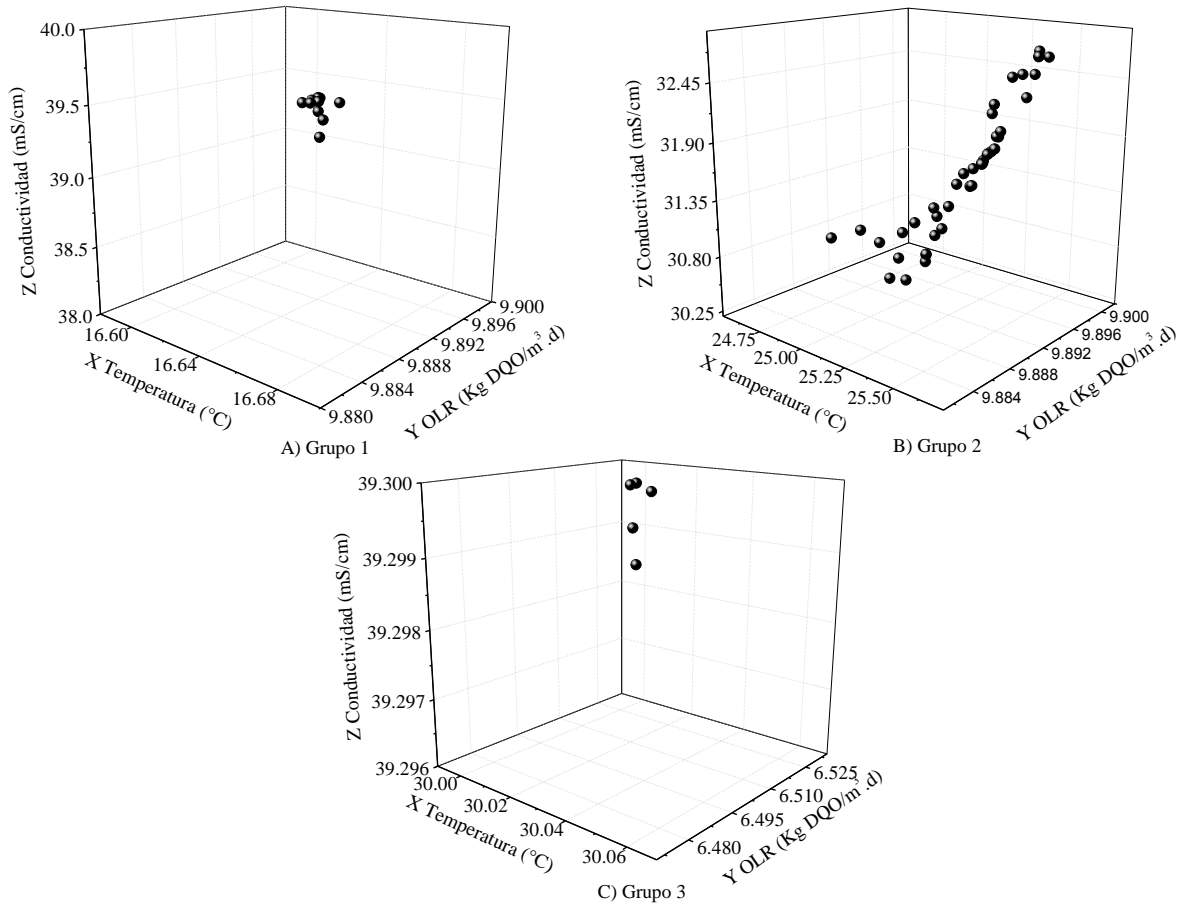


Figura 49. Grupos de combinaciones encontradas después del procesado de datos.

A diferencia del grupo A y C las combinaciones propuestas tienen una diferencia significativa que no puede ignorarse. Aunque el reactor UASB trabajó con buenas eficiencias durante los meses fríos del año, mantener esta temperatura, tal como lo propuso el modelo de IA en el grupo A de condiciones óptimas de operación, es inviable. En el caso de los valores propuestos de OLR y la salinidad, ambos son los mayores utilizados durante la experimentación. En el caso de los datos del grupo C, es necesario introducir energía al sistema para mantener la temperatura a 30°C, mientras que la OLR propuesta es baja comparada con la de los grupos A y B. Es por ello que estos grupos no fueron seleccionados para probarse experimentalmente.

Las condiciones para evaluar el modelo son las propuestas por el grupo B y se muestran a continuación: Temperatura de 25°C, OLR de 9.9 Kg DQO/m<sup>3</sup>.d y Conductividad de 31 mS/cm (Salinidad de 20 g/L). Al evaluar experimentalmente las condiciones propuestas se observó que las eficiencias de remoción se mantenían constantes mientras las condiciones también lo hicieron. Se evaluó por triplicado las mismas condiciones de operación, variando ligeramente la cantidad de DQO y el tiempo de retención para mantener la OLR dentro del sistema. Las eficiencias de remoción se mantuvieron constantes o variaron ligeramente entre un experimento y otro, probando de esta manera la consistencia y validez del modelo de IA (**Tabla 22**).

Tabla 22. Evaluación experimental del modelo de IA basado en AG y RNA.

Experimento	TRH (h)	DQO (mg/L)	Temperatura (°C)	OLR (Kg COD/m <sup>3</sup> .d)	Conductividad* (mS/cm)	Remoción (%)
1	37.6	15,430	25.13	9.85	32.77	72.0
2	37.6	15,340	25.54	9.84	32.73	71.6
3	38.9	16,065	25.03	9.91	31.87	67.6

\*Salinidad≈20 g/L.

De acuerdo a los resultados presentados, podemos observar que el uso de RNA acopladas a AG son útiles para optimizar un sistema de tratamiento de aguas residuales salobres con alta carga orgánica. La eficiencia de remoción obtenida bajo estas condiciones es aceptable comparada con las reportadas por otros autores.

En comparación a los estudios previos, se comparó las condiciones utilizadas por otros autores. Kimata-Kino et al. (2011) obtuvieron eficiencias mayores a las mostradas por el modelo de IA a pesar de que utilizaron salinidades similares y cargas orgánicas mayores. La diferencia principal entre las condiciones usadas en estudios previos y las propuestas por el modelo de IA es la temperatura de operación (37°C) y el sustrato.

Es importante considerar estos estudios debido a que utilizan diferentes fuentes de sustrato y salinidades, de esta manera podemos observar cual es el desempeño de estos sistemas frente a esas condiciones. El agua residual estudiada es más compleja que algunas

utilizadas en estudios anteriores, pues se utilizaron productos comunes para su elaboración. En el presente proyecto se acondicionó un lodo anaerobio convencional mezclado con sedimento de un cuerpo de agua salobre que recibe una descarga de agua residual industrial. El sistema fue acondicionado para trabajar a diferentes salinidades, pero de acuerdo al modelo, el mejor desempeño del reactor se da a conductividades de 32.00 mS/cm (salinidad de 20 g/L). Las condiciones de operación, así como las eficiencias alcanzadas en diferentes estudios, se muestran en la **Tabla 23**.

Tabla 23. Condiciones experimentales y resultados obtenidos en estudios previos.

Autor	Sustrato	Proceso	Temperatura (°C)	OLR (Kg DQO/m <sup>3</sup> .d)	Salinidad (g/L)	DQO removida (%)
Boardman et al. (1995)	Efluente real	UASB	32	13.8	7.7-26.3	77
Habets et al. (1997)	Efluente real	UASB	35	23-31	10	65-80
Guerrero et al. (1997)	Efluente real	UAF	37	5	7.5	80-90
Mosquera-Corral et al. (2001)	Efluente real	USBF	37	1-1.25	-	70-90
Lefebvre et al. (2006)	Efluente real	UASB	≈30	0.5	72	78
Kimata-Kino et al. (2011)	Sintético	UASB	35	18.3	20	>90
Li et al. (2014)	Sintético	UASB	35	0.25	12-28	52
Este trabajo	Sintético	UASB	25	9.9	20	70.4

Todas estas diferencias, del proceso actual frente a los ya reportados, muestran una clara diferencia en los resultados obtenidos. Las eficiencias obtenidas de manera experimental con las condiciones recomendadas por el modelo están dentro del rango bajo reportado para sistemas anaerobios convencionales (Tchobanoglous et al., 2003). Pero dichas eficiencias se lograron con un agua residual más compleja que algunos de los estudios reportados y en condiciones más extremas, ya que se buscaba evitar la introducción de energía, el uso de la máxima OLR soportada por el reactor y a una salinidad máxima. Aquellos que utilizaron un agua residual real y condiciones similares, obtuvieron eficiencias similares a las obtenidas de manera experimental en condiciones recomendadas. La principal diferencia entre el presente estudio y todos los ya reportados, es el uso de temperatura ambiente.

## 5. CONCLUSIONES

El modelo de IA probó ser útil en la optimización del sistema de tratamiento utilizado. A pesar de que la producción de biogás no pudo optimizarse, debido a la fuerte inhibición de la metanogénesis por parte de la alta conductividad del agua, los resultados obtenidos son satisfactorios, pues el agua residual utilizada era compleja, a pesar de ser un agua residual sintética.

La mejor arquitectura para la RNA fue de 4 capas (entrada, dos capas ocultas y salida) con 3 entradas, 10 neuronas en la primera capa oculta, 5 en la segunda capa oculta y finalmente 1 salida. Para aumentar la precisión de los datos predichos por la RNA es necesario obtener más datos experimentales. Es importante mencionar que al probar con nuevos datos la RNA actual no servirá para predecir los datos, por lo tanto, será necesario probar una nueva arquitectura.

Se observa que el modelo de IA basado en AG y RNA no da una combinación de condiciones que, al mantener dentro del reactor UASB, dé como resultado un agua residual con una eficiencia de remoción elevada. En vez de esto, las condiciones sugeridas por el modelo de IA una combinación de condiciones de operación son sugeridas por el modelo, estas condiciones tienen como característica principal, dar la máxima eficiencia de remoción en las condiciones más difíciles a las que puede operar el sistema de tratamiento, es decir, un agua residual con alta salinidad, alta OLR y con temperaturas ambiente. En comparación con otros estudios, la mayoría utiliza temperaturas por arriba de los 30°C, condición que mejora considerablemente la eficiencia de remoción.

Debido a que la OLR está en función del TRH, el volumen del reactor y la DQO, este valor puede modificarse a conveniencia, según los recursos disponibles para su construcción. El modelo de IA propone el uso de una salinidad elevada. Este valor no es el máximo utilizado durante la etapa de experimentación, aun así, a esta concentración, existe una fuerte inhibición del proceso anaerobio, además, variaciones en la concentración de este parámetro, afecta también la eficiencia de remoción. Es importante evaluar la eficacia del proceso anaerobio frente a aguas residuales reales. Para ello, hay que considerar el tiempo de aclimatación e inóculo a utilizar.

El principal beneficio de estos modelos de IA es la disminución del tiempo de experimentación. La implementación de estos modelos puede reducir los costos de

operación, construcción y experimentación, debido a que, una RNA bien diseñada, puede predecir el comportamiento del sistema de tratamiento bajo condiciones de operación específicas, sin necesidad de realizar experimentos.

En el presente estudio el modelo utilizado arrojó varios grupos de datos, en este caso, es necesario interpretar los datos que propone el modelo. Los datos seleccionados se deben adecuar a lo que se busca, en este caso, se buscaba el uso de la máxima salinidad que soporte el sistema, una OLR elevada y no introducción de energía. Además de validar experimentalmente los datos dados por el modelo, se consultó en la bibliografía estudios previos con aguas residuales con condiciones similares para comprobar los resultados tanto experimentales como los modelados.

Los experimentos realizados con las condiciones propuestas por el modelo, dan como resultado una eficiencia de remoción media del  $70.3 \pm 2.42\%$ . Los resultados son consistentes a diferentes valores de DQO y TRH, existen pequeñas variaciones entre los resultados de uno y otro experimento. Se concluye que el modelo utilizado es válido y ha optimizado de manera efectiva el sistema de tratamiento anaerobio basado en un UASB para el tratamiento de un agua residual salobre sintética, elaborada con productos domésticos.

## REFERENCIAS

- Aguado, D., Ribes, J., Montoya, T., Ferrer, J., & Seco, A. (2009). A methodology for sequencing batch reactor identification with artificial neural networks: A case study. *Computers and Chemical Engineering*, 33(2), 465–472.
- Akratos, C. S., Papaspyros, J. N. E., & Tsihrintzis, V. A. (2008). An artificial neural network model and design equations for BOD and COD removal prediction in horizontal subsurface flow constructed wetlands. *Chemical Engineering Journal*, 143(1–3), 96–110.
- Basogain-Olabe, X. (2005). *Redes Neuronales Artificiales Y Sus Aplicaciones*.
- Boardman, G. D., Tisinger, J. L., & Gallagher, D. L. (1995). Treatment of clam processing wastewaters by means of upflow anaerobic sludge blanket technology. *Water Research*, 29(6), 1483–1490.
- Castro, P. M., Matos, H. A., & Novais, A. Q. (2007). An efficient heuristic procedure for the optimal design of wastewater treatment systems. *Resources, Conservation and Recycling*, 50(2), 158–185.
- Čepin, M. (2011). *Assessment of Power System Reliability: Methods and Applications*, 322.
- Chávez-Ramírez, A. U., Muñoz-Guerrero, R., Durán-Torres, S. M., Ferraro, M., Brunaccini, G., Sergi, F., ... Arriaga, L. G. (2010). High power fuel cell simulator based on artificial neural network. *International Journal of Hydrogen Energy*, 35(21), 12125–12133.
- Coello, C. A. C. (1995). *Algoritmos Genéticos y sus Aplicaciones 1*.
- Demuth, H. (2002). *Neural Network Toolbox*. *Networks*, 24(1), 1–8.
- Dragoi, E.-N., Curteanu, S., Galaction, A.-I., & Cascaval, D. (2013). Optimization methodology based on neural networks and self-adaptive differential evolution algorithm applied to an aerobic fermentation process. *Applied Soft Computing*, 13(1), 222–238.
- Elmolla, E. S., Chaudhuri, M., & Eltoukhy, M. M. (2010). The use of artificial neural network (ANN) for modeling of COD removal from antibiotic aqueous solution by the Fenton process. *Journal of Hazardous Materials*, 179(1–3), 127–134.
- Fang, F., Ni, B.-J., Xie, W.-M., Sheng, G.-P., Liu, S.-G., Tong, Z.-H., & Yu, H.-Q. (2010).

- An integrated dynamic model for simulating a full-scale municipal wastewater treatment plant under fluctuating conditions. *Chemical Engineering Journal*, 160(2), 522–529.
- Guerrero, L., & Omil, F. (1997). Treatment of Saline Wastewaters From Fish Meal Factories in an Anaerobic Filter Under Extreme Ammonia Concentrations, 61, 69–78.
- Guerrero, L., Omil, F., Méndez, R., & Lema, J. M. (1997). Treatment of saline wastewaters from fish meal factories in an anaerobic filter under extreme ammonia concentrations. *Bioresource Technology*, 61(1), 69–78.
- Habets, L. H. A., Engelaar, A. J. H. H., & Groeneveld, N. (1997). Anaerobic treatment of inuline effluent in an internal circulation reactor. In *Water Science and Technology* (Vol. 35, pp. 189–197).
- Iqbal, J., & Guria, C. (2009). Optimization of an operating domestic wastewater treatment plant using elitist non-dominated sorting genetic algorithm. *Chemical Engineering Research and Design*, 87(11), 1481–1496.
- Kimata-Kino, N., Ikeda, S., Kurosawa, N., & Toda, T. (2011). Saline adaptation of granules in mesophilic UASB reactors. *International Biodeterioration and Biodegradation*, 65(1), 65–72.
- Lefebvre, O., Quentin, S., Torrijos, M., Godon, J. J., Delgenès, J. P., & Moletta, R. (2007). Impact of increasing NaCl concentrations on the performance and community composition of two anaerobic reactors. *Applied Microbiology and Biotechnology*, 75(1), 61–69.
- Lefebvre, O., Vasudevan, N., Torrijos, M., Thanasekaran, K., & Moletta, R. (2006). Anaerobic digestion of tannery soak liquor with an aerobic post-treatment. *Water Research*, 40(7), 1492–1500.
- Li, J., Yu, L., Yu, D., Wang, D., Zhang, P., & Ji, Z. (2014). Performance and granulation in an upflow anaerobic sludge blanket (UASB) reactor treating saline sulfate wastewater. *Biodegradation*, 25(1), 127–136.
- MathWorks, I. (2005). *Genetic Algorithm and Direct Search Toolbox for use with MATLAB®: user's guide*.
- Mjalli, F. S., Al-Asheh, S., & Alfadala, H. E. (2007). Use of artificial neural network black-box modeling for the prediction of wastewater treatment plants performance. *Journal*



- of Environmental Management, 83(3), 329–338.
- Moctezuma, J. (2006). Implementación Hardware de funciones de transferencia para redes neuronales artificiales.
- Mosquera-Corral, A., Sanchez, M., Campos, J. L., Mendez, R., & Lema, J. M. (2001). Simultaneous methanogenesis and denitrification of pretreated effluents from a fish canning industry. *Water Research*, 35(2), 411–418.
- Mu, Y., & Yu, H.-Q. (2007). Simulation of biological hydrogen production in a UASB reactor using neural network and genetic algorithm. *International Journal of Hydrogen Energy*, 32(15), 3308–3314.
- Omil, F., Mendez, R., & Lema, J. M. (1995). Anaerobic treatment of saline wastewaters under high sulphide and ammonia content. *Bioresource Technology*, 54(3), 269–278.
- Omil, F., Méndez, R., & Lema, J. M. (1996). Anaerobic treatment of seafood processing waste waters in an industrial anaerobic pilot plant. *Water SA*.
- Pendashteh, A. R., Fakhru'l-Razi, A., Chaibakhsh, N., Abdullah, L. C., Madaeni, S. S., & Abidin, Z. Z. (2011). Modeling of membrane bioreactor treating hypersaline oily wastewater by artificial neural network. *Journal of Hazardous Materials*, 192(2), 568–575.
- Prasertsan, P., Jung, S., & Buckle, K. a. (1994). Anaerobic filter treatment of fishery wastewater. *World Journal of Microbiology & Biotechnology*, 10(1), 11–3.
- Raduly, B., Gernaey, K. V., Capodaglio, A. G., Mikkelsen, P. S., & Henze, M. (2007). Artificial neural networks for rapid WWTP performance evaluation: Methodology and case study. *Environmental Modelling and Software*, 22(8), 1208–1216.
- Rangasamy, P., PVR, I., & Ganesan, S. (2007). Anaerobic tapered fluidized bed reactor for starch wastewater treatment and modeling using multilayer perceptron neural network. *Journal of Environmental Sciences*, 19(12), 1416–1423.
- Rodríguez-Piñero, P. T. (1960). Introducción a los algoritmos genéticos y sus aplicaciones.
- Singh, K. P., Basant, N., Malik, A., & Jain, G. (2010). Modeling the performance of “up-flow anaerobic sludge blanket” reactor based wastewater treatment plant using linear and nonlinear approaches-A case study. *Analytica Chimica Acta*, 658(1), 1–11.
- Soleimani, R., Shoushtari, N. A., Mirza, B., & Salahi, A. (2013). Experimental investigation, modeling and optimization of membrane separation using artificial

- neural network and multi-objective optimization using genetic algorithm. *Chemical Engineering Research and Design*, 91(5), 883–903.
- Stuckey, I. V. Æ. D. C. (2009). Effect of fluctuations in salinity on anaerobic biomass and production of soluble microbial products (SMPs), 165–175.
- Takeyas, B. L. (2007). *Introducción a la inteligencia artificial*. 23, 12(32), 1.
- Tanco, F. (2010). *Introduccion a Las Redes Neuronales Artificiales*, 1–34.
- Tchobanoglous, G., Burton, F. L., & Stensel, H. D. (2003). *Wastewater Engineering: Treatment and Reuse*. Metcalf & Eddy, Inc. Engineering (Vol. 4).
- Venu Vinod, A., Arun Kumar, K., & Venkat Reddy, G. (2009). Simulation of biodegradation process in a fluidized bed bioreactor using genetic algorithm trained feedforward neural network. *Biochemical Engineering Journal*, 46(1), 12–20.
- Vidal, G., Aspé, E., Martí, M. C., & Roeckel, M. (1997). Treatment of recycled wastewaters from fishmeal factory by an anaerobic filter. *Biotechnology Letters*, 19(2), 117–121.
- Zarei, M., Khataee, A. R., Ordikhani-Seyedlar, R., & Fathinia, M. (2010). Photoelectro-Fenton combined with photocatalytic process for degradation of an azo dye using supported TiO<sub>2</sub> nanoparticles and carbon nanotube cathode: Neural network modeling. *Electrochimica Acta*, 55(24), 7259–7265.

## **6. PERSPECTIVAS**

Debido a que la producción de biogás fue muy baja durante la experimentación, en el presente estudio tuvo que descartarse el aprovechamiento de este residuo. Se propone el uso de IA y experimentación en diferentes condiciones a las presentadas en este estudio para maximizar la producción de biogás al tratar este tipo de aguas residuales. Se recomienda además el ensayo de las condiciones propuestas por el modelo de IA sobre agua residual real para observar la eficacia de este modelo frente a condiciones reales de operación en un sistema de tratamiento a escala real.

Si bien el valor de la eficiencia de remoción obtenida en el presente estudio puede parecer bajo, hay que recordar que se obtiene solamente con la utilización del reactor anaerobio. Dada la complejidad del agua a tratar, propone estudiar un tren de tratamiento para alcanzar los límites permitidos para los parámetros de descarga contenidos en las Normas Oficiales Mexicanas (NOM 001, 002 o 003-SEMARNAT-1996).

