

DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

OPCIÓN I.- TESIS

TRABAJO PROFESIONAL

“DESARROLLO DE UN SISTEMA EXPERTO DE SOPORTE A LA DECISIÓN PARA DETERMINAR LA RENTABILIDAD DE LOS PROCESOS DE DIGESTIÓN ANAEROBIA MESOFÍLICA DE LODOS RESIDUALES FISICOQUÍMICOS”.

**QUE PARA OBTENER EL GRADO DE:
DOCTORA EN CIENCIAS
DE LA INGENIERÍA**

PRESENTA:

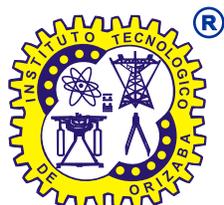
M.I.A. Rita Flores Asis

DIRECTOR DE TESIS:

Dr. Alberto Alfonso Aguilar Lasserre

CODIRECTOR DE TESIS:

Dr. Juan Manuel Méndez Contreras





FECHA: 31/05/2018
DEPENDENCIA: POSGRADO
ASUNTO: Autorización de Impresión
OPCIÓN: I

C. RITA FLORES ASIS
CANDIDATO A GRADO DE DOCTOR EN:
CIENCIAS DE LA INGENIERIA

De acuerdo con el Reglamento de Titulación vigente de los Centros de Enseñanza Técnica Superior, dependiente de la Dirección General de Institutos Tecnológicos de la Secretaría de Educación Pública y habiendo cumplido con todas las indicaciones que la Comisión Revisora le hizo respecto a su Trabajo Profesional titulado:

"DESARROLLO DE UN SISTEMA EXPERTO DE SOPORTE A LA DECISION PARA DETERMINAR LA RENTABILIDAD DE LOS PROCESOS DE DIGESTION ANAEROBIA MESOFILICA DE LODOS RESIDUALES FISICOQUIMICOS".

Comunico a Usted que este Departamento concede su autorización para que proceda a la impresión del mismo.

A T E N T A M E N T E


RUBEN POSADA GOMEZ

JEFE DE LA DIV. DE ESTUDIOS DE POSGRADO

C.A. TITULACIÓN



SECRETARIA DE
EDUCACIÓN PÚBLICA
INSTITUTO
TECNOLÓGICO
DE ORIZABA

ggc



FECHA : 21/05/2018

ASUNTO: Revisión de Trabajo Escrito

C. RUBEN POSADA GOMEZ

JEFE DE LA DIVISION DE ESTUDIOS
DE POSGRADO E INVESTIGACION.
P R E S E N T E

Los que suscriben, miembros del jurado, han realizado la revisión de la Tesis del (la) C.:

RITA FLORES ASIS

la cual lleva el título de:

"DESARROLLO DE UN SISTEMA EXPERTO DE SOPORTE A LA DECISION PARA DETERMINAR LA RENTABILIDAD DE LOS PROCESOS DE DIGESTION ANAEROBIA MESOFILICA DE LODOS RESIDUALES FISICOQUIMICOS".

Y concluyen que se acepta.

A T E N T A M E N T E

PRESIDENTE : DR. ALBERTO ALFONSO AGUILAR LASSERRE

SECRETARIO : DR. JUAN MANUEL MENDEZ CONTRERAS

PRIMER VOCAL : DR. ALEJANDRO ALVARADO LASSMAN

SEGUNDO VOCAL : DR. LUIS ANTONIO CALDERON PALOMARES

TERCER VOCAL : DR. EUSEBIO BOLAÑOS REYNOSO

VOCAL SUP. : DR. ULISES JUAREZ MARTINEZ

FIRMA

FIRMA

FIRMA

FIRMA

FIRMA

FIRMA

EGRESADO(A) DEL DOCTORADO EN CIENCIAS DE LA INGENIERIA

OPCION: I Tesis

AGRADECIMIENTOS

A mi asesor Dr. Alberto Alfonso Aguilar Lasserre, por su gran apoyo y orientación en el desarrollo de este trabajo de investigación, por la formación académica y científica, por ser un ejemplo de trabajo y dedicación a la ciencia. Gracias por aceptar este reto conmigo.

A mi co-asesor Dr. Juan Manuel Méndez Contreras, por su apoyo y guía científica, gracias por compartir sus conocimientos, por su motivación e inspiración, gracias por sus enseñanzas y sobre todo, por su valiosa amistad.

A los miembros de mí jurado doctoral:

Dr. Eusebio Bolaños Reynoso

Dr. Luis Antonio Calderón Palomares

Dr. Alejandro Alvarado Lassman

Dr. Ulises Juárez Martínez

Gracias por su orientación y apoyo para la culminación del presente trabajo de investigación.

Al Instituto Tecnológico de Orizaba, por permitirme desarrollar el presente trabajo de tesis.

A la Comisión Nacional de Ciencia y Tecnología (CONACyT) por la beca otorgada con número de registro 231368 que me permitió realizar estudios de Doctorado en Ciencias en Ingeniería en la ciudad de Orizaba Veracruz

DEDICATORIAS

A mi padre Dios, por darme fortaleza, por demostrarme en todo momento su presencia, por darme salud, voluntad y vida... porque en los momentos en que ya no podía más, él me levantó con su palabra... *“Todo lo puedo en Cristo que me fortalece”*

Filipenses 4:13

A mi madre, por tu apoyo incondicional, por tu amor y tu sabio consejo... *“despeja tu mente unos minutos y después todo fluirá”... que razón tenías mamá... te amo todos los días de mi vida!*

A mi padre... porque me has forjado un carácter que no se rinde a pesar de las circunstancias, porque me enseñaste a trabajar... y a esforzarme...eres mi mejor ejemplo...

Me siento orgullosa de ser como tú!

A mi amado esposo Emiliano... por ser mi motivación e inspiración... por ser el amor de mi vida...gracias por comprender y entender las horas que no te dediqué!

A mis hermanos Ely y Oscar... los amo, son parte de mi ser... me siento muy orgullosa de ustedes... los amaré por siempre!

A ti mi amor, mi razón, mi corazón... a ti que vives en mi mente... no sé si un día Dios me conceda la oportunidad de conocerte... pero quiero que sepas... que te sueño... te espero... y que aun si saber si Dios te regale la vida... no he dejado de imaginarte y de pensarte... y rogarle a Dios que me deje abrazarte... a ti hij@... quiero que sepas que mientras trabaja en este proyecto... te pensaba a cada instante!

A mi tío Antonio Flores...por creer en mí y siempre darme palabras de apoyo!

RESUMEN

Los principales problemas que presentan los lodos producidos en plantas de tratamiento de aguas residuales son el alto contenido de materia orgánica y las elevadas concentraciones de microorganismos patógenos. Por ello, es necesario implementar estrategias que reduzcan los contaminantes en los lodos y cumplan la con normatividad vigente nacional e internacional. El objetivo de este estudio fue “Desarrollar un Sistema Experto de Soporte a la Decisión (Expert Decision Support System EDSS)” que permita determinar patrones de comportamiento y predicciones de las variables fisicoquímicas que intervienen en el proceso de digestión anaerobia mesofílica (PDAM) implementando lógica difusa y redes neuronales artificiales para estimar los parámetros de operación óptimos, utilizando algoritmos genéticos multicriterio para el desarrollo de escenarios de operación que maximizan el rendimiento de las variables biogás, metano y remoción.

Para el desarrollo del Sistema Experto se propuso una metodología de 5 etapas: 1) Recopilación de datos experimentales, 2) Reconocimiento de patrones de comportamiento del proceso de digestión anaerobia mesofílica a través de Lógica Difusa y Redes Neuronales Artificiales, 3) Análisis de Gráficos de Superficie de Respuesta, 4) Optimización del PDAM por medio de un Algoritmo Genético Multicriterio, y 5) Desarrollo de un Sistema Experto de Soporte a la Decisión para el control del PDAM. La primera etapa corresponde a la producción de datos experimentales, para ello, fue necesario hacer una recopilación de los datos experimentales de un reactor anaerobio, en esta etapa se hizo un estudio y análisis de las bases de datos de investigaciones previas desarrolladas en Laboratorio de Ambiental del Instituto Tecnológico de Orizaba, se llevaron a cabo diversas pruebas de laboratorio para ampliar las bases de datos existentes, considerando los pre-tratamientos a los sustratos, pre-hidrolisis térmica, acida y enzimática. Las pruebas experimentales se desarrollaron mediante el monitoreo de cinéticas que simulan pequeños bioreactores a escala de laboratorio de 200 ml, en un tiempo de operación de 30, 60 y 90 días con incremento de carga gradual de $1 \text{ Kg SV m}^{-3} \text{ d}^{-1}$ en cada periodo de operación, el procedimiento completo se explica en el capítulo III.

El modelo de lógica difusa desarrollado para simular el comportamiento de las variables de entrada y estimar los resultados de salida corresponde a la etapa dos de la metodología definida

para la optimización del proceso de digestión anaerobia mesofílica, en esta etapa se definieron los conjuntos difusos de cada una de las variables lingüísticas, para lo que se desarrolló un modelo por cada uno de los ocho sustratos, posteriormente se capturaron reglas de inferencia que se activan estimando un impacto en cada una de las variables de salida, en esta misma etapa se desarrollaron redes neuronales artificiales a través del entrenamiento de la red que es alimentada por las bases de datos obtenidas en la etapa 1, las redes neuronales artificiales permitieron hacer una predicción de los resultados obtenidos en las variables de entrada y salida, así como, permitieron observar el impacto estimado de las variables de entrada del proceso.

En la etapa 3 se hizo un análisis e interpretación de las superficies de respuesta obtenidas del modelo de lógica difusa. Como resultado de los modelos de lógica difusa se obtuvieron superficies de respuesta que se desprenden de los conjuntos difusos y las reglas de inferencia programadas en la etapa 2, en las superficies de respuesta se observan los espacios de interacción entre las variables de entrada con el impacto en el rendimiento de cada una de las variables de salida, biogás, metano y remoción, posteriormente se consideraron los resultados derivados del modelo de lógica difusa para desarrollar modelos matemáticos que permitieron ser utilizados en la optimización del PDAM, para esta tercera etapa se utilizaron la herramienta gatoolbox de Matlab para la creación de algoritmos genéticos multicriterio que nos permiten generar una optimización para lograr un incremento en los valores de salida de los tres criterios, biogás, metano y remoción.

Para finalizar, en la etapa cuatro se desarrolló un PDAM, en el que se integran las herramientas antes mencionadas, para hacer una simulación del proceso, ingresando datos por el usuario y obteniendo resultados estimados, el pre tratamiento térmico es el tratamiento que presenta los mejores resultados en la producción de biogás, estimando una producción diaria de 275 ml diarios y un 75% de producción en biogás, por otro lado la optimización realizada por los algoritmos genéticos presente que el porcentaje de producción de metano puede incrementar hasta un 85% si se consideran una carga de $2 \text{ Kg SV m}^{-3} \text{ d}^{-1}$, durante 60 días y sólidos volátiles superiores a los $65 \text{ g SV/L}\cdot\text{d}$.

NOMENCLATURA

ABREVIATURA	SIGNIFICADO
% SS	Porcentaje de sólidos suspendidos
%SV	Porcentaje de Sólidos Volátiles
%SV _{rem}	Porcentaje de Sólidos Volátiles removidos
% v/v	Porcentaje volumen volumen
°C	Grados centígrados
AGV	Ácidos Grasos Volátiles
AP	Alcalinidad parcial
AT	Alcalinidad total
CO	Carga orgánica
DAT	Digestión anaerobia termofílica
EPA	Environmental protection agency
EWA	European wáter association
g N-NH ₃ /Kg ST	Gramos de nitrógeno amoniacal por kilogramo de sólido o total
g N-NTK/Kg ST	Gramos de nitrógeno total por kilogramo de sólido total
g SV/L	Gramos de Sólidos Volátiles por litro
g SV/L·d	Gramos de Sólidos Volátiles por litro por día
g/kg ST	Gramos por kilogramos de Sólidos Totales
g/L	Gramos por litro
HH/g ST	Huevos de helmintos por gramo de sólido total
IT	Inóculo termofílico
Kcal/Kg	Kilocalorías por kilogramo
L/g SV _{rem}	Litros por gramo de Sólidos Volátiles removidos
Log NMP/g ST	Logaritmo del número más probable por gramo de sólido total
LC	Lodo crudo
LH	Lodo pre hidrolizado

ABREVIATURA	SIGNIFICADO
mg NH ₃ -N/L	Miligramos de nitrógeno amoniacal por litro
Mg/año	Mega gramos por año
mg/g DQO	Miligramos por gramo de demanda química de oxígeno
mg/L	Miligramos por litro
Mv	mili volts
mg N/L	Miligramos de nitrógeno por litro
NMP/g SV	Numero más probable por gramo de Sólidos Volátiles
N _{org}	Nitrógeno orgánico
NTK	Nitrógeno total Kjeldhal
Ph	Potencial de hidrogeno
Ppm	Partes por millón
PTAR	Planta de tratamiento de aguas residuales
RLFI	Reactor de lecho fluidizado inverso
SF	Sólidos fijos
SV	Sólidos Totales
SV	Sólidos Volátiles
TPA	Tratamiento primario avanzado
TRH	Tiempo de retención hidráulico
Y _{biogás}	Rendimiento de biogás
Y _{biogás rem}	Rendimiento de biogás por gramo de sólido total volátil removido
Y _{CH₄}	Rendimiento de metano
Y _{CH₄ rem}	Rendimiento de metano por gramo de sólido total volátil removido
A	Relación de alcalinidad

Contenido

Introducción:	1
Capítulo I. Antecedentes	3
1.1 Introducción	3
1.2 Planteamiento del Problema	3
1.3 Objetivo General	5
1.4 Objetivos Específicos	5
1.5 Hipótesis	6
1.6 Justificación	6
1.7 Conclusión del Capítulo	8
Capítulo II. Marco teórico	9
2.1 Introducción	9
2.2 Origen de los lodos residuales	9
2.3 Bioenergía	11
2.3.1 Biomasa	11
2.3.2 Biogás	13
2.3.3 Biodigestor.....	14
2.3.3.1 Partes de un biodigestor	14
2.4 Digestión anaerobia	15
2.4.1 Fases del proceso de la digestión anaerobia.....	16
En el proceso de digestión anaerobia, se divide en cuatro fases o procesos:.....	16
Hidrólisis	16
Etapa fermentativa o acidogénica	16
Etapa acetogénica	16
Etapa metanogénica	16
Hidrólisis 16	
Fermentación o Acidogénesis.....	17
Acetogénesis	17
Metanogénesis	18
2.4.2 Clasificación de la digestión anaerobia.....	18
2.4.3 Variables de operación o control	19
2.4.3.1 pH	19
2.4.3.2 Alcalinidad y relación de alcalinidad.....	20
2.4.3.3 Producción de biogás	20

2.4.3.4	Reducción de materia orgánica.....	21
2.4.3.5	Rendimientos de biogás y de metano.....	21
2.4.3.6	Temperatura.....	22
2.4.3.7	Carga orgánica.....	22
2.4.3.8	Tiempo de retención hidráulico.....	23
2.4.4	Pre tratamientos para optimizar el proceso de digestión anaerobia.....	23
2.4.4.1	Pre-hidrólisis térmica.....	24
2.4.4.2	Pre tratamiento con pre hidrólisis ácida.....	25
2.4.4.3	Pre tratamiento con hidrólisis enzimática.....	25
2.5	Técnicas de inteligencia artificial.....	26
2.5.1	Sistemas expertos basados en Inteligencia Artificial.....	27
2.5.2	Sistemas de Apoyo a la Toma de Decisiones (DSS).....	29
2.6	Lógica difusa.....	30
2.6.1	Funciones de pertenencia.....	32
2.6.2	Método de Mamdani.....	32
2.7	Redes neuronales artificiales.....	34
2.7.1	Aprendizaje y Prueba de una red neuronal artificial.....	37
2.7.2	El perceptrón multicapa.....	38
2.8	Algoritmos genéticos.....	41
2.8.1	Nomenclatura empleada en algoritmos genéticos.....	42
2.8.2	Metodología de un Algoritmo Genético.....	43
2.9	Conclusión de Capítulo.....	46
	Capítulo III. Estado del Arte.....	47
3.1	Introducción.....	47
3.2	Optimización del proceso de digestión anaerobia.....	47
3.3	Control del reactor IA vs PDAM.....	48
3.4	Control del proceso IA vs DAM.....	49
3.5	Digestión anaerobia con Lógica Difusa y Redes neuronales.....	50
3.6	Grupos bacterianos que intervienen en el proceso de digestión anaerobia.....	54
3.7	Conclusión del Capítulo.....	57
	Capítulo IV. Materiales y Métodos.....	58
4.1	Introducción.....	58
4.2	Metodología.....	58
4.3	Etapa 1: Producción de datos experimentales.....	60
4.3.1	Obtención y caracterización de lodos residuales.....	61

4.3.1.1	Caracterización de sustratos.....	62
4.3.1.1.1	pH	63
4.3.1.1.2	Temperatura	63
4.3.1.1.3	Sólidos totales	63
4.3.1.1.4	Sólidos volátiles	64
4.3.1.2	Pre tratamientos para optimizar el proceso de digestión anaerobia	65
4.3.1.2.1	Evaluación de la pre-hidrólisis térmica en la solubilización de la materia orgánica ...	65
4.3.1.2.2	Pre-tratamiento térmico en Modo <i>Batch</i>	66
4.3.1.2.3	Operación semi-continua e incremento de la carga orgánica en la digestión anaerobia de lodo crudo y pre-hidrolizado	67
4.3.1.2.4	Pre-hidrólisis ácida en lodo residual	68
4.3.1.2.4.1.	Operación <i>batch</i> y semi-continua de lodo con pretratamiento ácido.....	68
4.3.1.2.5	Pre-hidrólisis enzimática.....	69
4.3.1.2.5.1	Operación <i>batch</i> y semi-continua de lodo con pretratamiento enzimático	70
4.4	Etapa 2: Identificación de Patrones de Comportamiento y Predicción	71
4.4.1	Determinación de patrones de comportamiento del proceso de digestión anaerobia mesofílica a través de lógica difusa	71
4.4.1.1	Modelo de lógica difusa para digestión anaerobia mesofílica en lodo con pre-tratamiento térmico en operación semi-continuo.....	71
4.4.1.1.1	Definición de Variables Lingüísticas.....	72
4.4.1.1.2	Fusificación.....	74
4.4.1.1.3	Reglas de Inferencia.....	77
4.4.1.1.4	Desdifusificación	78
4.4.1.2	Modelo de lógica difusa para digestión anaerobia mesofílica con pre hidrólisis térmica en operación <i>batch</i>	79
4.4.1.2.1	Definición de Variables Lingüísticas y fusificación del modelo de lógica difusa para la digestión anaerobia con lodo pre-tratado térmicamente en operación <i>batch</i>	80
4.4.1.2.2	Reglas de Inferencia.....	80
4.4.1.2.3	Desdifusificación	81
4.4.1.3	Modelo de lógica difusa para digestión anaerobia mesofílica en lodo crudo en operación <i>batch</i> 81	
4.4.1.3.1	Definición de Variables Lingüísticas y fusificación del modelo de lógica difusa para la digestión anaerobia con lodo pre-tratado térmicamente en operación <i>batch</i>	81
4.4.1.3.2	Reglas de Inferencia y desdifusificación	82
4.4.1.4	Modelo de lógica difusa para digestión anaerobia mesofílica en lodo crudo en operación semi-continua.....	83
4.4.1.4.1	Definición de Variables Lingüísticas.....	83
4.4.1.4.2	Fusificación.....	83

4.4.1.4.3	Reglas de Inferencia.....	84
4.4.1.4.4	Desdifusificación	84
4.4.1.5	Modelo de lógica difusa para digestión anaerobia mesofílica con pre hidrólisis ácida en operación <i>Batch</i>	85
4.4.1.5.1	Definición de Variables Lingüísticas y fusificación del modelo de lógica difusa de digestión anaerobia con pre-hidrolisis ácida.....	85
4.4.1.5.2	Reglas de Inferencia y Desdifusificación	86
4.4.1.6	Modelo de lógica difusa para digestión anaerobia mesofílica con pre hidrólisis ácida en operación semi continua	86
4.4.1.6.1	Reglas de Inferencia y Desdifusificación	87
4.4.1.7	Modelo de lógica difusa para digestión anaerobia mesofílica con pre hidrólisis enzimática en operación <i>Batch</i>	88
4.4.1.7.1	Definición de Variables Lingüísticas y fusificación del modelo de lógica difusa de digestión anaerobia con pre-hidrolisis enzimática.....	88
4.4.1.7.2	Reglas de Inferencia y desdifusificación	89
4.4.1.8	Modelo de lógica difusa para digestión anaerobia mesofílica con pre hidrólisis enzimática en operación semi-continúa.....	89
4.4.1.8.1	Definición de Variables Lingüísticas y fusificación del modelo de lógica difusa de digestión anaerobia con pre-hidrolisis enzimática.....	89
4.4.1.8.2	Reglas de Inferencia y desdifusificación	90
4.4.2	Predicción de variables del proceso de digestión anaerobia mesofílica a través de redes neuronales artificiales.....	91
4.4.2.1	Desarrollo de redes neuronales artificiales para la predicción de producción de biogás, metano Ch ₄ y remoción con el software Matlab	91
4.4.2.2	Red neuronal artificial de digestión anaerobia en lodo con pre-tratamiento térmico	94
4.4.2.3	Red neuronal artificial de digestión anaerobia en lodo crudo.....	96
4.4.2.4	Red neuronal artificial de digestión anaerobia en lodo con pre-tratamiento ácido.....	98
4.4.2.5	Red neuronal artificial de digestión anaerobia en modo enzimático	100
4.5	Etapa 4: Optimización del proceso de digestión anaerobia	103
4.5.1	Optimización multicriterio del proceso de digestión anaerobia mesofílica mediante algoritmos genéticos.....	103
4.5.1.1	Modelación matemática.....	103
4.5.1.2	Restricciones.....	105
4.5.1.3	Optimización Multicriterio	106
4.6	Etapa 5: Desarrollo del sistema de apoyo a la decisión.....	107
4.6.1	Desarrollo de un sistema de apoyo a la toma de decisiones	108
4.7	Conclusión del Capítulo	113
Capítulo V. Resultados.....		114

5.1	Introducción del Capítulo	114
5.2	Resultados de la caracterización de lodos residuales	114
5.3	Evaluación de la pre-hidrólisis térmica en la solubilización de la materia orgánica	115
5.4	Producción de biogás con hidrólisis con ácido acético	121
5.5	Producción de biogás con hidrólisis enzimática	124
5.6	Análisis de superficies de respuesta de los modelos de lógica difusa de los diferentes sustratos con y sin pre hidrolizado	127
5.7	Resultados de las redes neuronales	139
5.8	Resultados Algoritmos genéticos multicriterio	142
5.8.1	Resultados Algoritmo genético multicriterio en lodo prehidrolizado térmico semi-continuo en Matlab	142
5.8.2	Resultados Algoritmo genético multicriterio en lodo prehidrolizado térmico en modo batch en Matlab	145
5.8.3	Resultados Algoritmo genético multicriterio en lodo crudo en modo semi-continuo en Matlab	147
5.8.4	Resultados Algoritmo genético multicriterio en lodo crudo en modo <i>batch</i> en Matlab	149
5.8.5	Resultados Algoritmo genético multicriterio en pre-tratamiento ácido en operación en modo semi-continuo desarrollado en Matlab	151
5.8.6	Resultados Algoritmo genético multicriterio en pre-tratamiento ácido en operación batch desarrollado en Matlab	153
5.8.7	Resultados Algoritmo genético multicriterio en pre-tratamiento enzimático en operación semicontinua desarrollado en Matlab	155
5.9	Resultados del sistema de apoyo a la toma de decisiones	157
5.10	Conclusión del Capítulo	162
6.	Conclusiones:	163
	Referencias bibliográficas:	171
	ANEXOS:	182



Índice de Figuras

Figura 2.1 Generación de lodos residuales en los sistemas de tratamiento de aguas (Ruiz,2012).	10
Figura 2.2 Arquitectura de un sistema experto (I. G. 2005).	28
Figura 2.3 Modelo general de un sistema de lógica difusa tipo Mandami	33
Figura 2.4 Arquitectura de las Redes Neuronales Artificiales.....	35
Figura 2.5 Estructura de un sistema neuronal artificial	36
Figura 2.6 Elementos que componen a una red neuronal artificial.....	36
Figura 2.7 Funciones de salida del perceptrón.	39
Figura 2.9 Cruzamiento de único punto	44
Figura 2.10 Proceso de algoritmo genético.....	45
Figura 4.1 Metodología propuesta para el desarrollo del sistema de apoyo a la decisión del proceso de digestión anaerobia.....	60
Figura 4.2 Sistema de tratamiento de aguas residuales de la industria avícola (Ruiz, 2010).	62
Figura 4.3 Pre-hidrólisis térmica.....	65
Figura 4.4 Modelo de lógica difusa, tipo Mandami en Matlab.	72
Figura 4.5 Arquitectura de una neurona artificial.....	92
Figura 4.6 Red de alimentación hacia delante (Feed Forward).....	93
Figura 4.7 Correlación de la validación de la etapa de entrenamiento de la red neuronal artificial con 60 casos.	95
Figura 4.8 Correlación de la validación de la etapa de entrenamiento de la red neuronal artificial de digestión anaerobia en lodo crudo con 45 casos.	97
Figura 4.9 Correlación de la validación de la etapa de entrenamiento de la red neuronal artificial con 60 casos.	99
Figura 4.10 Correlación de la validación de la etapa de entrenamiento de la red neuronal artificial de digestión anaerobia en lodo con pretratamiento enzimático con 45.	101
Figura 4.11 Pantalla de inicio de sesión del sistema de apoyo a la decisión.	108
Figura 4.12 Pantalla principal del sistema de apoyo a la decisión.	109
Figura 4.14 Pantalla de predicción por redes neuronales artificiales.....	111
Figura 4.16 Pantalla de optimización.....	113
Figura 5.1 Remoción en lodo crudo y pre hidrolizado térmicamente en modo batch.....	116
Figura 5.2 Producción de biogás en lodo crudo y pre hidrolizado térmicamente en modo batch.	117
Figura 5.3 Producción de metano CH_4 en lodo crudo y pre hidrolizado térmicamente en modo batch.	117
Figura 5.4 Remoción diaria e incremento de la CVA en la digestión de lodos.....	119
Figura 5.5 Producción de biogás diaria e incremento de la CVA en la digestión de lodos	120
Figura 5.6 Producción de biogás diaria e incremento de la CVA en la digestión de lodos	120
Figura 5.7 % de Sólidos totales y sólidos volátiles en lodo con pretratamiento ácido acético.	121
Figura 5.8 Producción de biogás en lodo pre tratado con ácido acético.	122
Figura 5.9 Producción de Metano en lodo tratado con ácido acético.....	122
Figura 5.10 % de remoción en lodo con pre hidrolisis ácida en semi continuo	123
Figura 5.11 Producción de biogás en lodo con pre hidrolisis ácida en semi-continuo.....	123
Figura 5.12 Remoción diaria en lodo con pretratamiento enzimático en batch.	124
Figura 5.13 Producción de biogás en lodo con pretratamiento enzimático en batch.	125
Figura 5.14 Producción de Metano en lodo con pretratamiento enzimático.	125
Figura 5.15 % de Remoción en lodo con pretratamiento enzimático.....	126
Figura 5.16 Producción de biogás en lodo con pretratamiento enzimático.....	126
Figura 5.17 Producción de Metano en lodo con pretratamiento enzimático.....	127
Figura 5.18 Gráficas de superficie de respuesta del impacto de las variables de entrada % remoción.	128



Figura 5.19 Gráfica de superficie de respuesta del impacto de las variables de entrada % sólidos totales en la variable de salida biogás y Metano, en lodo con prehidrolisis térmica.....	129
Figura 5.20 % sólidos volátiles, en las variables de salida biogás y Metano, del lodo sin pretratamiento.	129
Figura 5.21 Gráfica de superficie de respuesta del impacto de las variables de entrada de temperatura y pH, en la variable de salida biogás y Metano, en lodo con prehidrolisis térmica.....	130
Figura 5.22 Gráfica de superficie de respuesta del impacto de las variables de entrada Carga Kgs SV m-3 d-1 y pH, en la variable de salida biogás, con pre hidrolisis térmica.....	131
Figura 5.23 Gráfica de superficie de respuesta del impacto de las variables de entrada pH y Carga en la variable de salida biogás y Metano, en lodo con prehidrolisis térmica.....	131
Figura 5.24 Gráficas de superficie de respuesta del impacto de las variables de entrada Temperatura y tiempo de operación con impacto en la variable de salida biogás.....	132
Figura 5.25 Gráficas de superficie de respuesta del impacto de las variables de entrada Temperatura y tiempo de operación con impacto en la variable de salida Metano.....	133
Figura 5.26 Gráficas de superficie de respuesta del impacto de las variables de entrada Temperatura y Tiempo de operación, en la variable de salida Biogás con pre-hidrolisis ácida.....	134
Figura 5.27 Gráficas de superficie de respuesta del impacto de las variables de entrada Temperatura y Tiempo de operación, en la variable de salida Metano en lodo con pre-hidrolisis ácida.....	134
Figura 5.28 Gráfico de comparación de datos experimentales y del modelo de lógica difusa del proceso de digestión anaerobia mesofílica en lodo pre tratado térmicamente.....	137
Figura 5.29 Validación de la predicción de la red neuronal con 60 casos.....	139
Figura 5.30 Validación de la predicción de la red neuronal con 30 casos.....	140
Figura 5.31 Gráfico de predicción o de la red neuronal del proceso de digestión anaerobia mesofílica en lodo pretratado térmicamente.....	141
Figura 5.32 Gráfico de porcentajes de impacto de las variables de entrada de la red neuronal del proceso de digestión anaerobia mesofílica en lodo pretratado térmicamente.....	142
Figura 5.33 Optimización algoritmo genético multicriterio biogás y metano.....	144
Figura 5.34 Resultados de optimización algoritmo genético multicriterio, biogás, metano y remoción.....	145
Figura 5.35 Optimización algoritmo genético multicriterio biogás y metano.....	146
Figura 5.36 Resultados de ptimización algoritmo genético multicriterio, biogás, metano y remoción para lodo con pre tratamiento térmico en modo batch.....	147
Figura 5.37 Optimización algoritmo genético multicriterio biogás y metano.....	148
Figura 5.38 Resultados de optimización algoritmo genético multicriterio, biogás, metano y remoción para lodo crudo en operación semi continuo.....	149
Figura 5.39 Optimización algoritmo genético multicriterio biogás y metano.....	150
Figura 5.40 Resultados de optimización algoritmo genético multicriterio, biogás, metano y remoción para lodo crudo en operación batch.....	151
Figura 5.41 Optimización algoritmo genético multicriterio biogás y metano en lodo ácido semi continuo.....	152
Figura 5.42 Resultados de optimización algoritmo genético multicriterio, biogás, metano y remoción para lodo ácido semi-continuo.....	153
Figura 5.43 Optimización algoritmo genético multicriterio biogás y metano en lodo ácido batch.....	154
Figura 5.44 Resultados de optimización algoritmo genético multicriterio, biogás, metano y remoción para lodo ácido batch.....	155
Figura 5.45 Optimización algoritmo genético multicriterio biogás y metano en lodo ácido batch.....	156
Figura 5.46 Resultados de optimización algoritmo genético multicriterio, biogás, metano y remoción para lodo ácido batch.....	157
Figura 5.47 Pantalla principal del sistema de apoyo a la decisión.....	158
Figura 5.48 Pantalla de opciones y presentación de gráficos de superficies de respuesta.....	159
Figura 5.49 Pantalla de predicción por redes neuronales artificiales.....	160
Figura 5.50 Pantalla de simulación con carga de datos desde hoja de cálculo.....	161



<i>Figura 5.51 Pantalla de optimización.....</i>	<i>162</i>
<i>Figura 6.1 Funciones de pertenencia para la variable tiempo</i>	<i>183</i>
<i>Figura 6.2. Funciones de pertenencia para la variable pH</i>	<i>184</i>
<i>Ecuación 6.7. Variable Carga, etiqueta “uno”</i>	<i>184</i>
<i>Ecuación 6.8. Variable Carga, etiqueta “dos”</i>	<i>184</i>
<i>Figura 6.3 Funciones de pertenencia para la variable tiempo</i>	<i>185</i>
<i>Ecuación 6.9 Temperatura, etiqueta “baja”</i>	<i>185</i>
<i>Figura 6.4 Funciones de pertenencia para la variable Temperatura.....</i>	<i>186</i>
<i>Figura 6.5 Funciones de pertenencia para la variable Sólidos totales</i>	<i>187</i>
<i>Figura 6.6 Funciones de pertenencia para la variable Sólidos volátiles</i>	<i>189</i>
<i>Figura 6.7 Funciones de pertenencia para la variable biogás</i>	<i>190</i>
<i>Figura 6.8 Comportamiento de la variable ST con respecto a la variable de salida biogás</i>	<i>191</i>
<i>Figura 6.9 Superficies de respuesta de remoción con respecto a la variable de salida biogás del modelo de lógica difusa, para observar su comportamiento.....</i>	<i>191</i>
<i>Figura 6.10 Superficies de respuesta de remoción con respecto a la variable de salida biogás del modelo de lógica difusa, para observar su comportamiento.....</i>	<i>192</i>
<i>Figura 6.11 Superficies de respuesta de región óptima para la interacción de las variables solidos volátiles y tiempo de operación en la variable de salida biogás.</i>	<i>192</i>
<i>Figura 6.12 Ecuaciones de la región óptima para la interacción de las variables solidos volátiles y tiempo de operación en la variable de salida biogás.</i>	<i>192</i>



ÍNDICE DE TABLAS

Tabla 2.1. Equivalencia de residuo producido y potencial para la generación de biogás (Pérez Mendel, 2010). 12	12
Tabla 2.2. Porcentaje de los componentes que integran el biogás (Castells, 2012)..... 14	14
Tabla 2.3 Diversas clasificaciones de la digestión anaerobia..... 18	18
Tabla 2.4 Intervalos de temperatura típicas para diversas bacterias (Metcalf & Eddy, 2003) 22	22
Tabla 2.5 Nomenclatura de un algoritmo genético..... 42	42
Tabla. 3.1. Parámetros de control de los grupos de Bacterias hidrolíticas y acidogénicas. 56	56
Tabla 3.2 Parámetros de control de los grupos de Bacterias acetogénicas y Metanogénicas. 57	57
Tabla 4.1. Parámetros de caracterización..... 63	63
Tabla 4.2. Incremento de la CVA en la digestión anaerobia semi-continua..... 68	68
Tabla 4.4. Variables de entrada de los modelos de lógica difusa de digestión anaerobia en lodos pre- hidrolizados y no pre hidrolizados. 74	74
Tabla 4.5 Conjuntos difusos para las variables de entrada en lodo con pre-tratamiento térmico. 76	76
Tabla 4.6 Conjuntos difusos para las variables de salida en lodo con pre-tratamiento térmico..... 77	77
Tabla 4.7. Reglas de inferencia, lodo crudo en modo batch..... 78	78
Tabla 4.8. Conjuntos difusos actualizados para lodo pre-tratado térmicamente en modo batch. 80	80
Tabla 4.9 Conjuntos difusos actualizados para lodo- crudo en modo batch..... 82	82
Tabla 4.10 Conjuntos difusos actualizados de lodo crudo en modo semi-continuo. 84	84
Tabla 4.11 Conjuntos difusos actualizados para lodo- crudo en modo batch..... 86	86
Tabla 4.12 Conjuntos difusos de lodo con pre-hidrolisis ácida en modo batch..... 87	87
Tabla 4.13 Conjuntos difusos de lodo con pre-hidrolisis ácida en modo batch..... 88	88
Tabla 4.14 Actualización de conjuntos difusos de lodo con pre-hidrolisis enzimática en modo batch 90	90
Tabla 4.15 Variables de entrada y salida de la RNA para el proceso de digestión anaerobia con pre-hidrolisis térmica. 92	92
Tabla 4.16 Pesos sinápticos de la capa oculta 1..... 95	95
Tabla 4.17 Pesos sinápticos de la capa oculta 2..... 96	96
Tabla 4.18 Pesos sinápticos de la capa oculta 1..... 97	97
Tabla 4.19 Pesos sinápticos de la capa oculta 2..... 98	98
Tabla 4.20 Pesos sinápticos de la capa oculta 1..... 99	99
Tabla 4.21 Pesos sinápticos de la capa oculta 2..... 100	100
Tabla 4.22 Pesos sinápticos de la capa oculta 1..... 102	102
Tabla 4.23 Bias de la capa oculta 1..... 102	102
Tabla 4.24 Bias de la capa oculta 2..... 102	102
Tabla 4.25 Parámetro del algoritmo genético. 107	107
Tabla 5.1 Caracterización de los lodos residuales..... 115	115
Tabla 5.2. Muestra del coeficiente de correlación del modelo de lógica difusa de digestión anaerobia mesofílica en lodo pre tratado térmicamente. 136	136
Tabla 5.3 Muestra del coeficiente de correlación del modelo de lógica difusa de digestión anaerobia mesofílica en lodo con pre hidrolisis ácida. 137	137
Tabla 5.4 Muestra del coeficiente de correlación del modelo de lógica difusa de digestión anaerobia mesofílica en lodo con pre hidrolisis enzimática. 138	138
Tabla 5.5 Predicción de la red neuronal con 60 casos..... 140	140
Tabla 5.6 Predicción de la red neuronal con 30 casos..... 141	141
Tabla 5.7 Datos optimizados por algoritmos genéticos. 143	143



Tabla 5.8. Datos optimizados por algoritmos genéticos para lodo pre tratado térmicamente en modo batch.
..... 145

Tabla 5.9 Datos optimizados por algoritmos genéticos para lodo pre tratado térmicamente en modo batch. 148

Tabla 5.10 Datos optimizados por algoritmos genéticos para lodo sin pre-tratamiento en modo batch..... 150

Tabla 5.11 Datos optimizados por algoritmos genéticos para lodo ácido en semicontinua. 152

Tabla 5.12 Datos optimizados por algoritmos genéticos para lodo ácido en batch. 154

Tabla 5.13 Datos optimizados por algoritmos genéticos para lodo ácido en batch. 155



Introducción:

El tratamiento de los lodos residuales generados en México es de vital importancia debido a que se producen grandes volúmenes, esto aunado a las exigencias legales en cuanto al cumplimiento de la normatividad ambiental vigente. En nuestro país se ha incrementado el número de plantas de tratamiento de aguas residuales (PTAR) de 793 en el año 2000 a 1833 en el 2008 (CONAGUA), acrecentando el volumen tratado de 23% a 40.2% teniendo por consecuencia un aumento en la cantidad de lodos generados. En México, no se tiene información oficial actualizada sobre la generación de lodos residuales, sin embargo en el 2003 se generaron aproximadamente 12, 000,000 toneladas de estos residuos, los cuales contienen contaminantes orgánicos, microorganismos patógenos y parásitos e incluso en algunos casos, metales pesados (Ortega, 2003).

Existen variables de operación en el proceso de digestión anaerobia que pueden ser controladas para poder interpretar su comportamiento, estas variables de decisión para optimizar el proceso pueden ser clasificadas como parámetros de funcionamiento críticos y de diseño del reactor. Entre los parámetros de funcionamiento crítico se observan la cantidad de sólidos totales, sólidos volátiles, pH, temperatura, DQO (Demanda química de oxígeno) y el tiempo de residencia hidráulica, con respecto a los parámetros de diseño del reactor se encuentran la capacidad volumétrica del reactor, caudal, concentración del efluente, carga orgánica, ancho y altura del reactor, entre otros. Otros factores a considerar son en referencia al modo de operación del reactor, dado que la alimentación del reactor se puede dar de forma continua o por lotes, también es importante mencionar que la temperatura tiene un alto nivel de impacto en el proceso, ya que existe una clasificación de acuerdo a la temperatura, esta se clasifica en un proceso de digestión anaerobia psicófila, mesófila y termófila (Rapport et al., 2008) (Siddharth Jain, 2011).

La digestión anaerobia desempeña un papel importante por su capacidad para transformar más materia orgánica en biogás (60-70% en volumen de metano, CH₄), por lo tanto también se reduce el volumen de lodo final para su disposición, además se promueve la destrucción de la mayoría de los patógenos presentes en el lodo y la limitación de problemas de olor asociados con la materia residual (Appels, Baeyens, Degreève, Dewil, 2008). Por tanto, la digestión



anaeróbica optimiza los costes de una planta de tratamiento de lodos activados (EDAR) y su impacto ambiental, esto se considera una parte importante y esencial de una EDAR moderna.

Actualmente el sector industrial a nivel global no cuenta con una herramienta que considere el proceso microbiológico de digestión anaerobia mesofílica en base a la experticia adquirida durante el modo experimental en los subprocesos de digestión anaerobia de lodo crudo, lodo prehidrolizado, lodo en medio ácido y en medio enzimático, para que estas sean contempladas como alternativas de selección del modelo más óptimo a través del análisis de las variables del proceso con el objetivo de maximizar el rendimiento de producción de biogás y biosólidos.

Por lo que la presente investigación propone un Sistema Experto de Soporte a la Decisión (Expert Decision Support System EDSS) que permita determinar patrones de comportamiento y predicciones de las variables fisicoquímicas que intervienen en el proceso de digestión anaerobia mesofílica implementando lógica difusa y redes neuronales artificiales, para generar escenarios óptimos por medio de algoritmos genéticos multicriterio, como apoyo a la toma de decisiones en la selección del proceso y su modalidad en términos de rendimientos de producción de biogás, metano y remoción.

El trabajo se encuentra organizado en cinco capítulos que muestran el proceso llevado a cabo para el desarrollo del sistema experto de apoyo a la decisión, para ello, en el Capítulo I se describen los antecedentes de la investigación, en el que se observa el planteamiento del problema, el objetivo, hipótesis justificación, en el Capítulo II se presenta el Marco teórico que se encuentra integrado por un breve resumen de las técnicas, procesos y herramientas empleadas para el desarrollo del sistema.

En el capítulo III, se presenta el estado del arte, que muestra una secuencia de los principales estudios realizados previamente en el tema estudiado, en el Capítulo IV se presenta el desarrollo de la metodología y cada una de las fases que se llevó a cabo para el desarrollo del Sistema experto de apoyo a la decisión. En el Capítulo V se muestran los resultados obtenidos en el laboratorio de ambiental para suministrar a las herramientas de inteligencia artificial que predicen el proceso y que permiten generar el sistema experto, en el mismo capítulo se observan los resultados obtenidos de los modelos de lógica difusa, así como de la predicción por medio de la redes neuronales artificiales y la optimización por medio de los algoritmos genéticos.

Capítulo I

Antecedentes

Capítulo I. Antecedentes

1.1 Introducción

A continuación se presenta el Capítulo I, en él se describe el contexto en que se desarrolla el trabajo de investigación, considerando la situación problemática que motivo a realizar el proyecto, el cual surge de la inquietud de contribuir al desarrollo de energías alternas, y la aportación al proceso de tratamiento de lodos por medio del proceso de digestión anaerobia mesofílica.

En este capítulo se exponen el objetivo general del proyecto y la hipótesis que fue planteada en el inicio del trabajo realizado, que infiere que el desarrollo del proceso de digestión anaerobia mesofílica (PDAM) será de apoyo en la selección del pre-tratamiento que presenta mejores rendimientos en términos de biogás, metano y remoción, también se plantea la argumentación que justifica el desarrollo de la investigación.

1.2 Planteamiento del Problema

El sector industrial a nivel mundial ha iniciado una búsqueda tecnológica que permita encontrar energías alternativas que utilicen fuentes renovables que brinden oportunidades de convertirse ambientalmente sustentables y económicamente viables para sustituir a los derivados del petróleo.

En los últimos años se ha presentado un crecimiento significativo en la producción de energías a partir de fuentes renovables que ayudan a satisfacer las necesidades de energía, además de que permiten minimizar los impactos ambientales sobre emisiones de gases de efecto invernadero, generando un enorme potencial para explotar muchos residuos agroindustriales. El potencial de la bioenergía también aumentará a medida que surjan tecnologías que permitan una conversión más eficiente de biomasa para la generación de biocombustibles y bioelectricidad. Los avances tecnológicos no sólo ayudarán a que la bioenergía compita mejor

con los combustibles fósiles en cuanto al precio, sino que también ampliarán la gama de materias primas y residuos.

En la zona centro del Estado de Veracruz se presenta una oportunidad para determinar el aprovechamiento energético de la biomasa residual que se genera en los procesos de producción de distintas empresas agroindustriales, tal es el caso de las industria avícola, que emite una gran cantidad de residuos ricos en proteínas y otros nutrientes que pueden ser reutilizados y ser convertidos en bioenergía. La industria Avícola está dedicada a la producción y procesamiento de aves para consumo humano, de la cual se obtiene los lodos residuales que provienen del procesamiento del ave y son resultado del tratamiento físico-químico del agua que se le da a los efluentes del proceso. Los lodos residuales pueden ser usados en sistemas de digestión anaeróbica para producir biogás capaz de generar bioelectricidad y obtener biosólidos residuales para ser utilizados como fertilizantes en la cadena agroindustrial cañero-azucarera, su aplicación energética de ambos residuos pueden elevar su rentabilidad económica.

En el tratamiento de las aguas residuales, la eliminación de los lodos residuales es un problema de importancia creciente, lo que representa hasta un 50% de los gastos corrientes de funcionamiento de una planta de tratamiento de aguas residuales. Aunque diferentes rutas de tratamiento son posibles, la digestión anaerobia desempeña un papel importante por su capacidad para transformar más materia orgánica en biogás (60-70% en volumen de metano, CH₄), por lo tanto también se reduce el volumen de lodo final para su disposición, además se promueve la destrucción de la mayoría de los patógenos presentes en el lodo y la limitación de problemas de olor asociados con la materia residual (Appels, Baeyens, Degrève, Dewil, 2008).

Por lo tanto uno de los principales aportes de la digestión anaerobia es la generación de biogás y biosólidos, los cuales pueden ser utilizados como bio-fertilizantes o el mejoramiento de suelos.

En la presente investigación plantea el desarrollo de un sistema experto de apoyo a la decisión que permite visualizar y estimar los rendimientos de producción de biogás, metano y remoción en lodos físicoquímicos pre tratados por cuatro diferentes pre-tratamientos que permiten la aceleración del proceso de hidrólisis, para ello. El sistema de forma interna evalúa las

características del sustrato, identificando los parámetros de operación correctos para maximizar los rendimientos, logrando así, ofrecer una herramienta para realizar predicciones de los rendimientos de producción de biogás, metano y remoción a partir del biosólido estudiado, fomentando el proceso de digestión anaerobia mesofílica como un método efectivo para la generación de biogás.

1.3 Objetivo General

Desarrollar un EDSS que permita identificar patrones de comportamiento y realizar predicciones de las variables de operación que intervienen en el PDAM con pre-tratamiento térmico, ácido y enzimático en modo batch y semi-continuo, implementando lógica difusa y redes neuronales artificiales para estimar los parámetros de control determinantes en la operación del reactor, utilizando algoritmos genéticos para definir escenarios de operación que permitan maximizar los rendimientos de biogás, metano y remoción.

1.4 Objetivos Específicos

1. Generar bases de datos experimentales de las diversas modalidades de digestión anaerobia mesofílica de lodos residuales que incluye: digestión anaerobia de lodos crudos, digestión anaerobia de lodos pre-hidrolizado térmicos, digestión anaerobia en medio ácido, digestión anaerobia de en medio enzimático, considerando bases de datos recabadas de investigaciones experimentales previas y con experimentación propia para su verificación y análisis.
2. Determinar los patrones de comportamiento a través de un modelo de lógica difusa, que represente el conocimiento y experiencia del personal involucrado la experimentación del PDAM con el objetivo de conocer el efecto de las variables que maximicen el rendimiento energético y de biosólidos.

3. Desarrollo de redes neuronales artificiales (RNAs) basadas en minería de datos experimentales en sus diferentes modalidades para predicción de los valores óptimos en términos de rendimiento energético y calidad de biosólidos.
4. Desarrollar escenarios óptimos a través de modelos matemáticos diseñados a partir de análisis de superficie de respuesta y optimizados por algoritmos genéticos multicriterio que determinen el proceso y su modalidad aplicable en términos de rendimiento de biogás, metano y remoción.
5. Desarrollar un Sistema Experto de Soporte a la Decisión que integre el módulo de determinación de patrones en base al conocimiento y experiencia, el módulo para la predicción de los valores óptimos a través de RNAs y el modulo para generar los escenarios óptimos que determinen el proceso y su modalidad en términos de rendimiento de biogás, metano y remoción.

1.5 Hipótesis

El desarrollo de un Sistema Experto de Apoyo a la decisión (EDSS) basado en técnicas de inteligencia artificial permitirá identificar y predecir las variables determinantes en el proceso de digestión anaerobia para incrementar el rendimiento de bioenergía y biosólidos obtenidos en plantas de tratamiento agroindustrial.

1.6 Justificación

La digestión anaerobia permite la descomposición de materia orgánica, la reducción tanto del volumen de los lodos, como la destrucción de sólidos, la reducción de atracción de vectores, la reutilización de los lodos digeridos como remediadores de suelo, y la producción de metano. Es por ello que la digestión anaerobia es considerada una de las mejores tecnologías base para reciclar energía, y contribuir a los procesos sustentables.

Existen diversas investigaciones que integran diversas aportaciones al proceso de digestión anaerobia, en algunas de estas investigaciones utilizan técnicas de inteligencia artificial para crear estrategias de control del proceso, contemplando sistemas de monitoreo o control de variables.

La presente investigación aborda el proceso de digestión anaerobia a través de un sistema experto que permita modelar las variables de control del proceso, al igual que Iter y otros investigadores en el 2010, desarrollaron modelos o sistemas expertos para predecir ciertas variables inmersas en el proceso, realizando un modelo basado en lógica difusa desarrollado para predecir las tasas de producción de metano y biogás por medio de digestión anaerobia mesofílica considerando reactores de tratamiento de aguas residuales de melaza (Iter, et. Al., 2010). A diferencia de este trabajo realizado en el 2010, el trabajado aquí expuesto propone la integración del análisis del proceso de digestión anaerobia con un pre-tratamiento para la aceleración del proceso de hidrolisis, se consideran la pre-hidrolisis térmica, ácida y enzimática en modo *batch* y en modo semicontinuo.

Otros investigadores han incursionado en el análisis de las variables que intervienen en el proceso, en el 2010, Waewsak y colaboradores desarrollan un sistema de control de un reactor anaeróbico híbrido (AHR), utilizando herramientas de redes neuronales artificiales y lógica difusa, para predecir y controlar las variables pH, sólidos volátiles y alcalinidad, considerando el tratamiento de aguas residuales con digestión anaerobia mesofílica (Waewsak et al., 2010).

En la revisión del estado de arte no existen estudios previos reportados donde se analicen las variables de operación del proceso para la determinación de patrones de comportamiento y predicción a partir de RNA'S, considerando los tres diferentes pre-tratamientos en el PDAM, y no se reporta alguna optimización del proceso, en el que se manejen algoritmos genéticos a partir de modelos matemáticos multicriterio con base al conocimiento y experiencia de especialistas involucrados en la experimentación del PDAM, otros investigadores se limitan únicamente a la predicción de algunas variables de operación del proceso, tales como. Sólidos volátiles, pH, y alcalinidad (Waewsak et al., 2010)

Por último es importante mencionar que con respecto al desarrollo tecnológico, hasta el momento no se encontró evidencia en el estado del arte del desarrollo de un SEAD (Sistema Experto de Apoyo a la Decisión) que considere el manejo de las diferentes modalidades del

PDAM en base a los siguientes módulos: a) Reconocimiento de patrones de comportamiento y predicción, b) Análisis de superficie de repuesta y c) Optimización del PDAM.

1.7 Conclusión del Capítulo

El mundo enfrenta un gran reto en materia de energía, es por ello que todos los esfuerzos realizados para generar fuentes de energía alterna y el aprovechamiento de los residuos permitirán una operación sustentable de las empresas, el desarrollo de un SEAD (Sistema Experto de Apoyo a la Decisión) puede ser una herramienta útil para seleccionar el pre-tratamiento a realizar en el biosólido y que permita predecir y optimizar los rendimientos de biogás, metano y remoción, antes de iniciar la operación del reactor.

Capítulo II

Marco teórico

Capítulo 2. Marco teórico

2.1 Introducción

En el presente trabajo se presenta una semblanza de los temas que corresponden los principales conceptos y temas que se incluyen en el desarrollo de la investigación, así como las técnicas que se emplearon para generar el SEAD.

El proceso de Digestión Anaerobia, es un proceso microbiológico en el cual la materia biodegradable se descompone en ausencia de oxígeno mediante la acción de distintos grupos de bacterias, dando como resultado la producción de biogás, es por ello que es necesario profundizar en el análisis del proceso, también se expone una descripción de las técnicas de inteligencia artificial empleadas, entre ellas, lógica difusa, redes neuronales artificiales y algoritmos genéticos.

2.2 Origen de los lodos residuales

Los lodos son sólidos con un contenido variable de humedad, provenientes del desazolve de los sistemas de alcantarillado urbano o municipal, de las plantas potabilizadoras y de las plantas de tratamiento de aguas residuales (PTAR), que no han sido sometidos a procesos de estabilización (NOM-004 SEMARNAT-2002).

El tratamiento de las aguas residuales consiste en una serie de operaciones en las cuales los contaminantes son gradualmente degradados o removidos, brindando un efluente limpio y un residuo con relativamente alta concentración de sólidos denominado lodo residual, los cuales presentan diferentes características dependiendo de la etapa de tratamiento de aguas en la que se generaron. La Figura 2.1 muestra la generación de lodos residuales en las diferentes etapas de un proceso de tratamiento de aguas residuales, cada etapa del proceso de tratamiento genera lodos residuales (Ruiz, 2012).

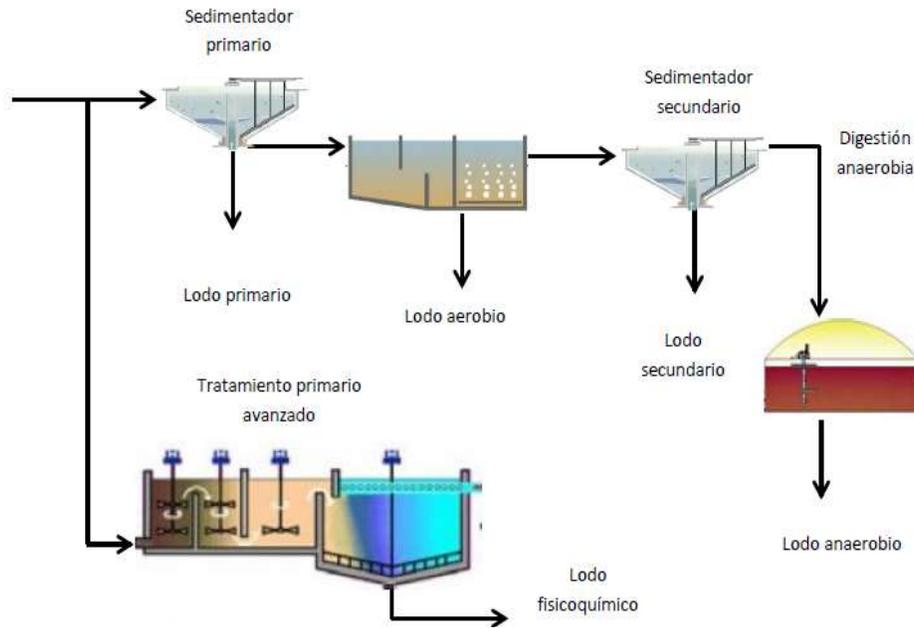


Figura 2.1 Generación de lodos residuales en los sistemas de tratamiento de aguas (Ruiz,2012).

Comúnmente el tratamiento de las aguas residuales consta de:

- Tratamiento primario
- Tratamiento secundario
- Tratamiento terciario

El tratamiento primario generalmente incluye operaciones físicas y algunas veces operaciones químicas, reduciendo aceites, grasas, arenas y sólidos gruesos. Para ello se utilizan tanques sedimentadores y así poder a llevar a cabo una sedimentación primaria de los sólidos suspendidos.

El tratamiento secundario es usualmente biológico y se utiliza para degradar la materia orgánica disuelta en el agua residual. Se utilizan generalmente reactores biológicos bajo condiciones aerobias y anaerobias en modo por lote o continuo, utilizando tecnologías de biomasa fija o suspendida. El proceso mayormente utilizado en las PTAR para el tratamiento biológico son los lodos activados.

El tratamiento terciario proporciona una etapa final para aumentar la calidad del efluente, comúnmente el proceso de desinfección se lleva a cabo en esta etapa, así como las etapas de remoción de nutrientes como nitrógeno (nitrificación/desnitrificación) y fósforo.

2.3 Bioenergía

La generación de energía se ha convertido en un importante tema de investigación, por lo que la posibilidad de aprovechamiento de cualquier fuente energética, especialmente si se trata de un recurso renovable, es una obligación de la sociedad.

La bioenergía es una de las fuentes energéticas renovables más importantes, la cual puede emplearse en forma sólida, líquida y gaseosa para la producción de electricidad y calor, y para la fabricación de biocarburantes. El concepto de bioenergía, engloba todo el proceso mediante el cual se lleva a cabo la transformación de la materia prima (residuos orgánicos) en fuente de energía, sin embargo; para que la bioenergía sea posible, antes debe obtenerse el biogás, el cual se produce a cuando los desechos orgánicos son digeridos en condiciones anaeróbicas húmedas y cálidas. (Dalzell, et al., 1991).

2.3.1 Biomasa

La bioenergía es la energía que se obtiene a partir de la biomasa, la cual es la materia orgánica originada en un proceso biológico, espontáneo o provocado, utilizable como fuente de energía; entonces, según (Castells, 2012), puede definirse a la biomasa como “Toda planta o materia que hay en la superficie: residuos agrícolas, forestales, restos de las industrias de madera y cultivos energéticos, también incluye a todos los productores de biomasa, incluyendo a los organismos vivos, de origen biológico”. La biomasa se encuentra disponible localmente como fuente de energía, la cual puede proveer electricidad, calor y energía.

En general cualquier substrato puede ser utilizado como biomasa en cuanto contengan carbohidratos, proteínas, grasas y celulosa como componentes principales. Para seleccionar la biomasa se considerar:

- El contenido de sustancias orgánicas debe ser el apropiado para el tipo de fermentación elegido.
- El valor nutricional de la sustancia orgánica se relaciona directamente con el potencial de formación de biogás, por ende se busca que sea lo más alto posible.
- El substrato debe estar libre de agentes patógenos que puedan inhibir el proceso de fermentación.
- El contenido de sustancias perjudiciales o tóxicas debe ser controlado para permitir una tranquila evolución de la fermentación.
- Es importante que el resultado final del substrato (después de haber aprovechado la fermentación para generar biogás) sea un desecho utilizable.
- El principal substrato (biomasa) disponible en el sector económico, se refiere a los animales de aprovechamiento (carne, leche, engorda); a continuación se muestran las equivalencias de excremento producido y potencial para la generación de biogás (Pérez Mendel, 2010), Tabla 2.1.

Tabla 2.1. Equivalencia de residuo producido y potencial para la generación de biogás (Pérez Mendel, 2010).

		Estiércol liq. [M ³ /animal]				Producción de gas M ³ /UAE/día
		UAE ¹	Día	Mes	Año	
Bovinos	Vacas, vacunos de engorda	1	0.05	1.5	18	0.56 - 1.5
	Vacas de producción lechera	1.2	0.055	1.65	19.8	0.56 - 1.5
	Toro de reproducción	0.7	0.023	0.69	8.28	0.56 - 1.5
	Vacunos jóvenes < 2 años	0.6	0.025	0.75	9	0.56 - 1.5
	Ternero de crinza < 1 año	0.2	0.008	0.24	2.88	0.56 - 1.5
	Ternero de engorda	0.3	0.004	0.12	1.44	0.56 - 1.5
Porcino	Porcino de engorda	0.12	0.0045	0.135	1.62	0.6 - 1.25
	Porcino de engorda	0.34	0.0045	0.135	1.62	0.6 - 1.25
	Porcino jóvenes (<12 kg)	0.01	0.0045	0.135	1.62	0.6 - 1.25
	Porcino jóvenes (12 - 20 kg)	0.02	0.001	0.03	0.36	0.6 - 1.25
	Porcino jóvenes (20 - 45 kg)	0.06	0.003	0.09	1.08	0.6 - 1.25
	Porcino jóvenes (45 - 60 kg)	0.16	0.0045	0.135	1.62	0.6 - 1.25
Ovinos	Ovejas < 1 año	0.05	0.003	0.09	1.08	-
	Ovejas > 1 año	0.1	0.006	0.18	2.16	-
Equinos	Caballos < 3 años	0.7	0.023	0.69	8.28	-
	Caballos enanos	0.7	0.023	0.69	8.28	-
	Caballos > 3 años	1.1	0.033	0.99	11.88	-
Aves de criadero	Pollo de engorda < 1200 gr	0.0023	0.0001	0.003	0.04	3.5 - 4
	Gallina < 1200 gr	0.0023	0.0001	0.003	0.04	3.5 - 5
	Pollo < 800 gr	0.0016	0.0001	0.003	0.04	3.5 - 6
	Gallina < 800 gr	0.0016	0.0001	0.003	0.04	3.5 - 7

2.3.2 Biogás

El biogás es obtenido a partir de diferentes recursos: componentes orgánicos procedentes de vertederos de basuras, aguas residuales comunitarias, desechos orgánicos procedentes de la industria, las viviendas comercios y granjas agrícolas. El biogás está compuesto por gas metano (CH_4) en un 60% y por dióxido de carbono (CO_2) en un 35%, ambos considerados componentes de efectos invernadero que contribuyen al calentamiento global. (Hazell & Pachauri, 2006).

El biogás, es generado a través de la descomposición microbiológica de la materia orgánica es un proceso natural que tiene lugar en todos los ámbitos donde se descompone materia orgánica, también llamada biomasa, en un entorno húmedo y anóxico a través de la actividad bacteriológica.

La energía contenida en la materia orgánica procede originariamente de la luz solar que es transformada en energía bioquímica por medio de la fotosíntesis. Por lo tanto el aprovechamiento de biogás es en realidad un aprovechamiento indirecto de la energía solar. Básicamente se podrá utilizar todo tipo de materias orgánicas o biológicas para la generación de biogás, siempre y cuando éstas pudieren ser reducidas por microorganismos.

El biogás se produce por procesos naturales o se puede generar controladamente en los llamados digestores, que tienen como detonante común la circunstancia de que el proceso se desarrollará bajo condiciones técnicamente controladas. (González La Fuente, 2002).

Como producto final de este proceso se obtiene un fango de fácil deshidratación y el biogás, el cual se compone de metano en una composición de alrededor del 60%, dióxido de carbono 35%, así como del nitrógeno, hidrógeno y hidrógeno de azufre.

El porcentaje de los componentes que integran el biogás, puede variar dependiendo de la forma de obtención y de los sustratos empleados, la Tabla 2.2, muestra los porcentajes de los componentes del biogás. (Castells, 2012).

Tabla 2.2. Porcentaje de los componentes que integran el biogás (Castells, 2012).

Componente Porcentaje (%)	Componente Porcentaje (%)
CH ₄	40 – 60
CO ₂	25 – 50
O ₂	< 1
N ₂	5
H ₂	< 0.1
CO	< 0.01
Etano, propano y butano	< 0.01
Compuestos halogenados	Trazas
H ₂ S	H ₂ S
Organosulfuros	Trazas

2.3.3 Biodigestor

Como ya se hizo mención anteriormente, una manera de transformar residuos orgánicos en biogás, es a través de un biodigestor, ya que éstos son utilizados para la para la producción y captación de biogás, y su aprovechamiento energético.

Un biodigestor es una alternativa sencilla y práctica que sirve para aprovechar los desechos orgánicos, ya que permite convertir excremento (de animales) y desechos vegetales mezclados con agua para que se descomponga, produciendo gas metano (CH₄) y fertilizantes orgánicos ricos en nitrógeno, fósforo y potasio. (Pérez Mendel, 2010). Existen diferentes tipos de biodigestores; los cuales varían según los desechos a tratar, las condiciones de operación, etc.

2.3.3.1 Partes de un biodigestor

Aunque existen diferentes tipos de biodigestores en cuanto a diseño, sin embargo; un biodigestor por lo general está formado por cinco partes principales (Elizondo, 2005):

La pila de carga: Es un depósito en donde se verte la mezcla de los materiales que alimentan al biodigestor.

Digestor: Tanque en donde en su interior los desechos son descompuestos. Por un extremo se conecta a la pila de carga y por el otro a la pila de descarga.

Pila de descarga: Sirve para retirar los residuos provenientes del tanque que fueron digeridos. Está colocada a menor nivel que la pila de carga.

Cubierta plástica: Se coloca sobre el digestor, ésta es la encargada de cerrar la entrada de aire al interior del mismo y de almacenar el gas producido.

Tubería, válvula y llave de paso: Se conecta una tubería en la parte superior de la cubierta plástica que conduce el gas donde será aprovechado; además, se conecta una sencilla válvula de seguridad que evita la sobre presión interna en la cubierta plástica y elimina el agua condensada en la tubería. La llave de paso es la encargada de permitir el paso del gas cuando se necesita.

2.4 Digestión anaerobia

La digestión anaerobia permite la descomposición de materia orgánica, la reducción tanto del volumen de los lodos, como la destrucción de sólidos (25-45% usualmente), la reducción de atracción de vectores, la reutilización de los lodos digeridos como remediadores de suelos o abono, así como la producción de metano; además de la recuperación o producción de otros materiales valiosos, incluyendo nitrógeno y fósforo.

Teniendo en cuenta lo anterior se reconoce a la digestión anaerobia como una de las tecnologías de base para reciclar energía, y contribuir a los progresos sostenibles.

La digestión anaerobia es un proceso secuencial que consiste en la degradación biológica por un ecosistema microbiano complejo de sustratos orgánicos en la ausencia de una fuente del oxígeno, es fuertemente regulada por aceptores de electrones, y se lleva a cabo a través de una serie de procesos secuenciales y paralelos.

El proceso de digestión anaerobia consiste en cuatro pasos principales: Hidrólisis, Acidogénesis, Acetogénesis y Metanogénesis (Nava, 2011).

2.4.1 Fases del proceso de la digestión anaerobia

En el proceso de digestión anaerobia, se divide en cuatro fases o procesos:

- Hidrólisis
- Etapa fermentativa o acidogénica
- Etapa acetogénica
- Etapa metanogénica

Hidrólisis

En esta etapa, las bacterias, principalmente celulolíticas, actúan sobre la materia orgánica degradándola, es decir; conversión de moléculas orgánicas complejas en sus componentes más simples, es realizada a través de enzimas sintetizadas por los microorganismos. En esta fase, se produce la despolimerización de las macromoléculas, las cuales se transforman en moléculas más simples (Castells & Bordas, 2011). Esta etapa inicial condiciona a las siguientes etapas, ya que los microorganismos que actúan en las mismas sólo lo hacen sobre compuestos disueltos, por lo que esta fase es limitante para contenidos importantes de sólidos en suspensión. La velocidad de esta etapa va a estar determinada entre otros factores, por el tamaño de los sólidos en suspensión y de la naturaleza de la materia orgánica (Sainz Satre, 2005).

La digestión anaerobia de sólidos biológicos viables, como los lodos activos, requieren un mecanismo de conversión adicional, denominado lisis o muerte celular, antes de que el material orgánico pueda ser hidrolizado. Los productos generados de la hidrólisis deben ingresar, a continuación, hacia el interior de la célula a través de la membrana celular para ser metabolizados (Pavlostathis & Gómez, 1991). Durante la etapa de la hidrólisis, se presentan tres tipos de reacciones sucesivas: hidrólisis de los polisacáridos, lípidos y proteínas. Los productos resultantes de estas reacciones, son fermentados hasta formar ácidos grasos, produciéndose pequeñas cantidades de dióxido de carbono (CO₂). (Nava, 2011).

Fermentación o Acidogénesis.

Los microorganismos responsables de esta etapa o bacterias acidogénicas, se caracterizan por ser microorganismos de rápido crecimiento, los cuales son muy resistentes al medio en el que se encuentran, además desarrollan su máxima actividad a valores de pH ligeramente ácidos ($\text{pH} < 7$) (Instituto para la Diversificación y Ahorro de la Energía (IDAE), 2007). En esta etapa los productos generados en la etapa de hidrólisis, son fermentados intracelularmente produciendo los ácidos grasos volátiles (AGV) de cadena corta conocidos como ácidos volátiles, los cuales son transformados en dióxido de carbono (CO_2) en el que el oxígeno es procedente del disponible en la materia orgánica o en sales inorgánicas, también se presenta la producción de hidrógeno (H_2) (Pavlostathis & Gómez, 1991).

Los ácidos grasos volátiles (AGV) generados, mas importantes son el acético, propiónico, butírico; y en segundo término el valérico y el caproico; y el ácido fórmico en cantidades muy pequeñas. La cantidad producida de ácidos grasos volátiles, depende de la producción de la concentración de hidrógeno en el sistema, por lo que si baja la concentración de hidrógeno, aumenta la cantidad de acético. Durante esta etapa no hay una reducción significativa en la demanda química de oxígeno (DQO) (Sainz Satre, 2005).

Acetogénesis

En esta etapa ocurre la degradación de los productos de la fermentación a acetato usando iones hidrogenados o bicarbonato como aceptor de electrón externo, mientras que algunos productos de la fermentación pueden ser metabolizados por los microorganismos o bacterias metanogénicas, mientras que otros necesitan ser transformados en productos más sencillos, acetato e hidrógeno, a través de las bacterias acetogénicas. (Nava, 2017).

Las bacterias acetogénicas, originan la producción de ácido acético a partir de los ácidos orgánicos generados en la etapa de Acidogénesis. Sin embargo, este proceso es inhibido cuando la concentración de hidrógeno en el medio comienza a elevarse. (Sainz Satre, 2005).

El ácido acético producido en esta etapa, sirve como substrato para las bacterias metanogénicas. Durante esta etapa, de la digestión anaerobia se produce de igual modo el

dióxido de carbono e hidrógeno, los cuales sirven también como sustrato para las bacterias metanogénicas de la siguiente etapa (Nava, 2017).

Metanogénesis

Las sustancias producidas en etapas anteriores son atacadas por las bacterias metanogénicas, las cuales necesitan encontrarse en una atmosfera con ausencia de oxígeno, durante esta etapa se obtiene metano (CH_4) a partir del ácido acético obtenido en la fase de Acetogénesis, o bien por la reacción del oxígeno con el dióxido de carbono (CO_2) generados en la etapa de Acidogénesis (Sainz Satre, 2005), como se muestra en la siguiente ecuación:

2.4.2 Clasificación de la digestión anaerobia

Existen diferentes criterios para la clasificación de la digestión anaerobia generalmente en función de las condiciones de operación; la más frecuente es la que clasifica al proceso en función de la temperatura, sin embargo también se puede clasificar de acuerdo a la carga orgánica tratada, el número de digestores empleados en el proceso y el tipo de sustrato (Tabla 2.3).

Tabla 2.3 Diversas clasificaciones de la digestión anaerobia.

Criterio	Clasificación
Temperatura	Psicrofílica Mesofílica Termofílica
Carga Orgánica	Baja Media Alta
Número de etapas	Una sola etapa Dos etapas Multi-etapa
Tipos de sustratos	Aguas residuales Lodos residuales Residuos sólidos orgánicos Combinación de los anteriores

2.4.3 Variables de operación o control

Las variables de control que se estimaron para el desarrollo del sistema experto de apoyo a la decisión, se definieron con el apoyo de un grupo de expertos y por medio de una revisión de la literatura referente al proceso, a continuación se mencionan las variables de control que intervienen en el proceso de digestión anaerobia mesofílica.

2.4.3.1 pH

El pH se considera un factor clave en el crecimiento de los microorganismos. La mayoría de estos no pueden tolerar niveles de pH por encima de 9.5, o por debajo de 4.0. Por lo general el tratamiento anaerobio trabaja dentro de un rango en el que el pH debe oscilar entre 6.5 y 7.5, con un óptimo entre 7.0 y 7.2. A un pH menor las bacterias se afectan seriamente (Girovich, 1996). Por otra parte, se necesita una alcalinidad del orden de 1000 mg/L o más como CaCO_3 , para evitar cambios en el pH, que provocarían un desequilibrio. (Jih-Gaw et al., 1997). Es importante señalar que el descontrol del pH es el resultado de un desequilibrio debido a un cambio en el proceso, lo que debe ser corregido mediante la adición de Ca(OH)_2 o NaHCO_3 para dar tiempo de efectuar la corrección (Luna and Guyot, 1990).

El pH es también una importante variable de diagnóstico de los sistemas anaerobios, pues muchos fenómenos tienen influencia sobre el mismo. Otros autores no consideran el pH como una buena variable de control por resultar demasiado lenta: una vez detectada una variación importante, el fracaso del sistema puede ser irreversible (Iza, 1995).

Por ello, se consideran otras variables como indicadores de estado del proceso anaerobio, como la producción de biogás y su contenido de CH_4 (Hill and Holmberg, 1988), la actividad bacteriana (Angelidaki and Ahring, 1997), los ácidos grasos volátiles o la relación entre ellos (Hillet et al., 1987; Ahring et al., 1995).

2.4.3.2 Alcalinidad y relación de alcalinidad

La alcalinidad es una medida inespecífica de la capacidad reguladora del medio que puede ser proporcionada por un amplio rango de sustancias como: Bicarbonatos de calcio, magnesio y amonio. En el intervalo de pH de 6 a 8, el principal equilibrio químico que la controla es el CO₂-bicarbonato.

La relación de alcalinidad, se define como la relación entre la alcalinidad por AGV's y la debida al bicarbonato, recomendándose no sobrepasar un valor de 0.3-0.4 para evitar la acidificación (Iza, 1995), aunque Noyola y Tinajero (2005), establecieron valores aceptables de 0.46-0.48 para la estabilidad de la digestión anaerobia.

2.4.3.3 Producción de biogás

El biogás es una mezcla de metano, bióxido de carbono y trazas de sulfuro de hidrógeno producto de la digestión anaerobia. La materia orgánica compleja se transforma en metano y bióxido de carbono como consecuencia de la actividad microbiana y sus proporciones dependen de factores el tipo de sustrato, la temperatura, el pH y la presión; si alguna de estas variables sufre algún cambio la composición del biogás puede alterarse.

El porcentaje de metano producido depende del estado de oxidación del compuesto que se degrada por ejemplo la composición típica cuando se alimentan carbohidratos es 55% metano y 45% bióxido de carbono y aunque el metanol y los lípidos producen mayor porcentaje de metano, las grasas logran producir hasta un 75% de metano (Marchaim, 1992). Se ha puesto atención especial al metano porque es un gas de efecto invernadero, lo que quiere decir que su presencia en la atmósfera afecta la temperatura y el sistema climático de la tierra; sin embargo, su alto valor como combustible lo hace una fuente potencial de energía, que puede recuperarse durante el proceso de la digestión anaerobia. Por lo tanto se han realizado diversos estudios para maximizar tanto la producción de biogás, como el contenido de metano en este proceso, mediante la adición de bacterias hidrogenotróficas, (Bagi et al., 2007), por mencionar algunos métodos.

2.4.3.4 Reducción de materia orgánica

En la digestión anaerobia, la reducción de materia orgánica se considera una de las variables más importantes en el tratamiento de lodos residuales ya que está íntimamente ligado a la producción de biogás y metano, indica directamente el grado de estabilización del sustrato, motivo por el cual la legislación de diferentes países la consideran como principal criterio para el tratamiento, manejo y disposición de lodos residuales; además de ser un factor clave en el arranque de los digestores debido a que el tiempo de residencia hidráulico (TRH) depende directamente de ésta. En el contexto de un balance de materia puede calcularse conociendo la concentración de Sólidos Volátiles o la Demanda Química de Oxígeno en el influente y en el efluente (Metcalf & Eddy, 2003).

2.4.3.5 Rendimientos de biogás y de metano

Los rendimientos de biogás y metano se relacionan directamente con la materia orgánica alimentada al reactor, generalmente se reportan como volumen del gas por masa o peso de materia orgánica alimentada o removida. Y se consideran directamente proporcionales a la eficiencia del proceso; sin embargo es importante hacer notar que los rendimientos también dependen de la naturaleza del sustrato, es decir si los rendimientos son bajos no necesariamente indican un comportamiento deficiente si se deben a una baja biodegradabilidad del sustrato.

El rendimiento de metano se considera el mejor indicativo de la eficiencia del proceso de digestión anaerobia, a diferencia del rendimiento de biogás por qué no considera la concentración de bióxido de carbono, sin embargo para el cálculo de esta variable es necesario el análisis del biogás producido (Nava, 2011).

2.4.3.6 Temperatura

Juega un papel vital en la vida y muerte de las bacterias involucradas en el proceso. Cada grupo de bacterias metanogénicas tiene una temperatura óptima de crecimiento en los diferentes rangos de operación en la que se alcanza la máxima actividad microbiana y, en consecuencia, la máxima remoción de los Sólidos Volátiles a ciertas condiciones dadas en el proceso. Los intervalos típicos de temperatura para las bacterias en cada una de las categorías señaladas pueden observarse en la Tabla 2.4.

Tabla 2.4 Intervalos de temperatura típicas para diversas bacterias (Metcalf & Eddy, 2003)

Temperatura °C		
Tipo	Intervalo	Óptimo
Psicrófilas	-2-30	12 – 18
Mesófilas	20 – 45	25 – 40
Termófilas	45 – 75	55 - 65
Hipertermófilas	80 - 95	85-90

Este aspecto es consecuencia de que las reacciones biológicas de transformación de los sustratos en productos por parte de los microorganismos son dependientes de la temperatura, y por lo tanto requieren menor energía a mayor temperatura, lo que implica un proceso más rápido a mayor temperatura.

Si la temperatura llega a fluctuar demasiado, las bacterias metanogénicas no pueden desarrollarse adecuadamente y el resultado será una deficiencia en el proceso.

2.4.3.7 Carga orgánica

Es uno de los parámetros más útiles para describir las condiciones de alimentación (concentración y volumen), se expresa típicamente como peso de materia orgánica expresada en concentración de Sólidos Volátiles o Demanda Química de Oxígeno (DQO) por unidad de volumen del reactor por día. Representa la medida exacta de alimento que un digester necesita.

2.4.3.8 Tiempo de retención hidráulico

Es un parámetro muy importante, depende típicamente del tipo de reactor, en los sistemas de mezcla completa coincide con el tiempo de retención celular, por lo que debe ser suficientemente largo para que se desarrollen las bacterias. Algunos tiempos reportados para la digestión anaerobia con cargas orgánicas convencionales van de 15 a 28 días y para alta carga orgánica se encuentran reportados valores de hasta 60 días (Cabirol et al., 2000; Girovich, 1996; Hobson, 1990).

2.4.4 Pre tratamientos para optimizar el proceso de digestión anaerobia

En el campo de tratamiento de lodos residuales, los procesos biológicos tales como la digestión aerobia y anaerobia cumplen satisfactoriamente con la remoción de la materia orgánica, sin embargo unos de los principales inconvenientes de estas tecnologías son los largos tiempos que representa aplicar estos tratamientos. En este sentido términos como pre-tratamiento, co-tratamiento, desintegración e hidrólisis han ganado popularidad como procesos que complementan a un proceso biológico. De tal forma que el objetivo de todo tren de tratamiento es remover el material orgánico y agua, además reducir volumen y masa, estabilizar el material degradable, con lo que se previenen los subsecuentes olores y atracción de vectores y finalmente inactivar patógenos.

El tratamiento de los residuos sólidos puede llevarse a cabo de forma satisfactoria si se logra intensificar la etapa limitante en la anaerobiosis (Vavilin et al., 1999). La tasa (velocidad) de hidrólisis, en general, aumenta con la temperatura (Bonmati et al., 2000, Del Borghi et al., 1999, Pavlostathis y Giraldo-Gómez, 1991; Siegrist et al., 1993; Veeken y Hamelers, 1999), independientemente del compuesto de que se trate. Existen diferentes tecnologías para desintegrar e hidrolizar la materia orgánica entre las que se encuentran, la hidrólisis térmica, tratamientos mecánicos (ultrasonido, lisis por centrifugación, cizallamiento de líquidos, colisión en placa y homogenización a alta presión), tratamientos químicos (oxidación con ozono o peróxido de hidrógeno) y tratamientos alcalinos (Carrère *et al.*, 2010).

2.4.4.1 Pre-hidrólisis térmica

Todos los tratamientos previos son una buena alternativa sin embargo el pre-tratamiento térmico es el más empleado porque logra una alta solubilidad y un alto porcentaje de reducción de materia orgánica de entre el 28 y 29%.

La hidrólisis térmica en combinación con la digestión anaerobia presenta las ventajas siguientes:

Incremento en la producción de biogás en digester debido a un mayor rendimiento de la digestión sobre todo en lodos residuales que se traduce con la instalación de una cogeneración, en una mayor producción eléctrica, consiguiendo el máximo rendimiento energético en el aprovechamiento de biogás como energía renovable.

El lodo hidrolizado y digerido presenta una mayor facilidad para su deshidratación consiguiendo grados de sequedad más altos a la salida de la deshidratación, reduciendo su volumen final y consiguientemente el costo del tratamiento posterior o disposición final del residuo agroindustrial.

La hidrólisis de lodo residual a altas temperaturas mayores de 90 °C produce una hidrogenización completa de los residuos agroindustriales, con una ausencia total de patógenos, permitiendo la aplicación agrícola con la garantía de producir biosólidos Clase A.

En algunos casos el tratamiento térmico se considera capaz de remover huevos de helmintos que son estructuras altamente resistentes, los escasos estudios realizados para remover huevos de helmintos mediante la pre hidrólisis térmica son de Cabirol et al., (2002b), quienes reportan que el proceso logra niveles aproximadamente menores a 0.28 huevos de helmintos viables/g ST en tiempos de retención hidráulica de 20 días. Lo anterior demuestra que ésta tecnología se aproxima al cumplimiento de normas sumamente estrictas como la norma de los Estados Unidos (U.S. EPA, 1999), por lo que se hace necesario evaluar su efecto en residuos agroindustriales con características específicas como los producidos en México.

2.4.4.2 Pre tratamiento con pre hidrólisis ácida

Normalmente la hidrólisis ácida se lleva a cabo generalmente por calentamiento con un dilución diluida de ácido a temperaturas que van desde de 35 a 200 °C por un cierto periodo que puede ser de unos cuantos minutos a horas con éste pre tratamiento, la hemicelulosa es hidrolizada y principalmente se obtiene monómeros de Azúcares fermentables (Galbe y Zacchi, 2007). Otros factores que también pueden interferir en la determinación de la reacción son la cantidad de material, la interferencia con otros compuéstos, presencia de diferentes tipos de enlaces, estructura cristalina o la forma de la matriz (Aguilar, 2002).

2.4.4.3 Pre tratamiento con hidrólisis enzimática

El tratamiento enzimático el cual utiliza enzimas que son catalizadores de origen proteico producidas por los seres vivos. Estos catalizadores biológicos aceleran las reacciones bioquímicas a temperaturas alrededor de 36° (para el caso de organismo mesofílicos). Es un método de conversión de compuestos lignocelúlosicos a compuestos fáciles de biodegradación (Azúcares fermentables) mediante la hidrólisis, en la cual se utiliza una amplia gama de microorganismo incluyendo bacterias y hongos, (Berlin et al., 2006).

Las dos características más importantes de una enzima son su especificidad y la tasa de la reacción que cataliza. La especificidad significa que una enzima conduce la transformación de un producto químico a lo largo de una trayectoria deseada; mientras que la tasa se refiere a la velocidad a la que ocurre la reacción en presencia de la enzima; además de éstas características se estima que una molécula de enzima puede efectuar entre 1,000 y 100,000 transformaciones moleculares por segundo.

Para obtener mejores resultados en la hidrólisis de compuestos lignocelulósicos a compuestos fácilmente biodegradables, pueden utilizarse enzimas en estado puro (una sola especie) o una combinación de las mismas (varias especies) para desempeñar de forma efectiva la etapa de hidrolisis (Wyman et al., 2005).

Las enzimas son compuestos biodegradables y por lo tanto ambientalmente amigables (Berlin et al., 2006) Se ha demostrado que el pre tratamiento secuencial permite un mayor aprovechamiento de las fracciones lignocelulósicos.

En otros estudios se ha observado que la desintegración bioquímica de lodos se basa en la actividad enzimática que se produce como resultado de la actividad de especies presentes en el sistema (autólisis) o añadidas desde fuera. La lisis enzimática rompe los compuestos de la pared celular mediante reacciones catalizadas por enzimas.

Éste proceso mejora sus resultados en combinación con un pre-tratamiento mecánico de desintegración, ya que las enzimas están también en el líquido intracelular (Thomás et al., 1993).

2.5 Técnicas de inteligencia artificial

La Inteligencia Artificial (AI por sus siglas en inglés), surgió poco después de la Segunda Guerra Mundial, su nombre se acuñó en 1965. La AI se considera importante para cualquier ámbito de la actividad humana debido a que sintetiza y automatiza tareas intelectuales, por lo que se puede decir que es un campo universal.

La inteligencia artificial podría definirse inicialmente como la facultad de conocer, entender o comprender de las máquinas. La inteligencia artificial, tiene diferentes definiciones por cada autor que escribe con respecto al tema, sin embargo, la más ajustada a la realidad es la expresada por la Encyclopedia Of Artificial Intelligence (Pino Diez, et al., 2001).

“La IA es un acampo de la ciencia y la ingeniería que se ocupa de la comprensión, desde el punto de vista informático, de lo que se denomina comúnmente comportamiento inteligente. También se ocupa de la creación de artefactos que exhiben este comportamiento”.

La inteligencia artificial tiene diversas áreas de aplicación (Escolano Ruiz, et al., 2003), entre las que destacan:

- Procesamiento del lenguaje natural

- Sistemas expertos
- Robótica
- Visión artificial
- Resolución de problemas
- Aprendizaje

Las primeras investigaciones acerca de la inteligencia artificial estaban principalmente dirigidas al hallazgo de una técnica universal para la solución de problemas. Este intento a gran escala ha sido abandonado y las investigaciones actuales están dirigidas al diseño de numerosos programas para ordenadores capaces de imitar los procesos de toma de decisiones de expertos, para con ello crear un sistema capaz de reproducir todas las facetas de la inteligencia humana (Álvarez Muñárriz, 1994).

2.5.1 Sistemas expertos basados en Inteligencia Artificial

En los procesos agroindustriales existen factores aleatorios que deben ser controlados para mejorar la calidad y aumentar la cantidad de sus productos para mercados más exigentes, en el que existen competidores que ofrecen productos con menores costos. Para lograr un aumento en nuestra competitividad hace falta incorporar sistemas expertos que emulen el conocimiento y razonamiento humano.

Los sistemas expertos son considerados una rama de la inteligencia artificial. El termino sistema experto se refiere a la creación de un software que emula el razonamiento humano a través de deducción lógica o patrones de comportamiento utilizando modelos matemáticos en un entorno de incertidumbre y riesgo.

Un sistema experto debe tener las siguientes características:

- Habilidad para llegar a una solución de los problemas de manera rápida y certera.
- Habilidad para explicar los resultados a las personas que no cuentan con ese conocimiento.

- Habilidad para aprender de las experiencias.
- Capacidad de reestructuración del ambiente para adaptarse al nuevo entorno.
- Y tener consciencia de sus limitaciones.

Un sistema experto está conformado por tres componentes: la base del conocimiento, la base de los hechos y el motor de inferencia, tal como se aprecia en la Figura 2.2, en el que se complementa con el módulo de justificación e interfaz del usuario.

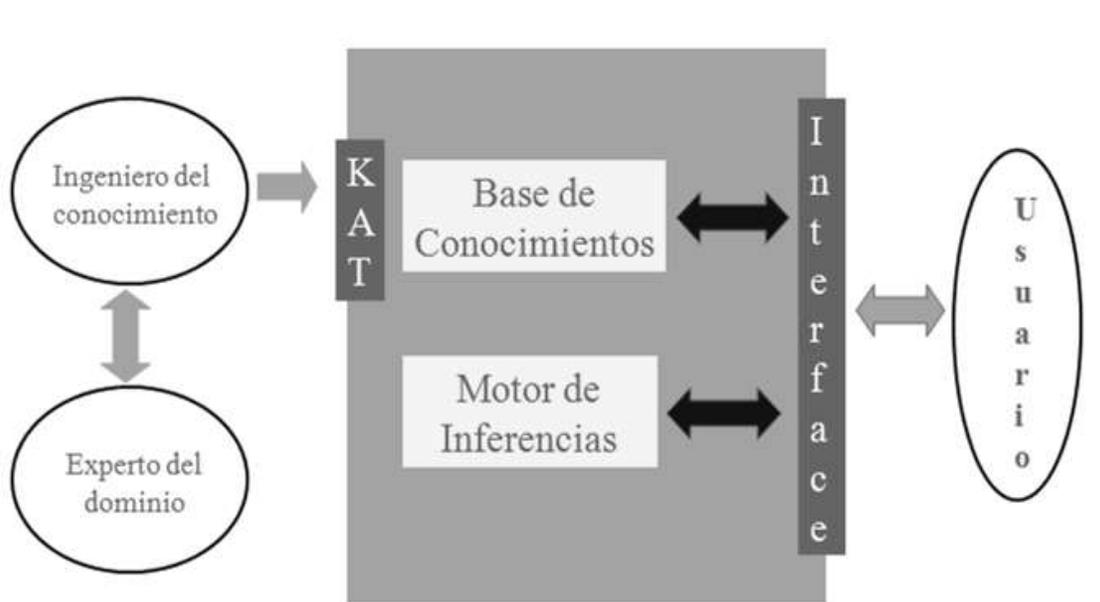


Figura 2.2 Arquitectura de un sistema experto (I. G. 2005).

La base de los conocimientos está formada por toda la cantidad de información disponible sobre el campo en el que se desarrolla la aplicación. Esta información debe contener tanto los hechos contrastados como las creencias y los heurísticos adquiridos por los especialistas a través de la experiencia. El orden en el que los elementos básicos de información se incluyen en la base de conocimientos no es normalmente determinativo, es decir pueden introducirse a la base de datos tal como se extraen del especialista. Esto es particularmente interesante tanto en el momento de construcción como en el de depuración de la base de conocimientos.

La base de los hechos está formada por datos sobre la situación concreta que va a ser considerada, además puede verse utilizarse como memoria auxiliar o de trabajo para almacenar los modos de razonamiento y la forma en que han sido utilizados. De esta forma bajo los

requerimientos del usuario final, el sistema ha de ser capaz de explicar cómo ha conseguido llegar a los resultados finales. Esta clarificación y transparencia en el modo de razonamiento es, la mayoría de las veces, de mayor importancia para el usuario final.

El motor de inferencia es la parte que se encarga de gestionar la información existente en la base de conocimientos, y en los datos de la base de los hechos, confrontándolos para construir una serie de razonamientos que conduzcan a los resultados. Básicamente pueden utilizar dos modos de razonamientos diferentes: el “encadenamiento hacia adelante” y el “encadenamiento hacia atrás”. En el primero puede aplicarse cuando las condiciones indicadas en la parte izquierda (premisas) se cumplen en la situación que se está considerando indicada en la base de los hechos o memoria de trabajo. Si esto ocurre, las condiciones expresadas en la parte derecha de la regla se agregan a la base de hechos y continua el proceso de razonamiento.

En el encadenamiento hacia atrás se parte de un conjunto de hipótesis que son contrastadas con las partes derechas de las reglas de la base de conocimiento. Al aplicar una regla se sustituye el objetivo inicial por un conjunto de sub-objetivos indicados por las premisas de la regla aplicada y se continúa el proceso.

La interfaz de usuario es el medio con que el usuario puede comunicarse con una máquina, un equipo o una computadora, y comprende todos los puntos de contacto entre el usuario y el equipo, normalmente suelen ser fáciles de entender y fáciles de accionar, es decir, es la interacción entre el SE y el usuario, y se realiza mediante el lenguaje natural.

2.5.2 Sistemas de Apoyo a la Toma de Decisiones (DSS)

Debido a que hay muchos enfoques para la toma de decisiones y debido a la amplia gama de ámbitos en los cuales se toman las decisiones, el concepto de sistema de apoyo a las decisiones (DSS por sus siglas en inglés Decision support system) es muy amplio. Un DSS puede adoptar muchas formas diferentes. En general, podemos decir que un DSS es un sistema informático utilizado para servir de apoyo, más que automatizar, el proceso de toma de decisiones. La decisión es una elección entre alternativas basadas en estimaciones de los valores de esas alternativas.

El apoyo a una decisión significa ayudar a las personas que trabajan solas o en grupo a reunir inteligencia, generar alternativas y tomar decisiones. Apoyar el proceso de toma de decisión implica el apoyo a la estimación, la evaluación y/o la comparación de alternativas. En la práctica, las referencias a DSS suelen ser referencias a aplicaciones informáticas que realizan una función de apoyo.

Un DSS, en términos muy generales, es "un sistema basado en computador que ayuda en el proceso de toma de decisiones" (Castro, S. J et al; 2015).

En términos bastante más específicos, un DSS es "un sistema de información basado en un computador interactivo, flexible y adaptable, especialmente desarrollado para apoyar la solución de un problema de gestión no estructurado para mejorar la toma de decisiones. Utiliza datos, proporciona una interfaz amigable y permite la toma de decisiones en el propio análisis de la situación" (Montes de Oca et al; 2010).

2.6 Lógica difusa

Las aplicaciones de la Lógica Difusa son muy variadas, van desde diseñar dispositivos artificiales, hasta el control de complejos procesos industriales, pasando por sistemas de diagnóstico o construcción de artefactos de entretenimiento.

La teoría de lógica difusa fue presentada en 1965 (Zadeh 1965) y sus primeras aplicaciones se realizaron en el área de ingeniería de control a partir de 1974 (Mamdani 1974, Mamdani y col. 1975), con la finalidad de poder introducir la ambigüedad del razonamiento humano y su interacción con sistemas físicos, haciéndola popular con el tiempo debido a su practicidad. Adicionalmente, al permitir el modelaje de sistemas complejos de una forma más simple, ya que posee fundamentos matemáticos precisos pero no complicados.

Se fundamenta en un sistema de inferencia borroso, donde los valores lingüísticos de la premisa y el consecuente están definidos por conjuntos borrosos, es así como las reglas siempre convierten un conjunto borroso en otro (Sivanandam 2007).

El término “difuso” se debe a que los valores que emplean, por lo general tienen cierta incertidumbre o difusidad, que es una propiedad de indeterminismo. Se dice que la Lógica Difusa es un tipo especial de lógica multivariada debido a que permite asignar más valores a los enunciados que la lógica clásica (falso o verdadero).

Se puede definir a la Lógica Difusa o borrosa como la teoría del razonamiento incierto que permite representar y procesar el razonamiento humano expresado por medio del lenguaje natural. Un modelo basado en Lógica Difusa, requiere de una fuente confiable con larga experiencia en el control del sistema a modelar a la cual se le denomina “experto”, que es quien mediante variables lingüísticas (mucho, poco, etc.) definirá el valor de las variables de entrada.

La lógica difusa es una de las disciplinas matemáticas que cuenta con mayor número de seguidores en la actualidad y un número creciente de aplicaciones entre las cuales podemos mencionar: La construcción de artefactos de uso doméstico y entretenimiento, el diseño de dispositivos artificiales de deducción automática, el diseño de sistemas de diagnóstico, y de control de complejos procesos industriales. De esta manera la lógica difusa se constituye en una herramienta con un gran potencial para el desarrollo de nuevos métodos técnicos de inteligencia artificial (Buckley, 1999).

La habilidad de la Lógica Difusa para procesar valores parciales de verdad ha sido de gran ayuda para la ingeniería. En general, se ha aplicado a sistemas expertos, control de sistemas de trenes subterráneos entre otros. (Guadarrama, 2000)

A las variables lingüísticas establecidas, se les asocian valores y la relación existente se cuantifica en grados de pertenencia; esto es, que hay un valor ligado a la posibilidad de que el parámetro medido cumpla con las condiciones que rigen la variable lingüística.

Se puede definir a un conjunto difuso como una colección de elementos bien definida, en la que es posible determinar si un elemento cualquiera para un universo dado, pertenece o no al conjunto, siendo la decisión “si pertenece” o “no pertenece”. Fueron diseñados para representar matemáticamente la incertidumbre y evaluar el rango de referencia en que se encuentra un objeto.

En un conjunto difuso a cada elemento del universo se le asocia un grado de pertenencia a partir de una función que se representa por un número entre 0 y 1, por lo que su dominio es el universo y su contradominio es el intervalo $[0,1]$, mientras más cercano a 1 sea el grado de pertenencia, más estará el elemento dentro del conjunto, por el contrario, mientras más cercano se encuentre de cero, menos estará el elemento en el conjunto.

2.6.1 Funciones de pertenencia

Son funciones las cuales su forma o estructura lógica, sirven para definir el valor de la variable lingüística asociada, es decir, indican en qué grado la variable lingüística pertenece al conjunto difuso. Para la representación de los grados de pertenencia de cada uno de los elementos que conforman al conjunto difuso, lo más viable es extraer los datos de los fenómenos que se va a representar y con ellos definir la forma de la función de pertenencia (Ponce Cruz, 2010). La forma de la función de pertenencia está abierta a cualquier función que modele la pertenencia de los elementos al conjunto que se pretende representar. Existen funciones de pertenencia convencionales y no convencionales las cuales asignan grados de pertenencia $[0,1]$.

Las funciones de pertenencia más comunes son función L, gamma, triangulares, trapezoidales, singleton, gaussiana y sigmoidales. (Álvarez Muñárriz, 1994).

De acuerdo a su forma, las funciones de pertenencia generalmente se asocian con una distribución de probabilidad o de densidad, habiendo diferencias esenciales en la interpretación de cada una; sin embargo, en ocasiones las funciones de pertenencia son obtenidas a través de una función de densidad (Pérez & León, 2007).

2.6.2 Método de Mamdani

Los sistemas de lógica difusa tienen una relación estrecha con conceptos de lógica tales como conjuntos difusos y variables lingüísticas. Los modelos de lógica difusa más populares son Mamdani y Takagi Sugeno.

La entrada de un sistema de lógica difusa tipo Mamdani normalmente es un valor numérico obtenido de un conjunto de datos, por ejemplo de un sensor, en este caso, los datos son recabados por varios bancos de datos obtenidos en laboratorio previamente.

Para que este valor pueda procesarse en el sistema difuso se hace necesario convertirlo a una variable del lenguaje difuso que el mecanismo de inferencia pueda procesar. Estos valores difusos son los niveles de pertenencia de los valores de entrada a los diferentes conjuntos difusos en los cuales se ha dividido el universo de discurso (Delgado y col., 2013). La Figura 2.3 presenta el modelo tipo Mandami.

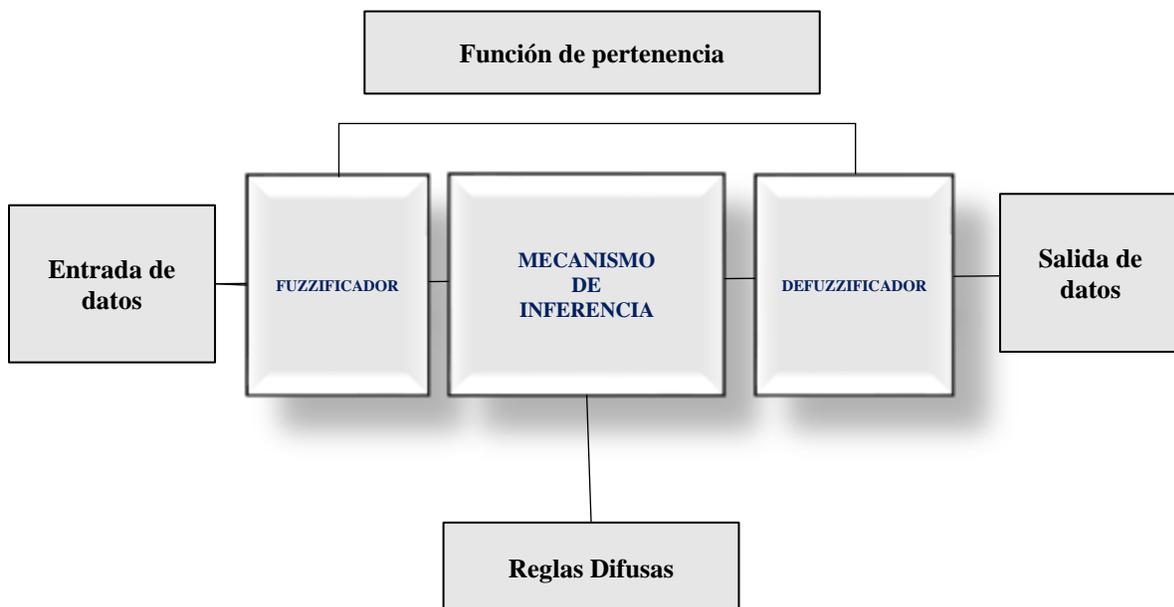


Figura 2.3 Modelo general de un sistema de lógica difusa tipo Mandami

Fuzzificador: Las entradas del sistema Mamdani son típicamente valores numéricos, procedentes de algún tipo de sensor o siendo los resultados de un proceso; para ser capaz de operar este valor, el sistema Mamdani traduce este valor en un valor especial que puede ser operado por mecanismos de inferencia. Esta traducción se realiza por el fuzzificador, que convierte los valores numéricos en valores difusos que representan los diferentes niveles de pertenencia en diferentes variables del sistema a los conjuntos difusos.

Mecanismo de inferencia difusa: una vez que el fuzzificador tiene traducido los valores difusos, éstos tienen que ser procesados para generar una salida difusa, su principal tarea es generar mecanismo de inferencia y tomar los valores difusos para generar una salida difusa basándose en un conjunto de reglas difusas.

Base de reglas difusas: Es la forma en que el modelo Mamdani representa la experticia y lo migra a etiquetas lingüísticas para procesar el conocimiento que utiliza para resolver el problema. Son conjuntos en los que se incluyen frases de SI-ENTONCES, que contiene dos partes cada uno: antecedente y conclusión. En un sistema difuso tipo Mamdani, el antecedente y la conclusión están dados por las expresiones lingüísticas.

Defuzzificador: El sistema de inferencia genera salidas difusas, por lo que no puede ser interpretado por un elemento externo que sólo podían operar los datos numéricos. Para hacer posible operar estos datos, se hace una traducción a formato numérico, y esta tarea es realizada por el defuzzificador, usando uno de los diferentes procedimientos tales como el grado o nivel del centroide o centros promediados.

La lógica difusa se ocupa de las cuestiones relacionadas con una intrínseca imprecisión en lugar de aquellos directamente relacionados con Aparatos para medir los fallos en la exactitud mediciones.

2.7 Redes neuronales artificiales

Las Redes Neuronales son modelos artificiales y simplificados con la capacidad de adquirir conocimiento a través de la experiencia, imitando el comportamiento del cerebro humano. La característica que tienen en común los problemas que no pueden representarse mediante algoritmos es la experiencia. Los seres humanos somos capaces de resolver este tipo de problemas empleando la experiencia acumulada, es por ello que se busca reproducir esta característica en los sistemas para la solución de problemas con el objeto de tener una aproximación de ellos; en este sentido, las Redes Neuronales son modelos artificiales y simplificados con la capacidad de adquirir conocimiento a través de la experiencia, imitando el comportamiento del cerebro humano. (Gestal 2009).

Funcionamiento de las Redes Neuronales Artificiales: parten de un conjunto de procesadores denominados neuronas artificiales los cuales están interconectados de acuerdo a una arquitectura ya definida, de tal forma que la información fluye en paralela hacia varias neuronas, esta característica les permite procesar grandes cantidades de datos y analizarlos de manera simultánea mediante mecanismos computacionales.

En resumen, una Red Neuronal es "Un Nuevo sistema para el tratamiento de la información, cuya unidad básica de procesamiento está inspirada en la célula fundamental del sistema nervioso humano: la neurona" (Mingo 2000).

Una neurona es una célula especializada, estructurada para soportar cambios drásticos de voltaje en su membrana, lo que le permite comunicarse con otras células, su función principal depende de la sinapsis, de la cual recibe la información que procesa y de su interacción con otras neuronas (Figura 2.4).

Cuenta con tres regiones bien definidas:

1. Las dendritas.
2. El cuerpo celular.
3. El axón.

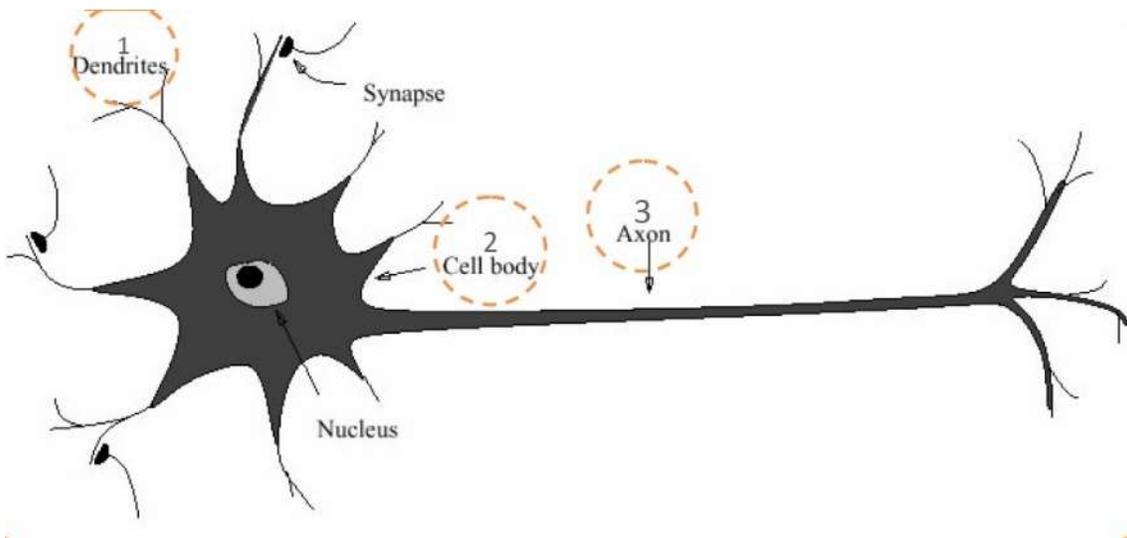


Figura 2.4 Arquitectura de las Redes Neuronales Artificiales.

Parten de un conjunto de procesadores denominados neuronas artificiales los cuales están interconectados de acuerdo a una arquitectura ya definida, de tal forma que la información fluye en paralelo, hacía varias neuronas, esta característica les permite procesar grandes cantidades de datos y analizarlos de manera simultánea mediante mecanismos computacionales.

Son redes interconectadas masivamente en paralelo de elementos simples, y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso (Ver Figuras 2.5 y 2.6).

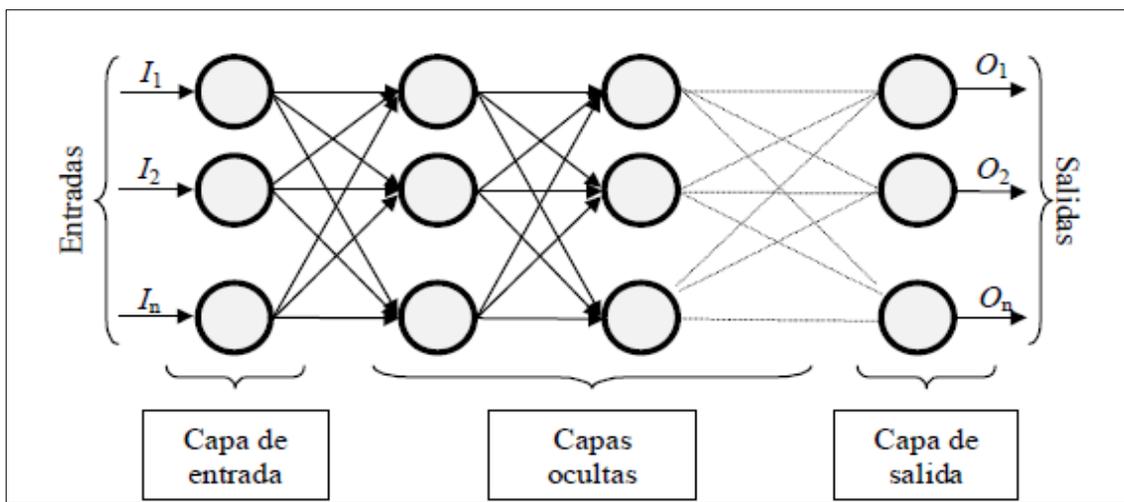


Figura 2.5 Estructura de un sistema neuronal artificial

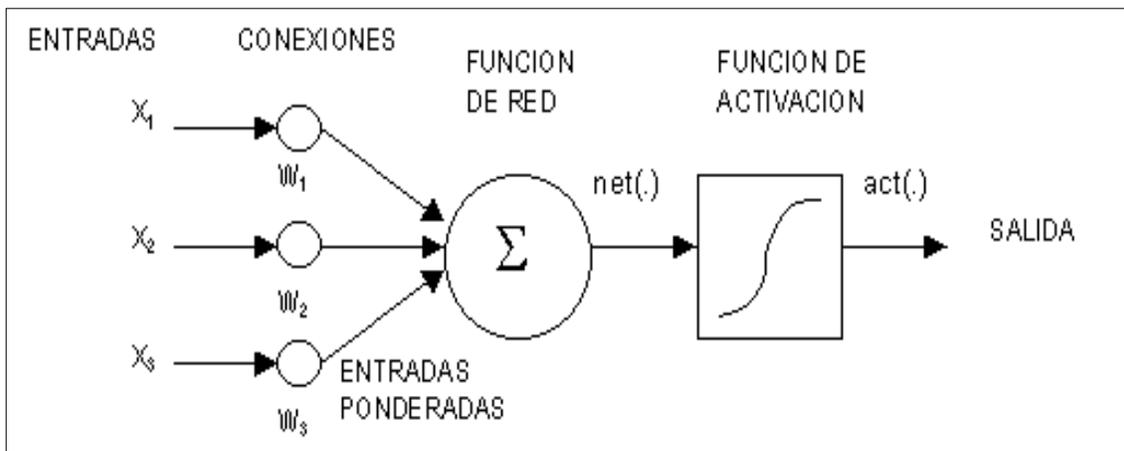


Figura 2.6 Elementos que componen a una red neuronal artificial

La red neuronal artificial está constituida por neuronas interconectadas y arregladas en tres capas (esto último puede variar). Los datos ingresan por medio de la “capa de entrada”, pasan a través de la “capa oculta” y salen por la “capa de salida”. Cabe mencionar que la capa oculta puede estar constituida por varias capas.

Conexiones ponderadas: hacen el papel de las conexiones sinápticas, el peso de la conexión equivale a la fuerza o efectividad de la sinapsis.

Función de propagación o de red: calcula el valor de base o entrada total a la unidad, generalmente como simple suma ponderada de todas las entradas recibidas.

Función de activación: es quizás la característica principal o definitoria de las neuronas, la que mejor define el comportamiento de la misma. Se encarga de calcular el nivel o estado de activación de la neurona en función de la entrada total.

Salida: calcula la salida de la neurona en función de la activación de la misma. El valor de salida cumpliría la función de la tasa de disparo en las neuronas biológicas.

2.7.1 Aprendizaje y Prueba de una red neuronal artificial

El aprendizaje consiste en el ajuste de pesos de interconexión entre las neuronas. Existen diferentes criterios de ajuste:

- Supervisado:
 - Heurístico: perceptrón.
 - Minimizan función de coste (algoritmos tradicionales de adaptación): se minimiza la función de error de evaluación para ajustar los pesos. Un ejemplo es el perceptrón multicapa.
- Mediante refuerzo (con recompensa/castigo):
 - Actor/crítico.
 - Q-learning.
- No supervisado:
 - Hebbiano: Hopfield. Competitivo:

- Mapas topológicos de Kohonen.
- Máquinas de Boltzmann.

El aprendizaje es un algoritmo por el cual se le dan datos a la neurona y ésta aprende a reconocer patrones con ellos. El aprendizaje no supervisado es aquél en el que se tienen un conjunto de patrones pero no están catalogados. El objetivo es que sea la Red la que los clasifique según los criterios que se le suministran (similitudes que deben cumplir los patrones para pertenecer a una clase) y según posibles analogías que pueda encontrar en los datos de entrada. El aprendizaje supervisado es aquél en el que se cuenta con patrones catalogados que sirven de ejemplo a la Red.

2.7.2 El perceptrón multicapa

Este tipo de redes se caracterizan por su facilidad de implementación. Su aprendizaje se basa en la retropropagación: se parte de unos pesos iniciales en las conexiones interneuronales. Para un conjunto de entradas se obtiene una cierta salida. Basándose en que se conoce la salida que deberíamos haber obtenido (patrón catalogado – aprendizaje supervisado), calculamos el error. A partir de este error se modifican los pesos siguiendo el sentido inverso al de evolución de la Red (se parte de la salida hasta llegar a la entrada). De la misma manera se opera con el resto de entradas de entrenamiento. Se puede observar que el error irá disminuyendo a medida que se aplique el algoritmo.

Sin embargo un entrenamiento reiterado con las mismas entradas acaba provocando un sobreentrenamiento a la Red Neuronal, memorizando características de un conjunto, impidiendo así que aprenda a generalizar. Por eso tras cada iteración hay que evaluar: introducir nuevos valores distintos a los de entrenamiento y calcular el error de salida. De esta manera se obtiene una función (error de evaluación) de la que nos interesa hallar su mínimo absoluto (puede haber mínimos locales). Determinando el número de iteraciones con que se alcanza dicho valor, nos aseguramos, en cierta forma, obtener un bajo error para cualquier conjunto de datos de entrada. Después, se puede aplicar un test con un conjunto nuevo de entradas que nos dará una medida de la capacidad de discriminación de la Red.

Perceptrón

Un perceptrón es una estructura neuronal más una regla de aprendizaje. Como se explicaba anteriormente, una neurona se compone de un conjunto de entradas, cada una con un peso, que se introducen en el cuerpo de la misma para su procesamiento. Ese procesamiento puede consistir en:

Ecuación 2.1 Combinación lineal

$$y = \sum_i \omega_i x_i - \theta$$

Ecuación 2.2 Distancia euclídea:

$$y = \sqrt{\sum_i (\omega_i x_i)^2} - \theta$$

Este resultado se introduce posteriormente en un bloque caracterizado por una de las siguientes funciones (Figura 2.7):

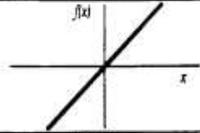
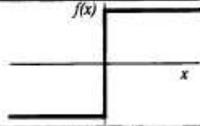
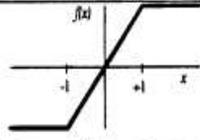
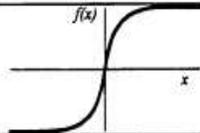
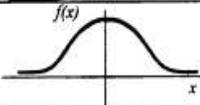
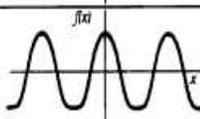
	Función	Rango	Gráfica
Identidad	$y = x$	$[-\infty, +\infty]$	
Escalón	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
Lineal a tramos	$y = \begin{cases} -1, & \text{si } x < -l \\ x, & \text{si } -l \leq x \leq +l \\ +1, & \text{si } x > +l \end{cases}$	$[-1, +1]$	
Sigmoidea	$y = \frac{1}{1 + e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
Gaussiana	$y = Ae^{-Bx^2}$	$[0, +1]$	
Sinusoidal	$y = A \text{sen}(ax + \varphi)$	$[-1, +1]$	

Figura 2.7 Funciones de salida del perceptrón.

La función que representa el comportamiento ideal de una neurona es la función escalón: dependiendo de la entrada se activa la conexión entre neuronas (salida = 1) o no (salida = 0). Esta decisión puede depender de un cierto umbral (que la salida sea capaz de superarlo), representado en las expresiones anteriores porque introducir este término negativo equivale a considerar que la función vale uno a partir de q y no a partir de cero como se representa en la tabla.

Aunque éste sea el comportamiento ideal, en la práctica se suele utilizar la función sigmoidea. Esto se debe a que es una función muy parecida al escalón y derivable en el entorno de cualquier punto del eje x . Como se verá, esto es necesario en el algoritmo de retropropagación ya que está basado en la minimización del error con respecto al valor de los pesos, por lo que hay que derivar e igualar a cero.

El algoritmo de aprendizaje para un perceptrón aislado es el siguiente:

Ecuación 2.3 Algoritmo de aprendizaje.

$$W_{k+1} = W_k - \eta \cdot X^t (y^d - y)$$

donde:

W = vector de pesos.

k = iteración actual.

h = factor de aprendizaje.

X = vector de entradas.

y^d = salida deseada.

y = salida obtenida en la iteración k .

Una propiedad muy importante de este algoritmo es la convergencia en presencia de solución y la posibilidad de implementar ciclos límite en ausencia de la misma.

El factor de aprendizaje h determina la rapidez del algoritmo pero también su exactitud. Cuanto mayor sea, necesitaremos menos iteraciones (antes alcanzaremos las cercanías del mínimo error de evaluación) pero el aprendizaje es muy grosero (es más probable que nos quedemos oscilando en las cercanías del mínimo error de evaluación que lo alcancemos realmente). Cuanto menor sea, más lento es pero más fino en el aprendizaje. Por lo tanto hay que llegar a un compromiso.

2.8 Algoritmos genéticos

Los algoritmos genéticos (AG) son métodos de búsqueda basados en los mecanismos de la selección natural (en donde sobrevive el más apto) y los principios de la genética. Los algoritmos genéticos fueron desarrollados tratando de imitar algunos procesos observados en la selección natural de Darwin (Cerroloza & Annicchiarico, 1996).

John Holland (1975) propuso los algoritmos genéticos como programas de computadora, los cuales imitan el proceso evolutivo natural y que se comportan en forma robusta ante un entorno variable e incierto.

El tema principal de la investigación de Holland, se centra en la robustez de dichos sistemas, es decir, en encontrar el equilibrio necesario entre la eficiencia y la eficacia para adecuarse a diferentes entornos.

La resolución de un determinado problema, sea este complejo, puede percibirse como la búsqueda de un espacio de posibles soluciones factibles, y dado que se busca la mejor solución, se dice que el problema es de optimización (Maroto Álvarez, et al., 2002). Los algoritmos genéticos parten de la premisa de emplear la evolución natural como un procedimiento de optimización que se caracteriza por tener operaciones básicas que son: selección, cruzamiento y mutación. Para evaluar las operaciones básicas es necesario que la información a optimizar se encuentre en cadenas de bits (0,1), y que esta representación sea una cadena finita siendo

cada cadena un individuo que conforma un población. La representación más empleada es en la que los individuos forman una población inicial A y B los cuales se encuentran binarizados. A partir de estos individuos iniciales A y B, se generan nuevos individuos a y b, llamados descendientes (Ver Figura 2.8).

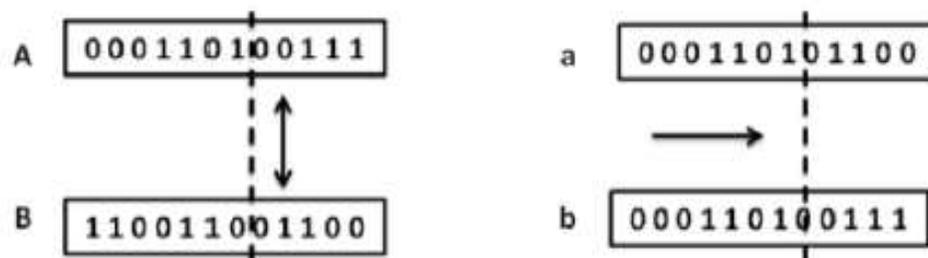


Figura 2.8 Población inicial de AG.

Los algoritmos genéticos siguen el procedimiento que ha seguido la naturaleza, es decir, trabajan sobre una población de individuos, de los cuales, cada uno representa una posible solución al problema. A cada individuo le es asignado un valor de adecuación, el cual representa la calidad de la solución. Los individuos de la población son cruzados entre sí para producir nuevas soluciones, en donde los individuos con un mejor valor de adecuación son los potencialmente aptos para ser cruzados, formando nuevos individuos o soluciones (Lahoz Beltrá, 2004).

2.8.1 Nomenclatura empleada en algoritmos genéticos

Las expresiones utilizadas en genética y en su estructura equivalente en algoritmos genéticos se muestran a continuación (Tabla 2.5).

Tabla 2.5 Nomenclatura de un algoritmo genético.

Evolución natural	Algoritmo genético
Genotipo	Código de cadena
Fenotipo	Punto sin codificar
Cromosoma	Cadena
Gen	Posición de cadena

Alelo	Valor en una posición determinada
Función de aptitud	Valor de la función objetivo

Genotipo: Expresión genética de un organismo o estructura genética del organismo. Es la información contenida en el genoma.

Fenotipo: Características físicas de un organismo, atribuibles a la expresión de su fenotipo. Contiene tanto los rasgos físicos como los conductuales. Es el resultado de la interacción entre el genotipo y el ambiente; se interpreta como la suma de los caracteres observables en un individuo. Es la manifestación externa del genotipo.

Cromosoma: Es la molécula única del ADN unida a proteínas básicas y otras proteínas la cual se condensa durante la mitosis y la meiosis formando una estructura compacta.

Gen: Especifica la herencia de un carácter; está formado por una secuencia de aminoácidos de una o más cadenas de ARN (ácido ribonucleico), que realizan diferentes funciones en la cadena.

Alelo: Es el valor de un gen. Una de las dos o más formas alternativas de un gen; determina el carácter controlado por el gen.

Función de aptitud: Es un tipo especial de la función que cuantifica la optimalidad de una solución. Se traduce en un cromosoma óptimo para que sus bases sean combinadas con cualquier otra técnica para la producción de una nueva generación que sea mejor a las anteriores.

2.8.2 Metodología de un Algoritmo Genético

Para las estructuras básicas de un algoritmo genético también es necesario conocer la transacción de una generación a otra, la cual consta de seis elementos.

Generación de la población inicial: En esta etapa se genera una población inicial de soluciones, en donde se define el tamaño de la población, número de generaciones, la tasa de crecimiento y la tasa de mutación.

Evaluación de la población: Una vez teniendo la población inicial, los individuos de la población son evaluados, es decir, se les asigna un valor de adecuación. La función de evaluación es aquella que asigna a cada uno de los individuos de la población el valor de adecuación, que indica la idoneidad de ese individuo con respecto al resto de individuos que forman la parte de la población.

Selección de la población: En esta fase, cada individuo de la población es copiado un número determinado de veces, en donde los mejores individuos tendrán el mayor número de copias con respecto a los individuos menos cualificados. De este modo se tendrá una nueva población la cual reemplazara a la anterior.

La selección en los algoritmos genéticos es una versión artificial de la selección natural de las especies, la cual se basa en la supervivencia de los mejores.

Cruzar la población: Los individuos de la población son emparejados de forma aleatoria, y cada una de las parejas se procederá al cruce con una determinada tasa de cruce fijada al inicio. Si el cruce se lleva por medio de los progenitores, se crearán nuevas soluciones denominadas descendientes, los cuales reemplazaran a las generaciones anteriores, de lo contrario los progenitores quedarán inalterados.

En el proceso de cruzamiento los mejores individuos tienen una mayor actividad en el proceso. En el proceso de cruzamiento simple, se cortan las cadenas en una posición elegida al azar e intercambiándolas en sus extremos. Este proceso, se llama cruzamiento de único punto (Figura 2.9).

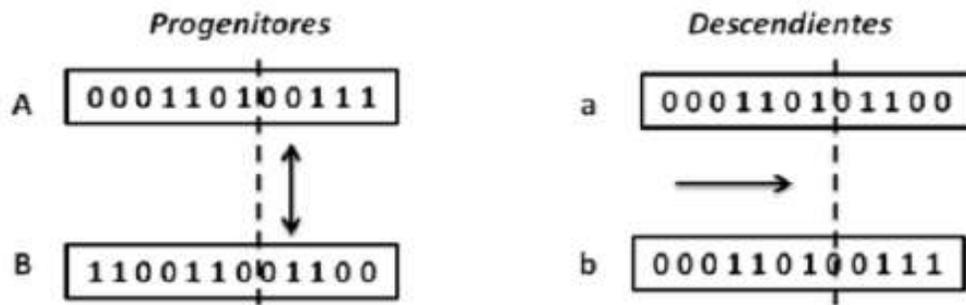


Figura 2.9 Cruzamiento de único punto

Mutación: Ésta se realiza con gran probabilidad, como una deformación aleatoria de las cadenas. Produce cambios incrementales al azar en la descendencia, efectuando cambios aleatorios en los valores de algunos genes. En el caso de cromosomas binarios, le corresponde hacer los cambios de posiciones en cada bit. No afecta a toda la población pero es probable que dañe a algunos.

La mutación tiene el efecto de perturbar de manera segura a los cromosomas a fin de introducir nuevas características que no estaban presentes en ningún elemento de los progenitores.

Reemplazo: Es el procedimiento para calcular o crear una nueva generación de la anterior y sus descendientes. Se crea un espacio a la descendencia en la población eliminando de ella a los padres (Figura 2.10).

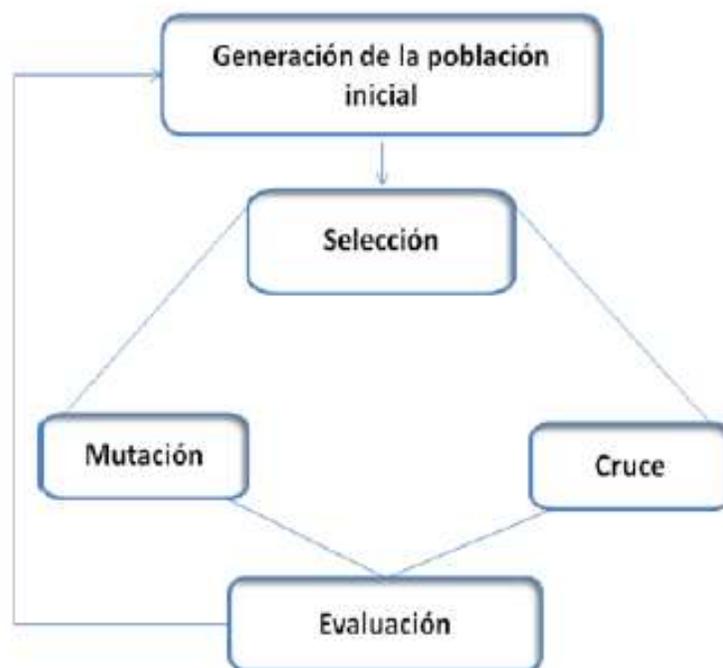


Figura 2.10 Proceso de algoritmo genético

2.9 Conclusión de Capítulo

En el capítulo II se abordaron los fundamentos teóricos de la investigación realizada, incluyendo la definición de bioenergía, el proceso de digestión anaerobia con una breve explicación de los diferentes pre-tratamientos para acelerar el proceso de hidrólisis y las variables que impactan el proceso, con la intención de proporcionar al lector una visión más amplia de los parámetros de control que intervienen en el proceso, por último se incluyó una descripción de las técnicas de inteligencia artificial empleadas, entre ellas, lógica difusa, redes neuronales artificiales y algoritmos genéticos.

Capítulo III

Estado de Arte

Capítulo III Estado del Arte.

3.1 Introducción

El proceso de digestión anaerobia es una importante alternativa para el tratamiento de aguas residuales, se refiere a un proceso complejo llevado a cabo por la descomposición de la materia. En el presente capítulo se presenta un breve estado de arte de las principales investigaciones realizadas en torno a la optimización del proceso de digestión anaerobia, centrándose en el uso de técnicas de inteligencia artificial para su optimización. Se presenta una reseña de las principales investigaciones realizadas sobre sistemas expertos de apoyo a la decisión y las técnicas de inteligencia artificial relacionadas con el desarrollo de este trabajo de investigación presentándose algunos estudios que se han llevado a cabo y se han aplicado en diversos aspectos de la digestión anaerobia mesofílica.

3.2 Optimización del proceso de digestión anaerobia

En el siguiente apartado se exponen estudios previos que han aplicado técnicas de inteligencia artificial en diferentes aportaciones a la digestión anaerobia, donde se emplean diversas herramientas para facilitar la toma de decisiones y resolución de problemas, en las investigaciones mencionadas, se incursiona en la optimización del proceso de digestión anaerobia, pero dejan de lado la inclusión de pre-tratamientos para la aceleración del proceso de digestión anaerobia. A continuación se presenta una reseña de algunas investigaciones que aplican técnicas de inteligencia artificial, tales como, lógica difusa y redes neuronales artificiales, en la optimización de procesos de producción de biogás, específicamente en el proceso de digestión anaerobia.

En los últimos años se ha incrementado el interés de las empresas por el tratamiento de sus residuos, debido a ello, diversos investigadores se han dedicado a estudiar diversas alternativas en el tratamiento de los residuos agroindustriales, el proceso de digestión anaerobia es una de las opciones que han sido implementadas con mucho éxito, ya que representa una fuente de

energía alterna, algunos estudios del proceso de digestión anaerobia se centran en el análisis del proceso y las variables de control que intervienen en él, (Appels, et al., 2008) examinan ampliamente los principios de la digestión anaerobia, los parámetros del proceso y su interacción.

3.3 Control del reactor IA vs PDAM

Existen estudios que implementan técnicas de inteligencia artificial en el PDAM que se enfocan al control, diseño y operación de bio-reactores, en el año 2010, Waewsak y colaboradores presentan un sistema de control desarrollado para el reactor anaeróbico híbrido (AHR), para ello desarrollaron una red neuronal artificial y un modelo de lógica difusa, considerando las variables pH, ácidos volátiles totales (ATV) y alcalinidad (ALK) en el efluente del reactor anaerobio, el resultado del trabajo presenta un incremento en la producción de biogás, un aumento en la eficiencia de eliminación de DQO y una adecuada estabilización del proceso (Waewsak et al.2010).

Steyer, et al., (1999), utilizaron lógica difusa para desarrollar una estrategia de control en el proceso de digestión anaerobia. Para desarrollar el sistema de control, primero se trató de mantener una alta tasa de carga de materia orgánica para evaluar el comportamiento del proceso bajo condiciones extremas. Para poder mantener dicha tasa, los autores alteraron la velocidad del flujo de entrada del reactor, con ello se indujo a una sobrecarga del reactor. A través de la lógica difusa, se determinaron las variables que tienen mayor impacto en el sistema de estrategia de control, se determinó que las más relevantes en el estudio fueron: potencial de hidrógeno (pH) y tasa de carga del reactor. Una vez obtenido el sistema de control este fue validado, concluyendo que el sistema de control es capaz de controlar automáticamente un proceso de digestión anaerobia para evitar sobrecargas; además, es capaz de adaptar los parámetros de control cuando se presenten cambios de fuerza en la concentración del efluente para poder llegar a la máxima capacidad del proceso (Steyer, et al., 1999).

3.4 Control del proceso IA vs DAM

Ruge Ruge & Hernández Sarabia (2011), realizaron estudios utilizando desechos orgánicos de un restaurante, con el fin de evaluar el efecto de la temperatura en la calidad del biogás obtenido y la concentración volumétrica de metano (CH_4) y dióxido de carbono (CO_2). Una vez obtenida la muestra, ésta sirvió como sustrato del reactor, donde se inoculó durante 40 días; posteriormente, para el control de la temperatura, se desarrolló un sistema de lógica difusa como controlador de los niveles de temperatura, se tomó como base la relación no lineal de la temperatura con la actividad microbiana dentro del proceso, en donde se enfocó a determinar la relación entre variable manipulada (CV) y la variable del proceso (PV), sin embargo; no se incorporó información de los fenómenos fisicoquímicos dentro del reactor, por lo que no se obtuvo ningún modelo matemático del proceso. El sistema de control difuso permitió mantener la operación en fase mesofílica (25° a 45°C), utilizando 35°C como punto de operación inicial, en donde se utilizó un sensor de gas para monitorear la concentración volumétrica de metano y dióxido de carbono. A través del sensor se asignaron valores a variables lingüísticas como Error (diferencia aritmética entre la señal de referencia y la señal de salida de temperatura) y Control (suministro de voltaje del reactor) (Ruge Ruge & Hernández Sarabia, 2011).

En el año 1998 Wen y Vassiliadis proponen un sistema de control automático (sistema experto) para la operación del proceso de una planta tratamiento de aguas residuales (EDAR) por digestión aerobia, mediante la aplicación de la inteligencia artificial (AI), por medio de un sistema experto se generó un valor objetivo para la demanda bioquímica de oxígeno (DBO), y se utilizó dicho valor para el entrenamiento de una red neuronal que generó una tasa de reciclaje de lodo. Se llevó a cabo una simulación del proceso por medio del sistema experto y datos reales, se concluyó que el sistema experto que integra redes neuronales es una herramienta eficaz para el control del proceso de una planta de tratamiento de aguas residuales (Wen y Vassiliadis, 1998).

Belmonte Izquierdo, et al., (2009), desarrollaron una estrategia de control compuesta por un observador neuronal y un supervisor difuso. El observador se basa en una red neuronal recurrente de alto orden cuyo objetivo es estimar variables difíciles de medir: biomasa y sustrato, en un reactor completamente agitado. Los autores emplearon la lógica difusa para

desarrollar un supervisor difuso, el cual permite la combinación de variables como: ODL, la cual es la cantidad de carga orgánica que una unidad de biomasa puede tratar en un día, y ΔQCH_4 , la cual se refiere a la diferencia entre producción de metano y la producción de metano a punto del equilibrio dada en mol/h. El modelo se validó mediante pruebas de tolerancia del observador (red neuronal) ante cambios en los parámetros del sistema (tasas de crecimiento de biomasa) (Belmonte Izquierdo, et al., 2009).

3.5 Digestión anaerobia con Lógica Difusa y Redes neuronales

Du, et al., (1999) desarrollaron un sistema inteligente a nivel de sistema experto que utiliza modelos neuronales y de lógica difusa para abordar los problemas de funcionamiento de los procesos de los lodos, en relación a la predicción y la comprensión heurística de la edad de los lodos. Técnicas de redes neuronales y lógica difusa se utilizan en el desarrollo del modelo. Estudios de simulación muestran que este modelo de red neuronal difusa obtenido es capaz de extraer reglas difusas a partir de un conjunto de datos numéricos que se puede utilizar para llevar a cabo el razonamiento heurístico.

Los sistemas de lógica difusa han sido aplicados en muchos bioprocesos y procesos de ingeniería química (Huang et al., 2009; Maldi et al., 2008; Karakuzu et al., 2006; Traore et al., 2005; Sousa y Almeida, 2001). En general, es una técnica que ha avanzado en el control del sistema de digestión anaerobia (Perendeci et al., 2008; Carlos et al., 2007; Punal et al., 2003).

Polit en el 2002, utilizan la lógica difusa para determinar un coeficiente de impacto de las variables pH y temperatura, el resultado de modelo difuso se introduce a un modelo matemático para calcular el balance de masas, los parámetros de pH y temperatura no se encuentran calculados explícitamente en el modelo matemático, por lo que se multiplica el coeficiente de pH y temperatura obtenidos por el modelo difuso con la tasa de crecimiento estimado para la biomasa, los resultados obtenidos se comparan con datos experimentales del proceso (M. Polit et al, 2002).

En otra investigación Ting Yang et al., (2013) se enfocan en la predicción de la demanda química de oxígeno. El objetivo de este trabajo fue proponer un enfoque de modelado difuso

para procesar lodos activados y aplicarlo para predecir la presencia de demanda de oxígeno (DQO) del proceso, para ello definen un grupo de variables que intervienen en las diferentes metodologías para el tratamiento de lodos activados, tales como: caudal, materia orgánica soluble, sustrato fácilmente biodegradable, materia orgánica inerte particulada, sustrato lentamente biodegradable, biomasa heterotrófica activa, biomasa autótrofa activa, partículas, oxígeno disuelto, nitrato y nitrito nitrógeno, entre otras. El modelo puede eliminar eficientemente los complejos términos no lineales existentes en las variables de operación (Ting Yang et al., 2013).

Algunos otros investigadores han utilizado herramientas como lógica difusa para hacer predicciones a gran escala como Ilter, et al., (2010) que realizaron un modelo basado en lógica difusa desarrollado para predecir las tasas de producción de metano y biogás en una planta piloto a escala de 90 litros, se consideraron 5 variables de entrada, como la tasa de carga orgánica volumétrica (OLR), la tasa volumétrica total de eliminación de demanda química de oxígeno (TCOD), alcalinidad del influente, pH del afluente y pH del efluente, los resultados pronosticados por lógica difusa se compararon con los resultados de dos pruebas de modelos exponenciales de regresión no lineal, el modelo de lógica difusa mostró predicciones precisas y efectivas con coeficientes de correlación satisfactorios por encima de 0.96. El reactor UASB a escala piloto mostró un rendimiento notable sobre el tratamiento de las aguas residuales de melaza bajo diversas condiciones de carga orgánica e hidráulica (Ilter, et al., 2010).

Existen algunos trabajos que apuntan a la optimización de procesos, y utilizan algunas técnicas de inteligencia artificial para lograrlo, los algoritmos genéticos representan una práctica muy empleada para la optimización de uno o múltiples criterios, tal es el caso de Guegim et al., (2012), trabajó en un modelo para optimizar la producción de biogás mediante el uso de redes neuronales y algoritmos genéticos. Para este trabajo usaron un sustrato compuesto de aserrín, estiércol de vaca, cáscara de plátano, salvado de arroz y papel, los resultados obtenidos de los 25 reactores monitoreados fueron considerados para estimar los parámetros de cada sustrato por medio de redes neuronales artificiales, posteriormente se desarrolló un modelo de optimización para la producción de biogás, a partir de los sustratos considerados como variables de entrada, como resultado se observó un incremento en la producción de biogás obtenido de los sustratos que presentaron mayor eficacia en el proceso (Guegim et al., 2012).

Las redes neuronales artificiales y los algoritmo genéticos han sido utilizados con éxito en la optimización de cierto procesos, (Jacob et al., 2016) aporta una investigación sobre el manejo de bacterias específicamente aisladas en un consorcio Anaeróbico mixto, dicho bisolido es usado como inóculo para la generación de biometano, de los datos experimentales obtenidos se generó una red neuronal artificial que permite obtener resultados que son considerados posteriormente en un algoritmo genético desarrollado por medio de Matlab, teniendo como variables de entrada la concentración de sustrato, la proporción de co-sustrato y la concentración de inóculo, el resultado obtenido del AG (algoritmo genético) se comparó con el rendimiento obtenido por la ANN (red neuronal artificial), demostrando un incremento del 8,64% cuando la ANN-GA se aplicó para la optimización durante la co-digestión anaerobia.

Las herramientas de inteligencia artificial también facilitan el desarrollo de sistemas de simulación, en el 2006, Traoré y un grupo de investigadores desarrollan un sistema de Simulación Benchmark (modelo y datos) y lo utilizan para desarrollar un controlador borroso de la altura de los lodos en el decantador secundario. La estrategia de control presentada se basa en simples datos lineales (flujo, eliminación y reciclaje de flujos) y a los valores analíticos diarias del índice de volumen de lodos (SVI), permitiendo el algoritmo fuzzy para reducir las variaciones de altura de lodo y por lo tanto para aumentar la eficiencia de los procesos de sedimentación (Traoré et al., 2006).

Hernandez, et al., (2009) Proponen un conjunto de modelos de lógica difusa utilizados para observar el proceso de digestión anaerobia para estimar las variables difíciles de medir en un reactor de tanque agitado por completo. En primer lugar, se declaró un modelo matemático para el proceso y se validó experimentalmente (Hernandez et al., 2009).

Por otro lado, es importante mencionar el uso de las herramientas de inteligencia artificial en la transferencia de tecnología utilizando lógica difusa multicriterio (Chang & Cheng, 2003), este método de selección logra puntuaciones finales denominados índices de adecuación difusa. En el trabajo se utilizan las variables lingüísticas para números difusos para asignar valores subjetivos, es decir información de los expertos, asignando diferentes ponderaciones a diferentes alternativas estratégicas para transferencia de biotecnología en las empresas.

Gueguim Kana, et al., (2012), realizaron un modelo para la optimización de la producción de biogás en sustratos mixtos de residuos mediante la utilización de redes neuronales y algoritmos

genéticos. El modelo fue realizado con el objetivo de impulsar nuevas alternativas de fuentes de energía renovable. Primeramente, se entrenó y validó la red neuronal con los datos obtenidos de las fermentaciones de veinticinco plantas piloto de menor escala. Una vez entrenada la red neuronal, se procedió a la optimización del algoritmo genético. Los resultados obtenidos por el modelo arrojaron un 8.64% más de producción de biogás que la prevista originalmente por los autores, además con la optimización se redujo el tiempo de producción de biogás, ya que sin la optimización la producción de biogás se daba a partir del octavo día, mientras que con la optimización ésta se presentó en el tercer día (Gueguim Kana, et al., 2012).

Strik, et al., (2005), desarrollaron un modelo en redes neuronales artificiales mediante Matlab, para predecir y optimizar la concentración de ácido sulfhídrico (H₂S) y amoníaco (NH₃) presentes en el proceso de la obtención de biogás, los cuales son compuestos tóxicos resultantes del proceso de digestión anaerobia. El modelo permite detectar cuando las concentraciones de ácido sulfhídrico y de amoníaco sobrepasan los límites permisibles, por lo que éste permite prever, controlar, reducir o incluso evitar la producción de dichos compuestos (Strik, et al., 2005).

Carrasco, et al., (2004), mediante la utilización de lógica difusa desarrollaron un sistema experto para determinar los estados de acidificación del proceso de digestión anaerobio. Cuando se presenta la acidificación trae como respuesta fluctuaciones en la carga de alimentación del reactor, originando variaciones o fallos de un reactor, además, la acidificación inhibe la metanogénesis (etapa de la digestión anaerobia en donde se da la formación del metano). Los autores, primero realizaron un sistema de diagnóstico utilizando el conocimiento de expertos del proceso, posteriormente identificaron las variables (pH) colocando etiquetas lingüística, el conocimiento del experto se implementó por medio de la estructuración de reglas difusas (Carrasco, et al., 2004).

Chegini, (2008) Desarrolla un sistema de predicción a partir de redes neuronales artificiales, para controlar los parámetros del proceso de producción y parámetros de calidad del secado por aspersion del jugo de naranja, se estudian los efectos del caudal de alimentación, la temperatura de entrada de aire de secado, la velocidad del atomizador, la pulverización del secado por aspersion de zumo de naranja semi-industrial, y analiza siete índices de rendimiento que son el contenido de humedad residual de polvo de zumo de naranja, el tamaño de

partículas, densidad aparente, tiempo medio de la capacidad de mojado, sólidos insolubles, temperatura de salida de aire y el rendimiento de secador (Chegini et al., 2008).

El modelo final de la Red Neuronal Artificial (RNA ó ANN por sus siglas en ingles) de propagación hacia atrás predice siete parámetros de salida a partir de tres variables de entrada.

La tecnología ANN había demostrado ser una herramienta útil para investigar, para aproximarse y predecir las propiedades físicas del polvo de zumo de naranja, así como los parámetros del proceso de secadores de pulverización.

Sablani & Rahman, (2003) Elaboran un modelo de red neuronal artificial para predecir la conductividad térmica de los alimentos como una función en el contenido de humedad, temperatura y porosidad aparente, entre los productos evaluados fueron manzanas, peras, almidón de maíz, uvas pasas, patatas, sacarosa, zanahorias y arroz (Sablani & Rahman, 2003).

El modelo fue capaz de predecir la conductividad térmica en 0.012–2.350 W/mK con un error realativo absoluto 12.6% y un error medio absoluto de 0.081W/mK, el contenido de humedad en 0.04 a 0.98 en fracción de base húmeda, temperatura en -42 a 130 °C y porosidad aparente en 0.0 a 0.70. El coeficiente de correlación de la red neuronal artificial entrenada fue de 0.957. Concluye que el modelo de red neuronal artificial fue óptimo para predecir la conductividad térmica basada a diferentes condiciones de contenido de humedad, temperatura y porosidad aparente.

3.6 Grupos bacterianos que intervienen en el proceso de digestión anaerobia

Dentro del metabolismo de la digestión anaerobia existen grupos de bacterias sintróficas cuya principal característica es la unión de varias especies para realizar una reacción química. Existen 4 categorías de bacterias que participan en los pasos de conversión de la materia hasta moléculas sencillas como metano o dióxido de carbono y que van cooperando de forma sinérgica, estas son:

Grupo 1: Bacterias hidrolíticas

Son un conjunto de bacterias cuya finalidad es romper los enlaces complejos de proteínas, celulosa, lignina o lípidos en monómeros o moléculas como aminoácidos, glucosa, ácidos grasos y glicerol, los cuales pasan al siguiente grupo de bacterias. En este proceso participan principalmente *Clostridium* y *Bacteroides* (Gallegos, 2010).

Grupo 2: Bacterias fermentativas acidogénicas

Las cuales se encargan de convertir azúcares, aminoácidos y lípidos en ácidos orgánicos, alcoholes y cetonas, acetato, CO₂ y H₂, siendo *Clostridium* el microorganismo que se encuentra principalmente realizando este proceso, aunque *Lactobacillus* y *Bacillus*, también lo hacen (Gallegos, 2010).

Grupo 3: Bacterias acetogénicas

Estas solo se desarrollan como productoras de H₂ junto a otras bacterias consumidoras de este. *Syntrophobacter wolinii*, especializada en la oxidación de propionato, y *Syntrophomonas wolfei*, que oxida ácidos grasos de 4 a 8 átomos de carbono, convierten el propiónico, butírico y algunos alcoholes en acetato, hidrógeno y dióxido de carbono, el cual se utiliza en la metanogénesis (Gallegos, 2010).

Grupo 4: Bacterias metanogénicas

Son aquellas bacterias capaces de generar gas metano como última fase de la digestión anaerobia descrita anteriormente (Gallegos, 2010; Nelsón, 2005).

A continuación se establecen otros procesos metabólicos en los que participan las bacterias.

La digestión anaerobia de la materia orgánica en la naturaleza, libera del orden de 500-800 millones de toneladas de metano por año a la atmósfera. Esto se produce en la profundidad de sedimentos o en el rumen de los herbívoros.

Existen tanto bacterias Gram positivas como negativas. Estos microorganismos crecen muy despacio, con tiempo de generación que van desde los 3 días a 35°C hasta los 50 días a 10°C (Girovich, M. J., 1996).

Para poder determinar las variables que se relacionan con el comportamiento de las bacterias que intervienen en el proceso se llevó a cabo un análisis e investigación en diversos artículos de microbiología y digestión anaerobia que reportaron parámetros de pH, temperatura, alcalinidad y principales inhibidores de proceso.

En las Tablas 3.1 y 3.2, se pueden observar los rangos óptimos de los parámetros de operación de pH y temperatura que se consideran propicios para la supervivencia de los principales grupos de bacterias que intervienen en el proceso de Digestión Anaerobia.

Tabla. 3.1. Parámetros de control de los grupos de Bacterias hidrolíticas y acidogénicas.

Grupos de Bacterias Anaerobias	Bacteria	pH	Temperatura °C	Referencia
Hidrolíticas	Clostridium,	(5.5 -8)	37	(He Q.y col. 2011)
	Proteus,	(7-7.5)	37-40	(Arabski, M y col. 2016)
	Bacteroides,	(7-7.5)	37-40	(Arabski, M y col. 2016)
	Bacillus	(7-7.4)	37	(Siwińska, M., y col 2015)
	Vibrio	(7-8)	37	(Jawetz, E., y col.1985)
	Acetovibrio	(5.5 -8)	37	(Prats, G. y col., 2013)
	Staphylococcus	(>5)	27-30	(Sperling, M. V,1996)
Acidogénicas	Clostridium,	(5.5 -8)	37	(He Q.y col. 2011)
	Lactobacillus,	(6.5-7.5)	35	(Rivas, C., & Mota, M. 2002)
	Escherichia,	(5.5-8)	30-40	(Rivas, C., & Mota, M. 2002)
	Bacillus,	(6.5-7.5)	35	(Rivas, C., & Mota, M. 2002)
	Pseudomonas,	(5.5-8)	30-40	(Solano, O. R.,2011)
	Desulfovibrio,	(6.5-7.5)	35	(Volbeda, A y col., 1995)
	Sarcina	(5.5-8)	30-40	(Nicolet, Y., y col, 1999)

Tabla 3.2 Parámetros de control de los grupos de Bacterias acetogénicas y Metanogénicas.

Grupos de Bacterias Anaerobias	Bacteria	pH	Temperatura °C	Referencia
Acetogénicas	Sintróficas	(6.5-7.5)	35	(Moreno Mingorance, A., 2014).
	Syntrophobacter wolinii	(5.5-8)	30-40	(ÉCNICO, A.,2005).
	Syntrophomonas wolfei	(6.5-7.5)	35	(Beaty, P. S., 1987)
	Syntrophospora bryantii	(5-8)	30-40	(Beaty, P. S., & McInerney, M. J. 1989)
	Syntrophus buswellii	(5.5-8)	30-37	(Fang, H. H., 1996)
Metanógenas	Methanobacterium	(6-8)	30-40	(Smith, D. R., 1997)
	Methanococcus	(6.8-7.5)	30-35	(Zeikus, J. G., & Wolee, R. S., 1972)
	Methanospirillum	(6.5-7.5)	30-35	(Xu, W y col., 1999)
	Methanobrevibacter	(6.5-8)	25-40	(Samuel, B. S y col., 2007)
	Methanomicrobium	(6.5-8)	25-40	(Yanagita, K., y col. 2000)

3.7 Conclusión del Capítulo.

En el presente capítulo se realizó una búsqueda del estado del arte relacionado a temas de bioenergía, el proceso de digestión anaerobia y la optimización del proceso en relación al control del reactor, existen algunos trabajos que han incorporado el uso de modelos de lógica difusa para control del reactor o manejo del proceso, en otros trabajos se reporta el manejo de redes neuronales artificiales para control y como apoyo al análisis del comportamiento de algunas variables que intervienen en el proceso. Son escasos los trabajos que han combinado más de una técnica de inteligencia artificial, con el objetivo de determinar parámetros de operación para incrementar y optimizar el proceso y los rendimientos de biogás y metano obtenidos, tampoco se ha observado que incluyan el análisis del impacto de los microorganismos que forman parte de cada una de las fases del proceso de digestión anaerobia, la mayoría de los trabajos se central en el control del reactor y el control de la operación, dejando una importante brecha en el área de predicción y optimización de los rendimientos.

Capítulo IV

Materiales y Métodos

Capítulo IV. Materiales y Métodos

4.1 Introducción

En el Capítulo cuatro se expone la investigación llevado a cabo para el desarrollo del sistema experto de apoyo a la decisión y las diferentes técnicas que fueron abordadas para integrar el sistema, partiendo de los procedimientos desarrollados a nivel laboratorio para la integración de la base de datos experimentales que alimentaron las técnicas de inteligencia artificial en la etapa 1 de la metodología, en la segunda etapa se explica el desarrollo de los modelos de lógica difusa y el entrenamiento de las redes neuronales creadas para estimar los patrones de comportamiento de las variables de operación que intervienen en el PDAM. Posteriormente en la etapa tres se presenta el análisis de superficies de respuesta realizado para la construcción de modelos matemáticos que fueron optimizados por algoritmos genéticos en la etapa cuatro, por último en la etapa cinco, se presenta el desarrollo del sistema.

4.2 Metodología

La metodología llevada a cabo se describe en cuatro principales etapas, la primera etapa corresponde a la “Producción de datos experimentales”, para ello, fue necesario hacer una recopilación de los datos experimentales de un reactor anaerobio, en esta fase se hizo un estudio y análisis de las bases de datos de investigaciones previas desarrolladas en el Laboratorio de Ambiental del Instituto Tecnológico de Orizaba.

Se desarrollaron diversas pruebas de laboratorio para ampliar las bases de datos existentes, considerando los pre-tratamientos a los sustratos, pre-hidrolisis térmica, acida y enzimática, las pruebas experimentales se desarrollaron mediante el monitoreo de cinéticas que simulan pequeños bioreactores a escala de laboratorio de 200 ml, en un tiempo de operación de 30, 60 y 90 días con incremento de carga gradual de $1 \text{ Kg S}_v \text{ m}^{-3} \text{ d}^{-1}$ en cada periodo de operación, el procedimiento completo se explica más adelante.

En la segunda etapa “Identificación de Patrones de Comportamiento y Predicción” a través de dos técnicas: 1) El diseño de un modelo lógica difusa desarrollado en base al conocimiento y experiencia de los especialistas del Proceso de Digestión Anaerobia, y 2) El desarrollo de Redes Neuronales Artificiales que trabaja en base a una minería de datos experimentales obtenidos en el Laboratorio del Proceso de Digestión Anaerobia Mesofilica.

Las dos técnicas permiten identificar el patrón de comportamiento de las variables de entrada que intervienen en el proceso y a su vez permiten predecir el rendimiento energético de diferentes escenarios propuestos.

En la tercera etapa “Análisis de superficie de respuesta”, a partir del modelo de Lógica Difusa se desarrollan gráficos de superficie de respuesta para mostrar como las variables de entrada impactan en ciertas condiciones de operación a la obtención de biogás, metano y remoción. El análisis de superficie de respuesta permite observar los mejores escenarios del proceso de digestión anaerobia mesofilica.

En la cuarta etapa llamada “Optimización del proceso”, partiendo de las superficies de respuesta obtenidos de los modelo de lógica difusa, se desarrollaron modelos matemáticos que permitieron ser utilizados en la optimización del proceso, para ello se utilizó la herramienta gatoolbox de Matlab para la creación de algoritmos genéticos que nos permiten generar una optimización de los tres criterios de salida: biogás, metano y remoción.

Para finalizar, en la quinta etapa “Desarrollo de un sistema experto de apoyo a la decisión”, se programó el sistema que integra los modelos de lógica difusa, las redes neuronales artificiales la optimización, permitiendo al usuario ingresar datos y obtener resultados estimados del PDAM (Figura 4.1).

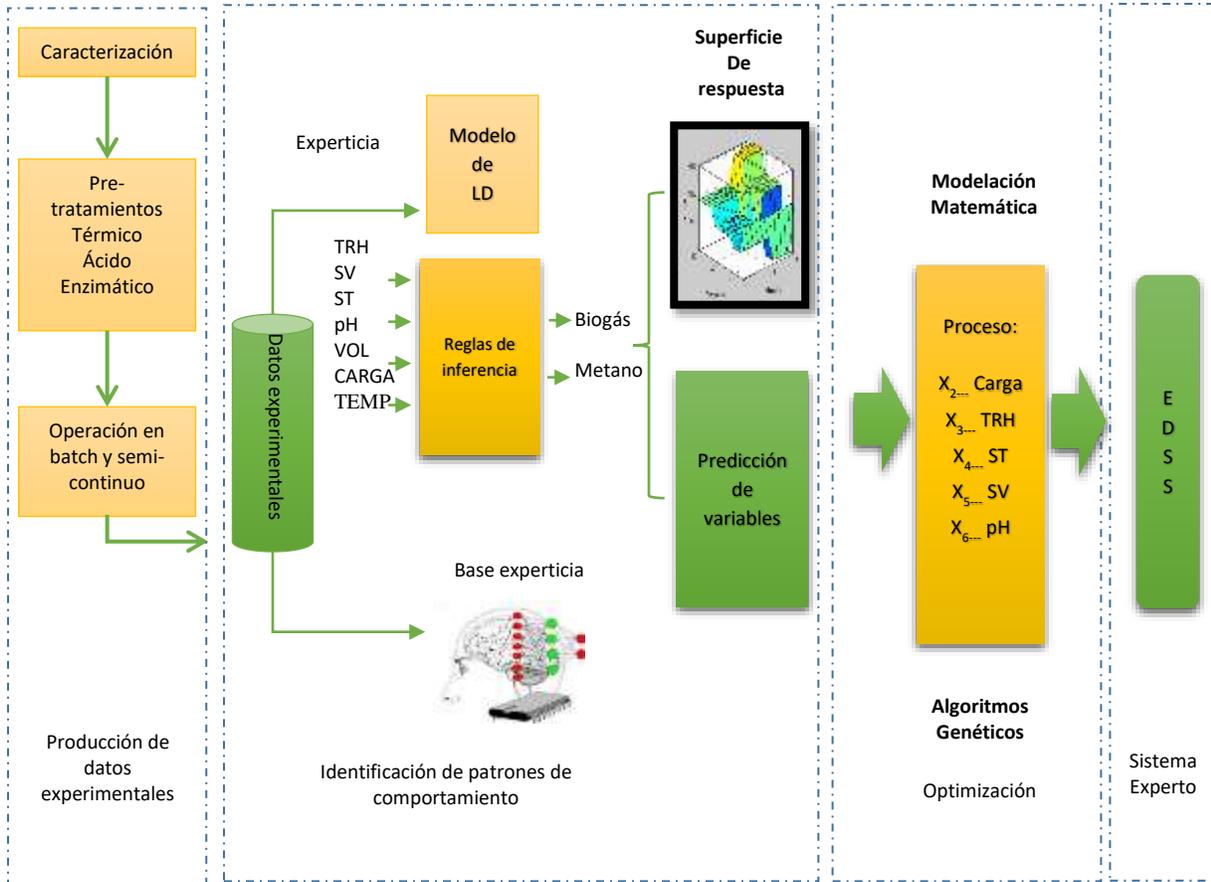


Figura 4.1 Metodología propuesta para el desarrollo del sistema de apoyo a la decisión del proceso de digestión anaerobia.

4.3 Etapa 1: Producción de datos experimentales

En la etapa uno se llevó a cabo el proceso de recolección de las bases de datos que alimentarán el sistema de apoyo a la decisión, para ello, se partió de una base de datos existente, elaborada por alumnos de posgrado del laboratorio de ambiental, también se llevaron a cabo algunos experimentos complementarios que permitieron validar la información y robustecer las bases de datos.

4.3.1 Obtención y caracterización de lodos residuales

El lodo residual utilizado proviene de una planta de tratamiento de aguas residuales de una industria avícola en su división rastro de aves, la planta opera actualmente tratando un caudal de 10 L/s; el agua residual se considera como agroindustrial y se presume que por su origen, contiene concentraciones elevadas de microorganismos patógenos.

La planta de tratamiento recibe aguas residuales de la matanza de aves, de la fábrica de hielo en barra y del área de cocimiento (denominada también de rendimiento) la cual cuenta con tres cocedores.

En la Figura 4.2 se observa el sistema de tratamiento de aguas residuales de la industria avícola, el cual está conformado inicialmente por un tratamiento primario; en donde son separados los sólidos de mayor tamaño (pluma y hueso) así como la mayor parte de la grasa. Enseguida el agua pasa a un tanque homogeneizador en donde es sometida a un tratamiento primario avanzado en el cual se le adicionan reactivos, en este caso se adiciona policloruro de aluminio, hidróxido de calcio y polímero catiónico, los cuales favorecen la separación de partículas de menor tamaño mediante el proceso de coagulación-floculación.

Posteriormente, el agua es conducida a un clarificador de placas paralelas en el cual se realiza la sedimentación, el agua tratada pasa a un tanque de cloración y finalmente es clarificada en filtros de grava y carbón activado.

Los lodos generados después del tratamiento son espesados antes de pasar al reactor aerobio, una vez digerido, el lodo se deshidrata en un filtro prensa hasta una concentración de entre 15-20% de ST.

El punto de muestreo del cual el lodo se obtuvo, fue de las tuberías del tanque espesador que conducen al tanque de digestión aerobia, los periodos entre cada purga del espesador son de aproximadamente 8 horas, en donde la concentración de ST de la muestra oscilan entre 1.5-2% ST. El lodo crudo fue transportado al laboratorio en contenedores de 20L, donde posteriormente se caracterizó y se acondicionó conforme requería el estudio y fue conservado a una temperatura de $4^{\circ}\text{C} \pm 2$, hasta el momento de preparar la combinación de residuos.

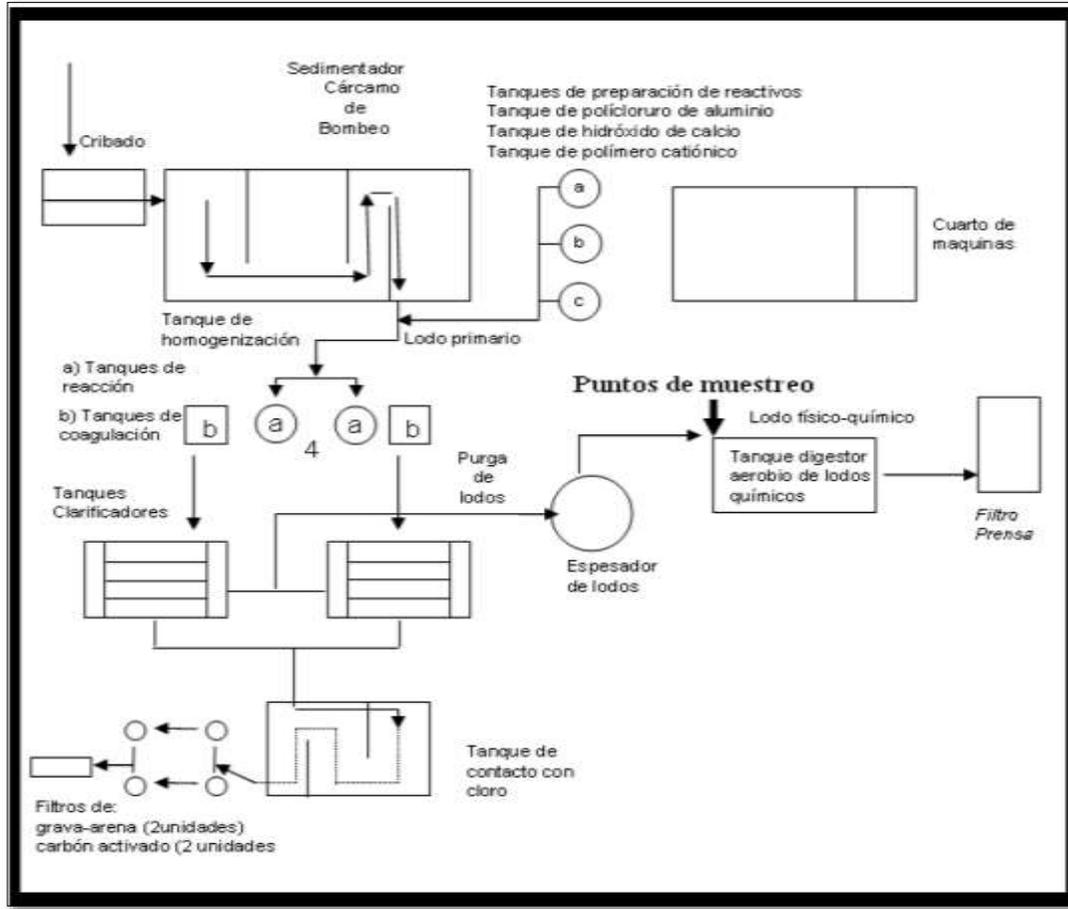


Figura 4.2 Sistema de tratamiento de aguas residuales de la industria avícola (Ruiz, 2010).

4.3.1.1 Caracterización de sustratos

Se llevó a cabo una caracterización fisicoquímica y bioquímica de los sustratos a utilizarse con la finalidad de conocer su composición, tipo y concentración de contaminantes y propiedades. Las muestras se analizaron por cuadruplicado y el muestreo de los sustratos fue semanal, los parámetros, el método de análisis empleado y las unidades en las que se reportan se muestran en la Tabla 4.1. La caracterización se realizó al inicio del tratamiento (sustratos crudos) y después de la digestión (biosólido).

Tabla 4.1. Parámetros de caracterización.

Físicos	Unidad	Método
pH		Potenciométrico
Temperatura	° C	Termopar
Sólidos Totales	% m/m	2540 B Standard Methods
Sólidos Totales Volátiles	% m/m	2540 E Standard Methods
Sólidos Totales Fijos	% m/m	2540 E Standard Methods
Químicos	Unidad	Método
DQO	mg O ₂ /L	Colorimétrico 5220 D SM
Nitrógeno Total	g N-NTK /kg ST	4500-NTK C Standard Methods
Nitrógeno Amoniacal	g N-NH ₃ /kg ST	4500-NH ₃ B Standard Methods
Nitrógeno Orgánico	g N-Org / Kg ST	4500-Norg B SM
Fósforo	ppm	4500-P B, E, Standard Methods
Relación de Alcalinidad	Alc. 5.75 / Alc 4.3	2320 B Standard Methods
AGV's	mg AGV's/L	Teórico (Jenkins 1983)

4.3.1.1.1 pH

El pH es el parámetro que indica la concentración de iones hidrógeno en una disolución, este parámetro se midió de forma directa en la muestra con un potenciómetro Orión 250a, el cual se calibró con soluciones tampón 4.0 y 7.0, la resolución de la lectura es de 0.01 unidades de pH y la precisión es de ± 0.01 .

4.3.1.1.2 Temperatura

Este parámetro se midió de forma directa en la muestra por medio de un termómetro de mercurio 0-100°C.

4.3.1.1.3 Sólidos totales

Los Sólidos Totales se definen como el material residual después de evaporación y secado de una muestra a cierta temperatura, esta determinación se realizó mediante la técnica gravimétrica descrita en el método estándar 2540 G de la APHA-AWWA-WPFC (1999). Se

evapora la muestra en un crisol a peso constante en una estufa a 103-105°C por un lapso de 24 horas. El aumento de peso sobre el peso del crisol vacío representa los Sólidos Totales; y el cálculo se realiza con la siguiente ecuación:

Ecuación 4.1 Ecuación para la determinación de sólidos totales.

$$\% ST = \frac{p3 - p1}{p2 - p1} \cdot 100$$

Dónde:

p1= Peso del crisol a peso constante.

p2=Peso del crisol a peso constante + peso de la muestra antes de evaporación.

p3=Peso del crisol a peso constante + peso del residuo seco.

4.3.1.1.4 Sólidos volátiles

El residuo producido en la determinación de Sólidos Totales según el método descrito anteriormente, se calcina a 550°C, durante dos horas. El peso perdido en el crisol tras la incineración del residuo seco, representa el contenido en Sólidos Volátiles. De la misma forma que los Sólidos Totales, esta técnica analítica se realizó de acuerdo con el método estándar 2540 G de la APHA-AWWA-WPFC (1999), y el porcentaje se calcula utilizando la siguiente ecuación:

Ecuación 4.2 Ecuación para la determinación de sólidos volátiles.

$$\%SV = \frac{p3 - p4}{P3 - p1} * 100$$

Dónde:

p1= Peso del crisol a peso constante.

p3=Peso del crisol a peso constante + peso del residuo seco.

p4=Peso del crisol a peso constante + peso de la muestra calcinada.

4.3.1.2 Pre tratamientos para optimizar el proceso de digestión anaerobia

Existen diversos pre-tratamientos que favorecen el proceso de digestión anaerobia, estos pretratamiento aceleran el proceso de hidrólisis, que se encarga de la descomposición de la materia en compuestos de moléculas más simples, permitiendo reducir los tiempos de remoción y mejorando los rendimiento de producción de biogás y metano CH_4 .

4.3.1.2.1 Evaluación de la pre-hidrólisis térmica en la solubilización de la materia orgánica

Para llevar a cabo la pre-hidrólisis térmica se utilizaron parrillas de calentamiento con agitación magnética y matraces Erlenmeyer de 250 ml con un tapón de hule en el cual se introdujo un termómetro colocado en el seno del líquido para el monitoreo de la temperatura, los tapones se sellaron con teflón para evitar fugas de vapor y modificar la concentración de sólidos totales. Se agitó el sistema para homogenizar el sistema, la temperatura y evitar la formación de espuma (Figura 4.3).



Figura 4.3 Pre-hidrólisis térmica

El tiempo del tratamiento comenzó hasta alcanzar la temperatura deseada y después de cada tiempo de exposición, muestras de 200 ml fueron retiradas y sumergidas en un baño helado

para su rápido enfriamiento y análisis, cada experimento fue llevado a cabo 4 veces para los tratamientos sugeridos.

El grado de solubilización de los compuestos orgánicos fue calculado de acuerdo con la ecuación 6.

Ecuación 4.3 Ecuación para la solubilización de compuestos orgánicos.

$$GS = \frac{\text{DQOs tratado} - \text{DQOs crudo}}{\text{DQOt crudo}}$$

Donde:

GS = grado de solubilización expresado en porcentaje

DQOs tratado = mg DQO_{soluble} / L con pre-tratamiento térmico

DQOs crudo = mg DQO_{soluble} / L sin pre-tratamiento térmico

DQOt crudo = mg DQO_{total} / L sin pre-tratamiento térmico

4.3.1.2.2 Pre-tratamiento térmico en Modo *Batch*

Con la finalidad de evaluar el efecto de la pre-hidrólisis térmica en el lodo fisicoquímico, se realizó una prueba por lote a nivel laboratorio utilizando cinéticas de 250 ml y 200 ml útiles. Para el arranque de las cinéticas se utilizó inóculo colectado del exceso de biomasa de la planta de tratamiento a escala piloto instalada en el Instituto Tecnológico de Orizaba. Los reactores (cinéticas) fueron alimentados con lodo residual fisicoquímico tratado térmicamente a 90°C y 90 min, mientras que la segunda fue alimentada con lodo residual fisicoquímico crudo sin tratamiento térmico.

Todas las pruebas se realizaron por triplicado en un volumen de trabajo de 250 ml con volumen útil de 200 ml, el contenido de ST en el lodo fue de 2.5% y 65% de STV, que corresponden a

una carga de 16.25 kg STV/m³, la temperatura del proceso de digestión anaerobia fue mesofílica a 36°C. La eficiencia del proceso se evaluó diariamente en términos de remoción de sólidos totales volátiles y el experimento por lote se detuvo hasta alcanzar el criterio de remoción del 38% de los sólidos volátiles para estabilizar la materia orgánica y cumplir con el criterio de atracción de vectores.

Concluida la etapa por lote se procedió a mantener a las cinéticas en alimentación semi-continua, la cual consistió en retirar y después alimentar cada cinética cada 24 horas con la cantidad calculada para cumplir con la carga orgánica aplicada. La producción de biogás para el lodo crudo y pre-hidrolizado fue medida diariamente por desplazamiento volumétrico de agua acidificada y su composición fue analizada por cromatografía de gases utilizando un cromatografo Focus GC marca Thermo Scientific equipado con una columna TG-bond Q para el análisis de O₂, N₂, CO₂ y CH₄, utilizando helio como gas de arrastre.

4.3.1.2.3 Operación semi-continua e incremento de la carga orgánica en la digestión anaerobia de lodo crudo y pre-hidrolizado

Después de las pruebas por lotes, las condiciones de operación en flujo semi-continuo fueron definidas para el proceso de digestión anaerobia para lodo con pre-tratamiento térmico a 90°C y 90 minutos de acuerdo a lo reportado por (Ruiz, 2012) como el tiempo de exposición optima a temperatura mesofílica, y lodo crudo sin pre-tratamiento, los parámetros de operación son mostrados en la Tabla 4.2. Para el lodo pre-hidrolizado, las cinéticas fueron operadas con una carga orgánica inicial de 1 kg SV/m³.d y 0.5 kg SV/m³.d para el lodo crudo, la carga orgánica se incrementó en periodos de 30 días, alimentando y retirando el mismo volumen una vez al día, utilizando una bomba peristáltica. El sustrato y la salida de las cinéticas fueron almacenados a 4°C para su posterior análisis lo más pronto posible. Los parámetros monitoreados fueron pH, alcalinidad y temperatura, la eficiencia del proceso se determinó en base a la remoción de sólidos volátiles y a la producción de biogás.

Tabla 4.2. Incremento de la CVA en la digestión anaerobia semi-continua

Carga Volumétrica Aplicada (Kg SV/m ³ d)		Intervalo de tiempo Días
Lodo crudo	Lodo pre-hidrolizado	
0.5	1	0 – 30
1	2	31 – 60
1.5	3	61 – 90

4.3.1.2.4 Pre-hidrólisis ácida en lodo residual

Para la elaboración de las pruebas de producción de biogás con pre-hidrólisis ácida se llevó a cabo tomando como referencia las pruebas de dosis reportadas en la tesis de Noemi Nava Valente en 2014, las dosis reportada como óptima fue de 4 ml por cada 100 ml de lodo residual durante 90 minutos de exposición (Nava, 2014).

Los tratamientos ácidos se llevaron a cabo en matraces Erlenmeyer de 250 ml, con un volumen útil de 200 ml. Se utilizó una incubadora ZHICGENG Incubator Shaker, modelo ZHWY-100B para establecer una agitación continua de 150 rpm y a temperatura ambiente. Una vez transcurrido el tiempo de exposición, las muestras se neutralizaron con NaOH al 40 % hasta un pH de 7.0 para detener el efecto del ácido acético.

4.3.1.2.4.1. Operación *batch* y semi-continua de lodo con pretratamiento ácido

Se acondicionaron las muestras de los lodos residuales a 3.5 % de ST y 65 % STV, para obtener la producción de biogás en operación *batch*. Se operó durante 30 días, y en 16 días llegó al 38% de remoción.

Para evaluar el efecto de la pre-hidrólisis ácida en el lodo fisicoquímico, se realizó una prueba por lote a nivel laboratorio utilizando reactores anaerobios adaptados por medio de cinéticas, elaboradas en matraces de 250 ml, con un volumen útil de 200 ml. Para el arranque de los reactores anaerobios se utilizó inóculo colectado del exceso de biomasa de la planta de tratamiento a escala piloto instalada en el Instituto Tecnológico de Orizaba. El reactor fue

alimentado con lodo residual fisicoquímico tratado con ácido acético, alimentando diariamente el contenido de ST en el lodo fue de 3.5% y 75% de STV, la temperatura del proceso de digestión anaerobia fue mesofílica a 36°C. La eficiencia del proceso se evaluó diariamente en términos de remoción de sólidos totales volátiles y el experimento por lote se detuvo hasta alcanzar el criterio de remoción del 38% de los sólidos volátiles para estabilizar la materia orgánica y cumplir con el criterio de atracción de vectores.

Concluida la etapa por lote se procedió a mantener a las cinéticas en alimentación semi-continua, la cual consistió en retirar y después alimentar las cinéticas cada 24 horas una cantidad de 18.33 mg por día, correspondiente a la necesidad de alimentación requerida por día, se operó en cargas de 1, 2 y 3 Kg SV/m³. La producción de biogás fue medida diariamente por desplazamiento volumétrico de agua y su composición fue analizada por cromatografía de gases.

4.3.1.2.5 Pre-hidrólisis enzimática

Los lodos residuales se trataron de manera enzimática con el objeto de facilitar la digestión del sustrato, disminuir los tiempos de residencia y aumentar el porcentaje de generación de metano.

La enzima con nombre comercial PROTEASA ® FUNGAL la cual es una proteasa de grado alimenticio obtenido por medio de la fermentación controlada de *Aspergillus oryzae* var. Es básicamente una mezcla proteasas ácidas, neutras y alcalinas que demuestran actividad exopeptidasa y endopeptidasa en las moléculas de proteína. Las exo-peptidasas liberan aminoácidos por medio de la hidrólisis de las cadenas peptídicas en su parte terminal. Las endopeptidasas hidrolizan los enlaces peptídicos internos de la proteína, liberando polipéptidos de diferentes longitudes menores de endopeptidasas que hidrolizan los enlaces peptídicos primarios de las moléculas proteicas. Consecuentemente, la viscosidad de soluciones de gelatina, cola y otros geles proteínicos es reducida rápidamente. La amplia especificidad de sustratos sobre los que actúa la PROTEASA FUNGAL la hace adecuada para hidrolizar fácil y eficientemente la mayoría de las proteínas.

El rango óptimo de temperatura para PROTEASA FUNGAL es de 50 a 55 ° C con un pH de 7.0. A una temperatura de 40 a 50 ° C a un pH de 7.0, proporciona una mejor estabilidad de la enzima, mientras que la temperatura superior a 60 ° C se inactiva inmediatamente la misma.

De acuerdo a los resultados de la caracterización química se eligió el compuesto orgánico predominante (Carbohidratos, Lípidos o Proteínas). Tomado como referencia la tesis de Noemí Nava Valente en el 2014, reporta como la enzima con mejores rendimientos presentados fue la enzima fungal, ya que los rendimientos obtenidos son óptimos en una dosis baja de la enzima, lo que implica un menor costo del proceso. Por todo lo anterior se decidió llevar a monitoreo en *batch* y semi-continuo la cinéticas alimentadas con sustrato pre-tratado enzimáticamente con enzima Fungal durante 90 minutos y dosis baja.

4.3.1.2.5.1 Operación *batch* y semi-continua de lodo con pretratamiento enzimático

Se acondicionaron las muestras de los lodos residuales a 3.5 % de ST y 70 % STV, para obtener la producción de biogás en operación *batch*, con el fin de monitorear la producción de biogás.

Para evaluar el efecto de la pre-hidrólisis enzimática en el lodo fisicoquímico, se realizó una prueba por lote a nivel laboratorio utilizó un baño con agitación orbital modelo BAO 6040, que se operó 50 °C (Digestión anaerobia mesofílica y temperatura requerida para la activación de la enzima) y 120 rpm, para obtener datos confiables se llevó a cabo el montaje de una prueba control y replica para una mejor validación de los resultados. Ésta prueba se realizaron en matraces de 250 mL, con un volumen útil de 200 mL para cada matraz.

Concluida la etapa por lote se inició la fase de alimentación semi-continua, se operó las cinéticas con una carga orgánica de 1, 2 y 3 Kg SV/m³. En un lapso de 15 días y se obtuvieron los siguientes resultados la cual consistió en retirar y después alimentar las cinéticas cada 24 horas. La producción de biogás fue medida diariamente por desplazamiento volumétrico de agua y su composición fue analizada por cromatografía de gases. Se observó una remoción de SV promedio de 40% , lo que supera el 38% de remoción de SV establecido por la NOM004-SEMARNAT-2002 para obtener un biosólido clase A.

El porcentaje mínimo de remoción de material orgánico fue de 38.5% que inclusive rebasa lo estipulado por normatividad y el máximo de 57.95%. El TRH fue de 14 días.

4.4 Etapa 2: Identificación de Patrones de Comportamiento y Predicción

En la etapa anterior se abordó la etapa 1 de la metodología llevada a cabo para la generación de biogás por medio de digestión anaerobia en condiciones mesofílicas, por medio de este proceso experimental se cuenta con una base de datos que son punto de referencia para el desarrollo de modelos de lógica difusa y redes neuronales artificiales.

4.4.1 Determinación de patrones de comportamiento del proceso de digestión anaerobia mesofílica a través de lógica difusa

Para el desarrollo de un sistema experto es necesario analizar el patrón de comportamiento de las variables que intervienen en el sistema, los patrones pueden ser determinado por medio de una consulta a los expertos, o apoyándose en minería de datos, en este trabajo se utilizaron ambas técnicas, a continuación se describe el proceso llevado a cabo por medio de lógica difusa para estimar los patrones de comportamiento de las variables de entrada y salida del proceso de digestión anaerobia mesofílica.

4.4.1.1 Modelo de lógica difusa para digestión anaerobia mesofílica en lodo con pre-tratamiento térmico en operación semi-continuo

En la presente investigación se desarrolla un Sistema Experto basado en Lógica Difusa que se basa en el modelado del conocimiento y experiencia de los laboratoristas y especialistas en el Proceso de Digestión Anaerobia Mesofílica. La capitalización del conocimiento de los especialistas toma la experiencia de los procesos en lodos fisicoquímicos crudos y en lodos pre-hidrolizados térmicamente; en medio ácido y en medio enzimático. Dicho sistema será capaz de hacer una predicción de los valores óptimos para maximizar los rendimientos en la

generación de biogás y la calidad de los biosólidos producidos y a su vez servirá de apoyo a la toma de decisiones ya que proyectará los escenarios recomendables de aplicación de los procesos a evaluar en términos de rentabilidad energética.

A continuación se describe el modelo de lógica difusa de digestión anaerobia mesofílica en lodo pre-tratado térmicamente en operación semi-continuo, en un modelo difuso tipo Mandami desarrollado en Matlab.

El modelo de Lógica Difusa muestra la combinación de las 11 variables de entrada: sólidos totales, sólidos volátiles, carga, tiempo de operación, temperatura, pH, inhibidores, bacterias hidrolíticas, bacterias acidogénicas, bacterias acetogénicas y bacterias metanogénicas, con respecto a las 3 variables de salida: biogás, metano y remoción (Figura 4.4).

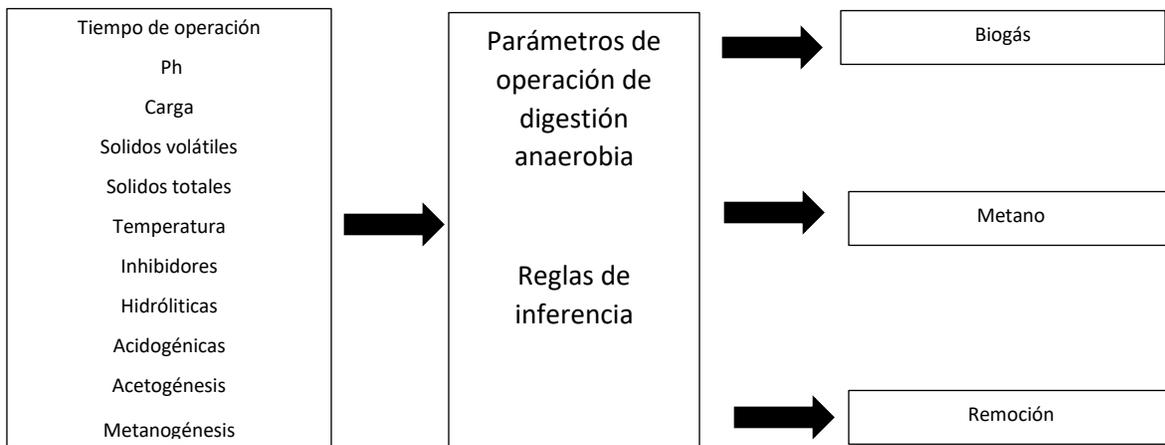


Figura 4.4 Modelo de lógica difusa, tipo Mandami en Matlab.

4.4.1.1.1 Definición de Variables Lingüísticas

En la Tabla 4.3 se describen las variables que son consideradas por los expertos como los valores de referencia para el control del proceso, y que influyen en la preservación y proliferación de los grupos bacterianos que intervienen en el proceso de digestión anaerobia, algunas de las variables de entrada, tales como, inhibidores, temperatura, pH y carga, representan variables que pueden ser manipuladas por los investigadores en el laboratorio, en el caso de los grupos bacterianos, se consideró la presencia de cada grupo durante el proceso.

Tabla 4.3. Variables de entrada de los modelos de lógica difusa de digestión anaerobia en lodos pre-hidrolizados y no pre hidrolizados.

Variables	Definición	Unidades de medida
Tiempo de operación	Días de operación y monitoreo de las cinéticas, dependiendo las cargas volumétricas de los reactores y la operación del proceso.	Días
Ph	Coefficiente que indica el grado de acidez o basicidad de una solución acuosa.	Unidades
Carga	Se expresa típicamente como peso de materia orgánica expresada en concentración de Sólidos Volátiles o Demanda Química de Oxígeno (DQO) por unidad de volumen del reactor por día. Representa la medida exacta de alimento que un digestor necesita.	gSV/m ³ d
Sólidos Volátiles	Es un indicador de materia orgánica expresada en concentración de Sólidos Volátiles.	% SV
Sólidos totales	Los Sólidos Totales se definen como el material residual después de evaporación y secado de una muestra a cierta temperatura.	%ST
Temperatura	Rango de temperaturas para la operación del proceso de digestión anaerobia mesofílica.	°C
Inhibidores	Las formas no ionizadas de los ácidos grasos volátiles, así como el amoníaco libre o el ácido sulfhídrico, también se incluyen la presencia de metales pesados.	U.
Hidrolíticas	Son un conjunto de bacterias cuya finalidad es romper los enlaces complejos de proteínas, celulosa, lignina o lípidos en monómeros o moléculas como aminoácidos, glucosa, ácidos grasos y glicerol (Clostridium y Bacteroides)	%
Acidogénesis	Bacterias que se encargan de convertir azúcares, aminoácidos y lípidos en ácidos orgánicos, alcoholes y cetonas, acetato, CO ₂ y H ₂ , (<i>Clostridium</i> , <i>Lactobacillus</i> y <i>Bacillus</i>).	%
Acetogénesis	Son bacterias productoras de H ₂ junto a otras bacterias consumidoras de este (<i>Syntrophobacter</i> , <i>wolinii</i> y <i>Syntrophomonas wolfei</i>)	%
Metanogénesis	Son las bacterias encargadas de la producción de Metano, existen 90 especies de metanógenas distribuidas en 5 clases distintas: Methanobacteria, Methanococci, Methanomicrobiota, Methanopyri y Methanosarcinales.	%

Las variables de salida correspondientes a la producción de biogás, metano y emoción son presentadas en la Tabla 4.4, son consideradas variables de salida, ya que el rendimiento de biogás y metano representa el resultado del comportamiento de los grupos bacterianos que intervienen en el proceso de digestión anaerobia, la proliferación de bacterias depende del

control adecuado de los parámetros que corresponden a las variables de entrada, por otro lado, el rendimiento de metano puede variar de acuerdo a la calidad del biogás obtenido. La remoción es considerada un resultado del adecuado control y co-digestión del reactor.

Tabla 4.4. Variables de entrada de los modelos de lógica difusa de digestión anaerobia en lodos pre-hidrolizados y no pre hidrolizados.

VARIABLES	DEFINICIÓN	UNIDADES DE MEDIDA
Biogás	Es una mezcla gaseosa que se obtiene de la descomposición de la materia orgánica en condiciones anaeróbicas.	ml/d
Metano	Es un componente del biogás, derivador de la descomposición de la materia orgánica.	%
Remoción	Descomposición de la materia orgánica para su conversión en biogás.	%

4.4.1.1.2 Fusificación

La modelación de la fusificación de las variables se realiza bajo del modelo Mandami en la librería “<<fuzzy>>” del software MatLab. Los comportamientos y funciones de membresía empleados para la modelación se realizaron de acuerdo a los valores arrojados por los intervalos de confianza de la base de datos de las experimentaciones previas en el laboratorio en las variables pH, carga, sólidos totales, sólidos volátiles, biogás y Metano (CH₄).

La fórmula empleada para la determinación de los intervalos de confianza fue:

Ecuación 4.4 Fórmula para calcular intervalos de confianza.

$$\bar{x} - Z_{\alpha/2} * \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{x} + Z_{\alpha/2} * \frac{\sigma}{\sqrt{n}}$$

En la Tabla 4.5 se muestra la determinación de los conjuntos difusos que fueron obtenidos estimando intervalos de confianza en las bases de datos descritas en la primera parte de la investigación.

Es de suma importancia hacer una clara definición de los parámetros y rangos en los que se van a definir los diferentes conjuntos difusos, ya que las reglas de inferencia parten de los intervalos dados en los conjuntos difusos para estimar el grado de pertenencia entre un intervalo y otro, considerando la figura geométrica en la que se represente el conjunto.

La variable inhibidores se definió de acuerdo al grupo de principales inhibidores, entre los más conocidos están: nitrógeno amoniacal, ácidos grasos de cadena larga, ácidos grasos volátiles, algunos cationes, etc.

La inhibición por amoniacal libre es más fuerte para las bacterias metanogénicas (Hansen et al., 1998).

Los conjuntos para la variable inhibidores se plantearon considerando la existencia de cada inhibidor, en donde el valor de intervalo bajo representa la inexistencia del inhibidor, el valor intermedio del conjunto indica la presencia y el valor alto del conjunto nuevamente representa valores de cero, haciendo una figura triangular.

Para el caso de los conjuntos difusos definidos para el grupo de bacterias, se llevó a cabo una revisión bibliográfica, en la que se analizaron las aproximaciones de la cantidad de grupos bacterianos presentes en cada etapa del proceso, es muy impreciso hacer un cálculo exacto de la proliferación de las bacterias existentes en cada fase, sin embargo, se realizó un análisis bibliográfico de la presencia de los principales grupos bacterianos presentes en cada fase y su conglomeración en porcentaje, considerando los valores reportados en partes por millón (ppm) (Gallegos, 2010) y representado en porcentajes en los conjuntos que se exponen en la Tabla 4.5.

Tabla 4.5 Conjuntos difusos para las variables de entrada en lodo con pre-tratamiento térmico.

Variab les	Etiqu eta	Figura geom étrica	Intervalo
Sólidos Volátiles	Bajo	Trapezoidal	(60 60 68 72)
	Óptimo	Triangular	(65.2 71.2 77.5 80.91)
	Alto	Trapezoidal	(79 83 90 90)
Sólidos totales	Recomendable	Trapezoidal	(1.11 2.132 2.84 3.52)
	Alto	Trapezoidal	(2.85 3.434 4 4)
Tiempo de operación	Corto	Trapezoidal	(1.54 8 25.9 33.14)
	Convencional	Triangular	(26.8 33.1 57.6 62.8)
	Largo	Trapezoidal	(57.86 65.9 80.2 90)
Carga	Uno	Triangular	(1 1.1 1.2)
	Dos	Triangular	(1.15 2 2.2)
	Tres	Triangular	(2 3 3.15)
Ph	Ácido	Trapezoidal	(5.5 6 6.5 7)
	Neutral	Triangular	(7 7.5 8)
	Alcalino	Trapezoidal	(8 8.5 9 9.5)
Temperatura	Bajo	Trapezoidal	(20 25 30 35)
	Estable	Triangular	(30 35 40)
	Alto	Trapezoidal	(35.3 40.2 45.28 50)
Inhibidores	AGV´S	Triangular	(0 1 2)
	Hidrógeno	Triangular	(1 2 3)
	Nitrógeno Amoniacal	Triangular	(2 3 4)
	Sulfatos y sulfuros	Triangular	(3 4 5)
	Cationes y metales pesados	Triangular	(4 5 6)
	Inexistente	Triangular	(6 7 8)
		Triangular	
Bacterias Hidrolíticas	Inexistentes	Trapezoidal	(0 0 0.4 0.6)
	Existentes	Triangular	(0.4 0.6 1 1)
Bacterias Acidogénicas	Bajas	Trapezoidal	(0 0 0.4 0.6)
	Recomendable	Trapezoidal	(0.4 0.6 1 1)
Bacterias Acetogénicas	Deficiente	Trapezoidal	(0 0 0.4 0.6)
	Favorable	Trapezoidal	(0.4 0.6 1 1)
Bacterias Metanogénicas	Bajas	Triangular	(0 0 0.2 0.4)
	Optimas	Triangular	(0.2 0.4 0.6 0.8)
	Excelentes	Triangular	(0.6 0.8 1 1)

En la tabla 4.6 se presentan los conjuntos difusos de las variables de salida, biogás, metano y remoción, para determinar los conjuntos se analizaron las bases de datos obtenidas del proceso de digestión anaerobia mesofílica con pre-tratamiento térmico, posteriormente se realizó el procedimiento de intervalos de confianza anteriormente descrito.

Tabla 4.6 Conjuntos difusos para las variables de salida en lodo con pre-tratamiento térmico.

Variables	Etiqueta	Figura geométrica	Intervalo
Biogás	Poco	Trapezoidal	(0 0.625 1.25 1.875)
	Promedio	Trapezoidal	(1.75 2.5 3.25 3.5)
	Mucho	Trapezoidal	(3.125 3.75 4.375 5)
Metano	Baja	Trapezoidal	(0.4 0.4694 0.582 0.638)
	Media	Trapezoidal	(0.635 0.712 0.81 0.8565)
	Alta	Trapezoidal	(0.7687 0.8187 0.8787 1.018)
Remoción	Baja	Trapezoidal	(37.47 39.2 40.93 42.67)
	Buenas	Trapezoidal	(40.93 44.4 47.87 51.33)
	Optimas	Trapezoidal	(49.6 53.07 54.8 60)

En el Anexo 1, se puede observar un ejemplo del detalle del procedimiento llevado a cabo para la determinación de los intervalos de confianza y para las ecuaciones que definen las funciones de membresía de los conjuntos difusos de cada una de las variables de entrada y salida para los 8 modelos de lógica difusa desarrollados.

4.4.1.1.3 Reglas de Inferencia

Se crearon 7776 reglas de inferencia, como resultados de la multiplicación del número de etiquetas de cada variable de entrada.

ST (2)*SV(3)*pH(3) *Carga organica(3)*Tiempo(3) *Temperatura(3)*Inhibidores(3)* hidrolíticas(2)* acidogénicas (2)* acetogénicas(2)*metanogénicas(2)=7,776

Una vez obtenidas las reglas de inferencia, se validaron en base a la experticia de la persona que realizó las experimentaciones, la M.I.Q. Noemí Nava Valente, y a los resultados obtenidos en su tesis de Maestría. (Nava Valente, 2011).

Como resultado de la validación, se obtuvieron 998 reglas válidas, el segmento de reglas se introdujeron al software Matlab (Ver tabla 4.7), para la interpretación y activación de cada regla, permitiendo estimar el grado de pertenencia entre las funciones membresía del modelo, logrando obtener una predicción del proceso.

Tabla 4.7. Reglas de inferencia, lodo crudo en modo *batch*.

Regla	Tiempo	ST	SV	Carga	pH	Temperatura	Inhibidores	Hidrolíticas	Acidobacterias	Acetogénicas	Mesófilicas	BIOGÁS	METANO	REMOCIÓN
1	Corta	Recomendable	Alto	Carga uno	Corta	Recomendable	Alto	Carga uno	Recomendable	Baja	Baja	Bajo	Poco	Poco
2	Corta	Recomendable	Alto	Carga dos	Corta	Recomendable	Alto	Carga dos	Recomendable	Baja	Baja	Medio	Promedio	Promedio
3	Corta	Recomendable	Alto	Carga uno	Corta	Recomendable	Alto	Carga uno	Recomendable	Baja	Baja	Bajo	Poco	Poco
4	Corta	Recomendable	Alto	Carga dos	Corta	Recomendable	Alto	Carga dos	Recomendable	Baja	Baja	Medio	Promedio	Promedio
5	Corta	Recomendable	Alto	Carga uno	Corta	Recomendable	Alto	Carga uno	Recomendable	Estable	Estable	Alta	Mucho	Mucho
6	Corta	Recomendable	Alto	Carga dos	Corta	Recomendable	Alto	Carga dos	Recomendable	Estable	Estable	Alta	Mucho	Mucho
7	Corta	Recomendable	Alto	Carga uno	Corta	Recomendable	Alto	Carga uno	Recomendable	Alta	Alta	Bajo	Poco	Poco
8	Corta	Recomendable	Alto	Carga dos	Corta	Recomendable	Alto	Carga dos	Recomendable	Alta	Alta	Medio	Promedio	Promedio
9	Corta	Recomendable	Alto	Carga uno	Corta	Recomendable	Alto	Carga uno	Alcalino	Baja	Baja	Bajo	Poco	Poco
10	Corta	Recomendable	Alto	Carga dos	Corta	Recomendable	Alto	Carga dos	Alcalino	Baja	Baja	Bajo	Poco	Poco
11	Corta	Recomendable	Alto	Carga uno	Corta	Recomendable	Alto	Carga uno	Alcalino	Estable	Estable	Bajo	Poco	Poco
12	Corta	Recomendable	Alto	Carga dos	Corta	Recomendable	Alto	Carga dos	Alcalino	Estable	Estable	Bajo	Poco	Poco
13	Convencional	Recomendable	Alto	Carga uno	Convencional	Recomendable	Alto	Carga uno	Recomendable	Baja	Baja	Bajo	Poco	Poco
14	Convencional	Recomendable	Alto	Carga dos	Convencional	Recomendable	Alto	Carga dos	Recomendable	Baja	Baja	Medio	Promedio	Promedio
15	Convencional	Recomendable	Alto	Carga uno	Convencional	Recomendable	Alto	Carga uno	Recomendable	Estable	Estable	Medio	Promedio	Promedio
16	Convencional	Recomendable	Alto	Carga dos	Convencional	Recomendable	Alto	Carga dos	Recomendable	Estable	Estable	Alta	Mucho	Mucho
17	Convencional	Recomendable	Alto	Carga uno	Convencional	Recomendable	Alto	Carga uno	Recomendable	Alta	Alta	Bajo	Poco	Poco
18	Convencional	Recomendable	Alto	Carga dos	Convencional	Recomendable	Alto	Carga dos	Recomendable	Alta	Alta	Medio	Promedio	Promedio
19	Larga	Recomendable	Alto	Carga uno	Larga	Recomendable	Alto	Carga uno	Recomendable	Baja	Baja	Bajo	Poco	Poco
20	Larga	Recomendable	Alto	Carga dos	Larga	Recomendable	Alto	Carga dos	Recomendable	Baja	Baja	Medio	Promedio	Promedio

Para la activación de las reglas de inferencia se ingresan datos al modelo y se observa el resultado arrojado en la variable de salida, las reglas que se activan son aquellas en las que se encuentra el dato ingresado, pero de forma interna el software estima el grado de pertenencia entre las diferentes funciones de membresía.

4.4.1.1.4 Desdifusificación

La defusificación (defuzzification) es un proceso matemático usado para convertir un conjunto difuso en un número real. El sistema de inferencia difusa obtiene una conclusión a partir de la información de la entrada, pero es en términos difusos. Esta conclusión o salida difusa es obtenida por la etapa de inferencia borrosa, esta genera un conjunto borroso pero el dato de salida del sistema debe ser un número real y debe ser representativo de todo el conjunto obtenido en la etapa de agregado, es por eso que existen diferentes métodos de defusificación y arrojan resultados distintos, el “más común y ampliamente usado” es el centroide. Con el

método de defusificación del centroide se transforma la salida difusa en un número real el cual es la coordenada equis (x) del centro de gravedad de tal conjunto difuso de salida.

El proceso de Desdifusificación se realiza de manera interna en el software MatLab, en donde se introducen las variables de entrada al sistema, y posteriormente se muestran los resultados en las variables de salida, biogás, metano y remoción, para poder explicar con mayor detalle el proceso de activación de las reglas, es necesario abordar un ejemplo, para ello, se ingresaron los siguientes valores en las variables de entrada del modelo: se consideró un proceso de operación de 10 días, sólidos totales de 1.5 %, sólidos volátiles de 60%, una carga de 1.25 gSV/d, nivel de pH de 7, con un porcentaje de 0.5 % de bacterias hidrolíticas, acidogénicas, acetogénicas y metanogénicas, en una temperatura de 32, con estos valores se activaron 55 reglas, y arrojaron una producción de biogás estimada es de 62.5 ml. Metano de 45.3% y remoción del 45%.

A continuación se presentan una objetiva explicación de los 7 modelos restantes, es importante mencionar que la metodología de construcción de los ocho modelos son semejantes con respecto a las variables y los conjuntos que los componen, existen algunas diferencias en relación al número de reglas y algunos intervalos de confianza, en el siguiente apartado se describieron las principales diferencias.

4.4.1.2 Modelo de lógica difusa para digestión anaerobia mesofílica con pre hidrólisis térmica en operación *batch*

Se mantuvo la estructura del modelo de lógica difusa planteado considerando las 11 variables de entrada y las 3 variables de salida definidas, haciendo modificaciones a los intervalos de confianza de las variables tiempo de operación, y las variables de salida, ya que los resultados obtenidos en el laboratorio para el modelo de lógica difusa con pre hidrólisis térmica en modo *batch* presentó diferencias en las variables de salida, por lo que se modificaron los intervalos de confianza para las variables de salida, biogás, metano y remoción.

4.4.1.2.1 Definición de Variables Lingüísticas y fusificación del modelo de lógica difusa para la digestión anaerobia con lodo pre-tratado térmicamente en operación *batch*

Al igual que en los modelos anteriores la primera fase consiste en hacer una definición de las variables, y posteriormente estimar los conjuntos difusos empleados en las funciones de pertenencia del modelo, para el modelo de lógica difusa de digestión anaerobia con pretratamiento térmico en modo *batch* se estimaron los intervalos mostrados en la Tabla 4.8.

Tabla 4.8. Conjuntos difusos actualizados para lodo pre-tratado térmicamente en modo *batch*.

Variables	Etiqueta	Figura geométrica	Intervalo
Tiempo de operación	Corto	Trapezoidal	(1. 3.281 9.113 10)
	Convencional	Triangular	(9 11.46 19.44 20)
	Largo	Trapezoidal	(19 22.15 26.81 30)
Biogás	Poco	Trapezoidal	(0 68.75 137.5 250)
	Promedio	Trapezoidal	(206.3 275 357.5 385)
	Mucho	Trapezoidal	(343.8 412.5 481.3 550)
Metano	Baja	Trapezoidal	(0.4 0.4694 0.582 0.638)
	Media	Trapezoidal	(0.6346 0.7116 0.8372 0.8832)
	Alta	Trapezoidal	(0.7687 0.8187 0.8787 1.018)
Remoción	Baja	Trapezoidal	(25.47 39.2 40.93 30)
	Buena	Trapezoidal	(30.93 44.4 47.87 50.33)
	Óptima	Trapezoidal	(48 52 54 60)

4.4.1.2.2 Reglas de Inferencia

Se validaron 856 reglas de inferencia, de las 7, 776 reglas que se obtuvieron de la multiplicación del número de etiquetas de cada variable de entrada. Con el apoyo y asesoría de los expertos en ambiental se validaron las reglas que fueron introducidas al software de Matlab.

4.4.1.2.3 Desdifusificación

Se desarrolló una corrida en el modelo desarrollado, ingresando como datos de entrada, tiempo de operación 15.5 días, con 2.75 % de sólidos totales, sólidos volátiles de 68%, una carga de 2.25 gSV/d, se opere en un nivel de pH de 7.5 y temperatura es de 35°C, la producción de biogás estimada fue de 376 ml. Metano de 61% y remoción del 47%, lo que indica que el proceso en operación *batch* registra menores producciones de biogás y metano CH₄.

4.4.1.3 Modelo de lógica difusa para digestión anaerobia mesofílica en lodo crudo en operación *batch*

Se desarrolló un modelo de lógica difusa para el proceso de digestión anaerobia para cada tipo de sustrato, para el caso del sustrato lodo crudo, existen dos tipos de operación, en lotes (*batch*) y operación continua, en el siguiente apartado se describe el modelo elaborado para el sustrato lodo crudo en operación *batch*.

4.4.1.3.1 Definición de Variables Lingüísticas y fusificación del modelo de lógica difusa para la digestión anaerobia con lodo pre-tratado térmicamente en operación *batch*

La operación en *batch*, fue realizada a 30 días de monitoreo, para ello se modificaron los conjuntos difusos de tiempo de operación y las variables de salida biogás, metano y remoción.

En la tabla 4.9 se presentan las modificaciones realizadas a los conjuntos de 11 variables de entrada y 3 variables de salida planteados en el modelo de lógica difusa con pretratamiento térmico, la variable de operación se ajustó al tiempo de monitoreo del reactor, dicho ajuste de tiempo efecto en las variables de respuesta.

Tabla 4.9 Conjuntos difusos actualizados para lodo- crudo en modo *batch*.

Variables	Etiqueta	Figura geométrica	Intervalo
Tiempo de operación	Corto	Trapezoidal	(1.3 9 11)
	Convencional	Triangular	(9 11 16 21)
	Largo	Trapezoidal	(20 23 27 30)
Biogás	Poco	Trapezoidal	(0 68.75 137.5 250)
	Promedio	Trapezoidal	(245.3 275 310 375)
	Mucho	Trapezoidal	(340 412 480 550)
Metano	Baja	Trapezoidal	(0.2 0.4694 0.582 0.60)
	Media	Trapezoidal	(0.59 0.68 0.72 0.85)
	Alta	Trapezoidal	(0.75 0.80 0.85 1)
Remoción	Baja	Trapezoidal	(25 39.2 40.93 30)
	Buena	Trapezoidal	(30 44.4 47.87 50)
	Óptima	Trapezoidal	(48 2 54 60)

4.4.1.3.2 Reglas de Inferencia y desdifusificación

Para el modelo de lógica difusa para lodo pretratado térmicamente en operación *batch* se validaron 887 reglas de las reglas obtenidas de la combinación de las 11 variables de entrada y las tres variables de salida.

Para la desdifusificación se procedió a programar los conjuntos difusos por medio del software Matlab, para validar la activación de las reglas, es necesario observar el comportamiento las reglas, y su activación, de acuerdo a los parámetros ingresados al sistema. Se introdujeron los siguientes datos para observar la activación de las reglas, considerando un tiempo de operación 20 días, con 1.75 % de sólidos totales, sólidos volátiles de 70%, una carga de 1.5 gSV/d, se opere en un nivel de pH de 7.1 y temperatura es de 30°C, con un porcentaje de 0.7 % de bacterias hidrolíticas, acidogénicas, acetogénicas y metanogénicas, la producción de biogás estimada fue de 466 ml. Metano de 50% y remoción del 45%, se activaron 33 reglas que determinaron la simulación del proceso.

4.4.1.4 Modelo de lógica difusa para digestión anaerobia mesofílica en lodo crudo en operación semi-continua

El modelo es similar al modelo de operación en *batch*, se emplearon las once variables de entrada anteriormente descritas, pero fue necesario hacer unos ajustes en los intervalos de cada conjunto difuso, considerando que la base de datos es más robusta debido a que el tiempo de operación es más prolongado, ya que se hacen incrementos de carga orgánica.

Para el caso de las variables de salida se operaron las tres que se determinaron en el inicio del planteamiento de los modelos, biogás, metano y remoción.

4.4.1.4.1 Definición de Variables Lingüísticas

Las variables lingüísticas quedaron definidas en el apartado anterior, para ello es importante hacer una revisión bibliográfica y una entrevista con el experto, para poder determinar cuáles variables de entrada y salida son importantes considerar en el modelo porque impactan en el proceso en lodos pre-tratados y no pre-tratados.

4.4.1.4.2 Fusificación

Los conjuntos difusos que fueron definidos por medio de intervalos de confianza aplicados a las bases de datos obtenidas del monitoreo de cinéticas en laboratorio, tuvieron un ajuste con respecto a las conjuntos definidos en la operación en semicontinuo con pretratamiento térmico. En la Tabla 4.10 se muestran los conjuntos lingüísticos de las variables, tiempo, carga, como parte de las variables de entrada que tuvieron cambios en los intervalos de confianza calculados y las variables de salida, biogás, metano y remoción considerando los cambios dados por el tipo de lodo sin tratamiento utilizado.

Tabla 4.10 Conjuntos difusos actualizados de lodo crudo en modo semi-continuo.

Variables	Etiqueta	Figura geométrica	Intervalo
Tiempo de operación	Corto	Trapezoidal	(1 10 20 31)
	Convencional	Triangular	(30 45 62)
	Largo	Trapezoidal	(60 70 80 90)
Carga	Uno	Triangular	(0.5 1 1.2)
	Dos	Triangular	(1.1 2 2.0)
	Tres	Triangular	(1.9 3 3.5)
Biogás	Poco	Trapezoidal	(0 0.45 7.25 1.2)
	Promedio	Trapezoidal	(1.1 1.4 1.8 2.2)
	Mucho	Trapezoidal	(2 2.8 3 4)
Metano	Baja	Trapezoidal	(0.2 0.4 0.5 0.638)
	Media	Trapezoidal	(0.635 0.712 0.81 0.8565)
	Alta	Trapezoidal	(0.7687 0.8187 0.9 1)
Remoción	Baja	Trapezoidal	(35.47 39.2 40.93 42)
	Buenas	Trapezoidal	(40.1 44 47 52)
	Optimas	Trapezoidal	(49 53.07 54.8 60)

4.4.1.4.3 Reglas de Inferencia

Para el modelo desarrollado para la operación en lodo crudo semicontinuo generaron 7,776 reglas de inferencia, mismas que fueron validadas por los expertos, quedando como reglas validas 898, descartando las reglas que no representan una probable activación en el modelo, es decir aquellas en las que el comportamiento de las variables no se combinan entre si y no pueden existir dichos casos.

4.4.1.4.4 Desdifusificación

Al igual que en el caso anterior, las reglas que se activan son aquellas en las que de forma interna el software estima el grado de pertenencia entras las diferentes funciones de membresía.

Es necesario explicar la activación de las reglas de inferencia mediante la ejemplificación de una corrida (caso) del modelo, para ello, se ingresaron datos considerando que el proceso de digestión anaerobia se encuentra en el día 20, con 2 % de solidos totales, solidos volátiles de

65%, una carga de 2 gSV/d, con un pH de 7.2, con un porcentaje de 0.4 % de bacterias hidrolíticas, acidogénicas, acetogénicas y metanogénicas, y la temperatura es de 34°C, la producción de biogás estimada es de 55 ml. Metano de 55.3% y remoción del 44%.

4.4.1.5 Modelo de lógica difusa para digestión anaerobia mesofílica con pre hidrólisis ácida en operación *Batch*

A continuación se describe el modelo de lógica difusa del proceso de digestión anaerobia mesofílica en con pre-tratamiento ácido, se han descrito diferente pre tratamientos químicos que incluyen el uso de ácidos fuertes como el ácido clorhídrico, perclórico, sulfúrico, nítrico o ácidos débiles como el fórmico y el acético (Xia y Clarkson, 1997; Curreli *et al.*, 2002; Cheng *et al.*, 2008).

Los cuales aceleran La destrucción de compuéstos orgánicos complejos, éstos se lograr por medio de ácidos minerales fuertes o álcalis. El pre-tratamiento acido mejora el rendimiento de la producción de monosacáridos a partir de la fracciones lignocelúlosicos de los residuos agroindustriales (Saha y Bothasta, 1999).

4.4.1.5.1 Definición de Variables Lingüísticas y fusificación del modelo de lógica difusa de digestión anaerobia con pre-hidrolisis ácida

Se ajustan los nuevos intervalos de datos considerando los datos generados por experticia y por prácticas de laboratorio.

Para poder hacer el proceso de fusificación, es necesario crear los conjuntos difusos de las etiquetas lingüísticas para estimar las diferentes funciones de membresía, dichos conjuntos se muestra a continuación en la Tabla 4.11.

Tabla 4.11 Conjuntos difusos actualizados para lodo- crudo en modo *batch*.

Variabes	Etiqueta	Figura geométrica	Intervalo
Tiempo de operación	Corto	Trapezoidal	(1 3 9 10)
	Convencional	Triangular	(9 11 16 20)
	Largo	Trapezoidal	(19 23 27 31)
Biogás	Poco	Trapezoidal	(0 68 130 200)
	Promedio	Trapezoidal	(195.3 255 300 375)
	Mucho	Trapezoidal	(370 410 480 500)
Metano	Baja	Trapezoidal	(0.2 0.30 0.50 0.60)
	Media	Trapezoidal	(0.59 0.68 0.72 0.85)
	Alta	Trapezoidal	(0.75 0.80 0.85 1)
Remoción	Baja	Trapezoidal	(20 23.2 27.9 30)
	Buena	Trapezoidal	(29 35 45 50)
	Óptima	Trapezoidal	(52 56 60)

4.4.1.5.2 Reglas de Inferencia y Desdifusificación

Se validaron 778 reglas, que fueron introducidas al modelo y nuevamente se procede a hacer la desdifusificación de los conjuntos difusos, para validar la activación de la reglas, se observó su comportamiento y su activación, de acuerdo a los parámetros ingresados al sistema. Se consideró un tiempo de operación 15 días, con 2.75 % de sólidos totales, sólidos volátiles de 60%, una carga de 1.5 gSV/d, se opere en un nivel de pH de 7.2y temperatura es de 32°C, con un porcentaje de 0.5 % de bacterias hidrolíticas, acidogénicas, acetogénicas y metanogénicas, la producción de biogás estimada fue de 255 ml. Metano de 52% y remoción del 42%.

4.4.1.6 Modelo de lógica difusa para digestión anaerobia mesofílica con pre hidrólisis ácida en operación semi continúa

El proceso de operación en semicontinuo se refiere a la alimentación diaria de los reactores anaerobios, por lo que genera diferentes resultados en las producciones de biogás, para ello se hicieron ajuste a los intervalos de los datos experimentales, definición las actualizaciones a las variables lingüísticas y fusificación del modelo de lógica difusa de digestión anaerobia con pre-hidrolisis ácida en operación semi continúa.

La Tabla 4.12 muestra los conjuntos que se actualizaron para el presente modelo, mostrando las diferencias entre los intervalos de confianza calculados para la operación semi continua en las variables de salida del proceso.

Tabla 4.12 Conjuntos difusos de lodo con pre-hidrolisis ácida en modo *batch*.

Variables	Etiqueta	Figura geométrica	Intervalo
Biogás	Poco	Trapezoidal	(0 62.5 125 187.5)
	Promedio	Trapezoidal	(175 250 325 350)
	Mucho	Trapezoidal	(312.5 375 437.5 500)
Metano	Baja	Trapezoidal	(0.4 0.469 0.582 0.6194)
	Media	Trapezoidal	(0.599 0.6528 0.825 0.901)
	Alta	Trapezoidal	(0.806 0.856 0.9991 1.09)
Remoción	Baja	Trapezoidal	(44 46.7 52.3 55.4)
	Buena	Trapezoidal	(54.76 59.2 64.7 70.3)
	Óptima	Trapezoidal	(63.36 8.91 71.68 80)

4.4.1.6.1 Reglas de Inferencia y Desdifusificación

Se ingresaron al sistema 705 reglas de inferencia validadas previamente por medio de un análisis realizado en colaboración con los expertos del proceso.

Para explicar la desdifusificación de los conjuntos difusos, y la activación de las reglas por medio del software Matlab, se realizó una corrida del sistema, tomando como valores iniciales, tiempo de operación 25.5, con 2.35 % de sólidos totales, sólidos volátiles de 56%, una carga de 2 kgSV/d, pH de 7 y temperatura es de 30°C, la producción de biogás estimada es de 301 ml. Metano de 58% y remoción del 48%.

4.4.1.7 Modelo de lógica difusa para digestión anaerobia mesofílica con pre hidrólisis enzimática en operación *Batch*

El tratamiento enzimático se refiere a un proceso llevado a cabo para la aceleración del proceso de hidrólisis por medio de enzimas que son catalizadores de origen proteico producidas por los seres vivos. Estos catalizadores biológicos aceleran las reacciones bioquímicas a temperaturas alrededor de 36° (para el caso de organismo mesofílicos). Es un método de conversión de compuestos lignocelulósicos a compuestos fáciles de biodegradación (Azúcares fermentables) mediante la hidrólisis, en la cual se utiliza una amplia gama de microorganismo incluyendo bacterias y hongos, (Berlin et al., 2006).

4.4.1.7.1 Definición de Variables Lingüísticas y fusificación del modelo de lógica difusa de digestión anaerobia con pre-hidrolisis enzimática

Es necesario cerciorarse de que los nuevos conjuntos difusos se asemejen a los datos obtenidos en el laboratorio de ambiental y a la información proporcionada por los expertos, por tal motivo se actualizaron la variable de entrada tiempo de operación y las variables de salida, ya que las proporciones con respecto a los rendimientos de biogás y metano se modifican con respecto a los deferentes sustratos, dichos conjuntos se muestra a continuación en la Tabla 4.13.

Tabla 4.13 Conjuntos difusos de lodo con pre-hidrolisis ácida en modo *batch*.

Variables	Etiqueta	Figura geométrica	Intervalo
Biogás	Poco	Trapezoidal	(0 37.5 75 112.5)
	Promedio	Trapezoidal	(105 150 195 210)
	Mucho	Trapezoidal	(187.5 225 262.5 300)
Metano	Baja	Trapezoidal	(0.4 1.153 2.376 2.984)
	Media	Trapezoidal	(2.952 3.788 4.852 5.356)
	Alta	Trapezoidal	(4404 4.946 5.598 71)
Remoción	Baja	Trapezoidal	(35 39.2 40.93 42)
	Buena	Trapezoidal	(40 44.4 47.87 50)
	Óptima	Trapezoidal	(49.6 53.07 54.8 61)

4.4.1.7.2 Reglas de Inferencia y desdifusificación

Para el sustrato con tratamiento enzimático se ingresaron 650 reglas al sistema, mismas que previamente se validaron por los expertos, las reglas corresponden al motor de inferencia de un modelo de lógica difusa, para este caso se llevó a cabo una corrida del sistema para mostrar los resultados de las reglas que se activaron en el proceso de desdifusificación.

Para demostrar la activación de las reglas se realizó una corrida del sistema, ingresando valores a las variables de entrada, considerando un tiempo de operación de 22 días, con 2 % de sólidos totales, sólidos volátiles de 50%, una carga de 2 kgSV/d, pH de 7 y temperatura es de 32°C, la producción de biogás estimada es de 380 ml. Metano de 60% y remoción del 50%.

4.4.1.8 Modelo de lógica difusa para digestión anaerobia mesofílica con pre hidrólisis enzimática en operación semi-continúa

Por último se describe el modelo de lógica difusa para lodo con pre hidrólisis enzimática en operación semi continua, se refiere a la aceleración de proceso de hidrólisis por medio de una enzima de origen natural, en un procedimiento de operación de alimentación continua.

4.4.1.8.1 Definición de Variables Lingüísticas y fusificación del modelo de lógica difusa de digestión anaerobia con pre-hidrolisis enzimática

Los conjuntos difusos de las variables lingüísticas de salida actualizados con respecto al pre tratamiento enzimático en operación continua se muestran en la Tabla 4.14.

Tabla 4.14 Actualización de conjuntos difusos de lodo con pre-hidrolisis enzimática en modo *batch*.

Variables	Etiqueta	Figura geométrica	Intervalo
Biogás	Poco	Trapezoidal	(100 125 175 200)
	Promedio	Trapezoidal	(199 220 260 310)
	Mucho	Trapezoidal	(300 325 365 400)
Metano	Baja	Trapezoidal	(0.4 1.153 2.376 2.984)
	Media	Trapezoidal	(2.952 3.788 4.852 5.356)
	Alta	Trapezoidal	(4.404 4.946 5.598 7.106)
Remoción	Baja	Trapezoidal	(37 39.2 40.93 41)
	Buena	Trapezoidal	(40.93 44.4 47.87 51)
	Óptima	Trapezoidal	(4 53.07 54.8 60)

4.4.1.8.2 Reglas de Inferencia y desdifusificación

Se hizo una comparación con el banco de datos recabados en laboratorio, se compararon las 7,776 reglas obtenidas en el modelo general, y para el modelo de pre tratamiento enzimático en operación continua se obtuvieron 648 reglas válidas.

Para realizar el análisis de los datos se entrevistaron a expertos en el proceso de digestión anaerobia, y se analizaron los datos obtenidos, así como se consultaron diversas fuentes bibliográficas previamente mencionadas, que permitieron determinar las reglas factibles de activación en el proceso.

Para poder hacer las predicciones de las variables de salida, es necesario hacer la desdifusificación de las reglas integradas al software, para observar las reglas activadas se realizó una corrida del sistema, ingresando datos en el sistema en las variables de entrada, el periodo de tiempo de operación de 14 días, con 2.3 % de sólidos totales, sólidos volátiles de 60%, una carga de 1.5 kgSV/d, pH de 7 y temperatura es de 30°C, la producción de biogás estimada es de 330 ml. Metano de 50% y remoción del 45%.

4.4.2 Predicción de variables del proceso de digestión anaerobia mesofílica a través de redes neuronales artificiales

El objetivo principal de las Redes Neuronales es definir una función a partir de la cual se pueda distinguir patrones de comportamiento con los datos de salida, para observar el comportamiento de los datos recabados en la etapa uno de esta investigación, se elaboraron redes neuronales artificiales, en primer lugar se introdujeron al software Neural tools 5.5 para observar su comportamiento y hacer una exploración inicial de los resultados, posteriormente se analizaron las bases de datos por medio del software Matlab, en el siguiente apartado se describe el procedimiento llevado a cabo para el entrenamiento y predicción de las redes en el software Matlab.

4.4.2.1 Desarrollo de redes neuronales artificiales para la predicción de producción de biogás, metano CH_4 y remoción con el software Matlab

En este trabajo se desarrollaron redes neuronales artificiales (RNA) para realizar predicciones sobre las variables que impactan en el proceso de digestión anaerobia mesofílica, a partir de los parámetros de operación de 5 variables que actúan en el sistema de producción de biogás por medio del proceso de digestión anaerobia, en las red neuronales no se encuentra contempladas las 11 variables de entrada planteadas en los modelos de lógica difusa, las variables que se descartaron de las redes diseñadas, son temperatura, debido a que el proceso llevado a cabo en el laboratorio fue con un valor controlado a una temperatura constante de 32°C , para el caso de inhibidores y microorganismos, son variables en las que no se cuenta con bases de datos robustas para hacer la aplicación de redes neuronales artificiales de forma positiva.

En la Tabla 4.15, se puede observar la descripción de las variables de entrada y salida consideradas en la red neuronal.

Tabla 4.15 Variables de entrada y salida de la RNA para el proceso de digestión anaerobia con pre-hidrolisis térmica.

Variables	Definición
Tiempo de operación	Días de operación y monitoreo de las cinéticas, dependiendo las cargas volumétricas de los reactores y la operación del proceso.
Ph	Coefficiente que indica el grado de acidez o basicidad de una solución acuosa.
Carga	Se expresa típicamente como peso de materia orgánica expresada en concentración de Sólidos Volátiles o Demanda Química de Oxígeno (DQO) por unidad de volumen del reactor por día. Representa la medida exacta de alimento que un digester necesita.
Sólidos Volátiles	Es un indicador de materia orgánica expresada en concentración de Sólidos Volátiles.
Sólidos totales	Los Sólidos Totales se definen como el material residual después de evaporación y secado de una muestra a cierta temperatura.
Biogás	Es una mezcla gaseosa que se obtiene de la descomposición de la materia orgánica en condiciones anaeróbicas.
Metano	Es un componente del biogás, derivador de la descomposición de la materia orgánica.
Remoción	Descomposición de la materia orgánica para su conversión en biogás.

Los pasos para programar una red neuronal son: diseño de la arquitectura, entrenamiento, validación y prueba. El diseño de una neurona artificial se representa en la Figura 4.5. La red está definida por elementos de entrada, por la multiplicación y suma de los pesos sinápticos y las bias (sesgo), por una función de transferencia y por los elementos de salida.

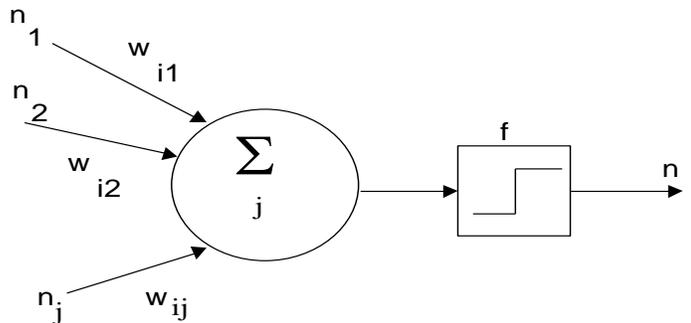


Figura 4.5 Arquitectura de una neurona artificial

Este trabajo de investigación utiliza una RNA de alimentación hacia delante con entrenamiento de retropropagación programada en Neural Network de Matlab. El diseño de la RNA es de tipo perceptrón multicapa, y se caracteriza porque las neuronas están organizadas en capas y sus conexiones entre ellas se orientan estrictamente hacia una sola dirección de una capa a otra. El diseño de una red neuronal artificial se representa en la Figura 4.6.

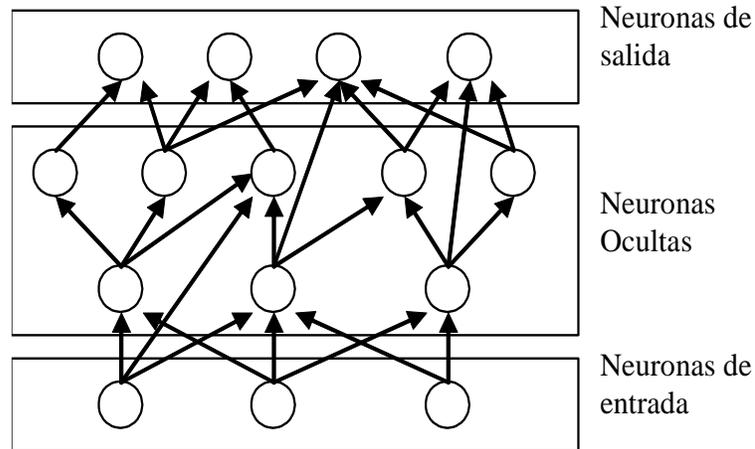


Figura 4.6 Red de alimentación hacia delante (Feed Forward).

La expresión matemática utilizada en la neurona artificial se indica en la Ecuación. (8).

Ecuación. 4.5 expresión matemática utilizada en la neurona artificial

$$y_j = f \left[\sum_{i=0}^n w_{ji} x_i + b \right]$$

Donde (x_i) son los valores de entrada, (w_{ji}) son los coeficientes de los pesos de la neurona j , (b) es bias, que es considerado un valor de sesgo que permite ajustar los pesos de la neurona para lograr un error mínimo de salida, (y) son los valores de salida, y (f) es la función de transferencia sigmoide. Los pesos de los datos de entrada son seleccionados de manera aleatoria, en un rango normalizado entre $[-1,1]$, para lograrlo se utiliza la función de

MAPMINMAX de Matlab para normalizar el valor mínimo y máximo de cada elemento de entrada y salida. La expresión matemática de la función Sigmoide se indica en la Ecuación (9).

Ecuación 4.6 Función Sigmoide

$$f(z) = \frac{1}{1+e^{-z}}$$

Los algoritmos de entrenamiento para una red neuronal son Levenberg-Marquardt, regularización Bayesiana, BFGS Quasi-Newton donde “BFGS” quiere decir Broyden, Fletcher, Goldfarb, and Shanno, de retropropagación elástica, *batch* con reglas de aprendizaje de pesos y sesgos, de retropropagación de gradiente conjugado Powell - Belae, Fletcher - Powell, Polak - Rubiere, escalado, de retropropagación de gradiente descendente, con tasa de aprendizaje adaptativa, con momento, de retropropagación secante de un solo paso, incremental de actualización de orden aleatorio, de orden secuencial, y de orden cíclico.

Cons

iderando esta recomendación se programa la RNA con el algoritmo Levenberg-Marquardt, utilizando la función de entrenamiento TRAINLM. Se utiliza la función de aprendizaje de adaptación LEARNGDM, la función de desempeño MSE que expresa el error cuadrático medio y se definen dos capas ocultas, en la primera utiliza 20 neuronas y un bias, en la segunda capa solo una neurona y un bias.

4.4.2.2 Red neuronal artificial de digestión anaerobia en lodo con pre-tratamiento térmico

El entrenamiento de la red tiene un error cuadrático medio (MSE) de 0.001 y la raíz del error cuadrático medio (RMSE) es de 0.0312.

La validación se realiza con 60 muestras cuyo resultado fue un MSE de 0.01 y un RMSE de 0.1, el coeficiente de determinación (R²) de predicción de la validación es de 0.99975, la Figura 38 muestra su comportamiento. La prueba se realiza con 60 muestras nuevas para la

predicción, logrando un MSE de 0.01 y un RMSE de 0.1, el coeficiente de determinación (R²) de predicción de la prueba es 0.99756, (Figura 4.7).

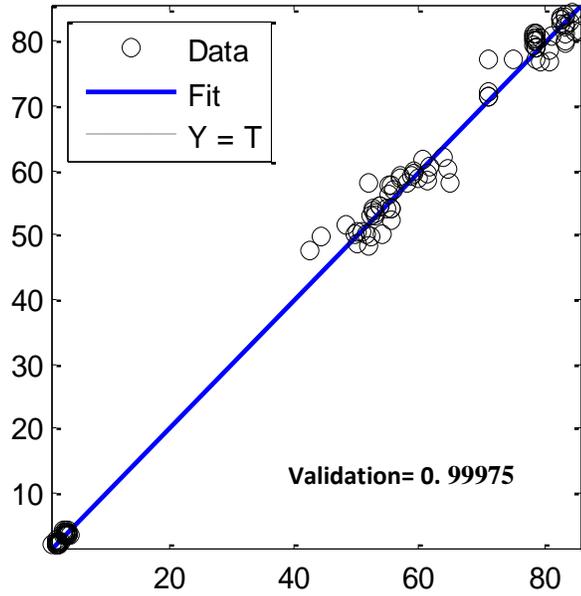


Figura 4.7 Correlación de la validación de la etapa de entrenamiento de la red neuronal artificial con 60 casos.

La capa oculta 1 utiliza pesos sinápticos normalizados de [-1,1], ver Tabla 4.16. Los bias de las capas se aprecian en las Tabla 4.17.

Tabla 4.16 Pesos sinápticos de la capa oculta 1

Capa 1	Neurona	X1	X2	X3	X4	X5
IW,1	{1,1}(1)'=	1.6484	-0.94521	0.27219	0.86143	-1.4567
IW,1	{1,1}(2)'=	1.2383	2.0406	-0.82999	-1.2403	-1.4358
IW,1	{1,1}(3)'=	-1.4436	1.354	1.1616	-0.48846	0.029831
IW,1	{1,1}(4)'=	0.72921	0.85798	1.7474	-1.1964	1.002
IW,1	{1,1}(5)'=	-0.75015	1.4509	1.2825	-0.95191	-0.75443
IW,1	{1,1}(6)'=	-1.3571	-0.67718	2.3576	0.06613	-0.94799
IW,1	{1,1}(7)'=	-1.6156	-0.08349	0.86709	0.80526	0.27613
IW,1	{1,1}(8)'=	0.053823	1.6882	-0.47374	-1.2899	1.0197
IW,1	{1,1}(9)'=	0.8003	0.89221	0.33966	0.27062	0.24125
IW,1	{1,1}(10)'=	0.89461	1.1218	-0.96215	-1.2256	0.61229

Tabla 4.17 Pesos sinápticos de la capa oculta 2

Capa 2 Neuronas A1	Capa 2 Neuronas A1	Capa 2 Neuronas A1
LW{2}	{2,1}(1)'=	-0.19886
LW{2}	{2,1}(2)'=	-0.17373
LW{2}	{2,1}(3)'=	-0.22944
LW{2}	{2,1}(4)'=	0.82369
LW{2}	{2,1}(5)'=	-0.81762
LW{2}	{2,1}(6)'=	0.86057
LW{2}	{2,1}(7)'=	0.14142
LW{2}	{2,1}(8)'=	-0.42341
LW{2}	{2,1}(9)'=	-0.016993
LW{2}	{2,1}(10)'=	-0.67187
LW{2}	{2,1}(11)'=	0.49965
LW{2}	{2,1}(12)'=	-0.5912
LW{2}	{2,1}(13)'=	-0.29419
LW{2}	{2,1}(14)'=	0.42779
LW{2}	{2,1}(15)'=	0.012503
LW{2}	{2,1}(16)'=	-0.33885
LW{2}	{2,1}(17)'=	-0.30176
LW{2}	{2,1}(18)'=	0.86234
LW{2}	{2,1}(19)'=	0.23119
LW{2}	{2,1}(20)'=	-0.57184
LW{2}	{2,1}(21)'=	1.194
LW{2}	{2,1}(22)'=	1.0536
LW{2}	{2,1}(23)'=	0.29118
LW{2}	{2,1}(24)'=	-0.17065
LW{2}	{2,1}(25)'=	1.2502
LW{2}	{2,1}(26)'=	-1.2356
LW{2}	{2,1}(27)'=	1.2773
LW{2}	{2,1}(28)'=	-1.1292
LW{2}	{2,1}(29)'=	0.60315
LW{2}	{2,1}(30)'=	-0.18755

4.4.2.3 Red neuronal artificial de digestión anaerobia en lodo crudo

Para el caso de la RNA de lodo crudo el entrenamiento de la red se desarrolló en una base de datos de 60 registros, con un error cuadrático medio (MSE) de 0.62562 y la raíz del error cuadrático medio (RMSE) es de 0.42562. La validación se realiza con 45 muestras cuyo resultado fue un MSE de 0.041 y un RMSE de 0.1, el coeficiente de determinación (R2) de

predicción de la validación es de 0.9998, la Figura 4.8 muestra su comportamiento. En la tabla 4.18 se observan los pesos sinápticos de la capa oculta 1 y en la Tabla 4.19 se presentan los pesos sinápticos de la capa oculta 2.

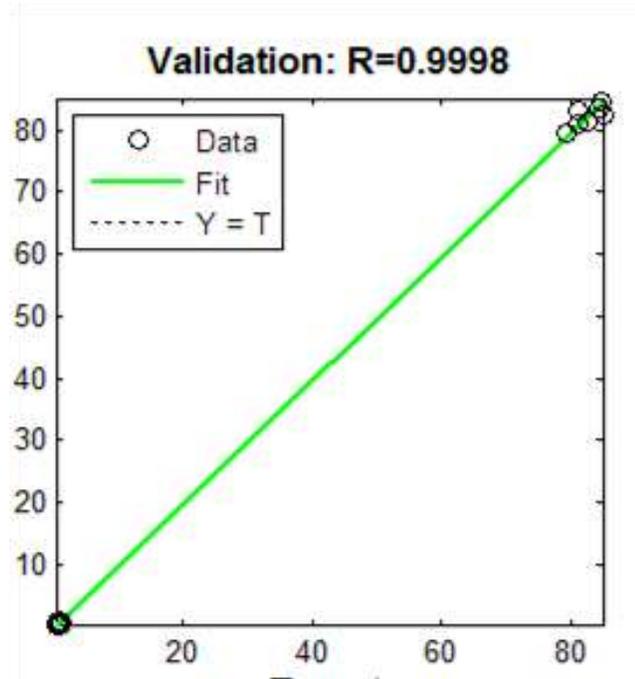


Figura 4.8 Correlación de la validación de la etapa de entrenamiento de la red neuronal artificial de digestión anaerobia en lodo crudo con 45 casos.

Tabla 4.18 Pesos sinápticos de la capa oculta 1

Capa 1	Neurona	X1	X2	X3	X4	X5
IW,1	{1,1}(1)'=	-1.5156	1.0091	0.96369	-0.49792	0.72559
IW,1	{1,1}(2)'=	-0.81509	-1.1126	-2.26	-1.1031	3.1401
IW,1	{1,1}(3)'=	-0.78757	1.2195	-0.26024	-1.8645	-0.68807
IW,1	{1,1}(4)'=	-0.26191	2.8738	-0.17793	-0.2132	-1.4708
IW,1	{1,1}(5)'=	0.14942	2.513	-0.14928	2.6066	-1.4366
IW,1	{1,1}(6)'=	0.22555	2.1922	1.5887	-3.2162	1.2131
IW,1	{1,1}(7)'=	-1.4451	1.306	-0.28263	4.56	0.68652
IW,1	{1,1}(8)'=	0.04723	-0.71011	0.56726	-2.0569	-2.243
IW,1	{1,1}(9)'=	2.4768	-2.27	-0.62076	0.81293	-1.2322
IW,1	{1,1}(10)'	-0.73157	-0.77734	1.7578	0.047298	-0.036726

=

Tabla 4.19 Pesos sinápticos de la capa oculta 2

Capa 1 Neuronas A1	Capa 1 Neuronas A1	Capa 2 Neuronas A1
LW{2}	{2,1}{1}'=	2.6319;
LW{2}	{2,1}{2}'=	2.0022;
LW{2}	{2,1}{3}'=	1.5091;
LW{2}	{2,1}{4}'=	-2.075;
LW{2}	{2,1}{5}'=	1.4951;
LW{2}	{2,1}{6}'=	-0.59254;
LW{2}	{2,1}{7}'=	0.47308;
LW{2}	{2,1}{8}'=	0.58215;
LW{2}	{2,1}{9}'=	2.8373;
LW{2}	{2,1}{10}'=	-2.5581
LW{2}	{2,1}{30}'=	-0.18755

4.4.2.4 Red neuronal artificial de digestión anaerobia en lodo con pre-tratamiento ácido

La validación se realiza con 60 muestras cuyo resultado fue un MSE de 0.01 y un RMSE de 0.1, el coeficiente de determinación (R²) de predicción de la validación es de 0.969975, la Figura 4.9 muestra su comportamiento.

El entrenamiento de la red tiene un error cuadrático medio (MSE) de 0.001 y la raíz del error cuadrático medio (RMSE) es de 0.0316.

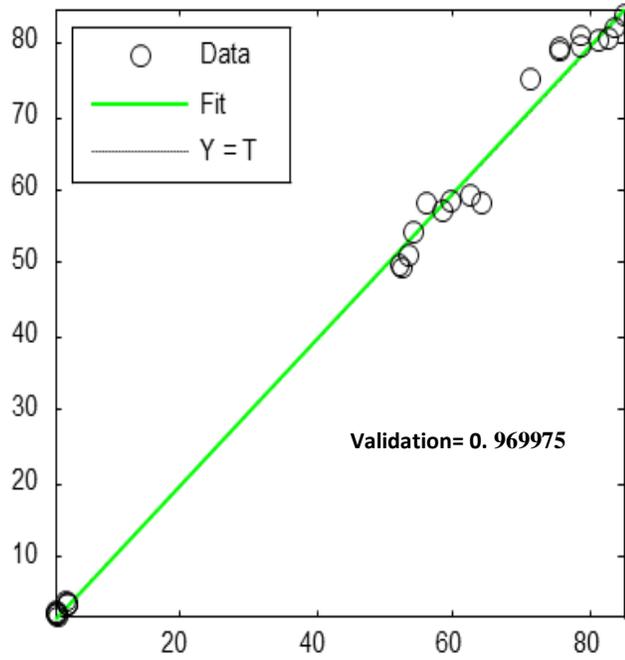


Figura 4.9 Correlación de la validación de la etapa de entrenamiento de la red neuronal artificial con 60 casos.

La capa oculta 1 utiliza pesos sinápticos normalizados de [-1,1], ver Tabla 4.20.

Los bias de las capas se aprecian en la Tabla 4.21

Tabla 4.20 Pesos sinápticos de la capa oculta 1

Capa 1	Neurona	X1	X2	X3	X4	X5
IW,1	{1,1}(1) ^o =	1.484	0.94521	0.219	0.86143	1.4567
IW,1	{1,1}(2) ^o =	1.383	2.0406	-0.299	-1.2403	-1.4358
IW,1	{1,1}(3) ^o =	-1.236	1.354	1.1616	-0.48846	1.2831
IW,1	{1,1}(4) ^o =	0.7921	0.85798	-1.44	-1.1964	1.602
IW,1	{1,1}(5) ^o =	0.75015	-1.4509	1.25	-0.95191	-0.75443
IW,1	{1,1}(6) ^o =	1.3571	0.67718	-1.3576	0.06613	0.94799
IW,1	{1,1}(7) ^o =	1.6156	0.08349	0.86709	0.80526	1.1763
IW,1	{1,1}(8) ^o =	0.053823	1.6882	-0.47374	-1.2899	-1.0117
IW,1	{1,1}(9) ^o =	-0.8003	-0.89221	0.33966	0.27062	1.2415
IW,1	{1,1}(10) ^o =	0.89461	-1.1218	-0.96215	-1.2256	0.3329

Tabla 4.21 Pesos sinápticos de la capa oculta 2

Capa 2 Neuronas A1	Capa 2 Neuronas A1	Capa 2 Neuronas A1
LW{2}	{2,1}(1)'=	0.19886
LW{2}	{2,1}(2)'=	1.7313
LW{2}	{2,1}(3)'=	-0.22944
LW{2}	{2,1}(4)'=	0.12369
LW{2}	{2,1}(5)'=	-0.11762
LW{2}	{2,1}(6)'=	0.86057
LW{2}	{2,1}(7)'=	1.11142
LW{2}	{2,1}(8)'=	-0.19341
LW{2}	{2,1}(9)'=	0.21693
LW{2}	{2,1}(10)'=	-0.47127
LW{2}	{2,1}(11)'=	0.45965
LW{2}	{2,1}(12)'=	-1.15912
LW{2}	{2,1}(13)'=	0.5419
LW{2}	{2,1}(14)'=	-0.779
LW{2}	{2,1}(15)'=	0.012503
LW{2}	{2,1}(16)'=	-0.33885
LW{2}	{2,1}(17)'=	-0.30176
LW{2}	{2,1}(18)'=	0.86234
LW{2}	{2,1}(19)'=	0.23119
LW{2}	{2,1}(20)'=	-0.57184
LW{2}	{2,1}(21)'=	1.194
LW{2}	{2,1}(22)'=	1.0536
LW{2}	{2,1}(23)'=	-0.92118
LW{2}	{2,1}(24)'=	-0.13445
LW{2}	{2,1}(25)'=	-1.1402
LW{2}	{2,1}(26)'=	-1.2356
LW{2}	{2,1}(27)'=	1.1573
LW{2}	{2,1}(28)'=	-1.1332
LW{2}	{2,1}(29)'=	0.94315
LW{2}	{2,1}(30)'=	0.27755

4.4.2.5 Red neuronal artificial de digestión anaerobia en modo enzimático

Por último se presenta la red neuronal diseñada para el grupo de datos de digestión anaerobia en lodo enzimático, para la cual se estiman las mismas 5 variables consideradas en las redes neuronales artificiales anteriores.

Para la red neuronal artificial se considera una base de 60 datos que son parte del monitoreo y registros históricos del proceso de operación de reactores de tratamientos de lodo residuales por medio de digestión anaerobia mesofílica con pre tratamiento enzimático.

Se seleccionaron las 5 variables de entrada anteriormente mencionadas, que afectan las variables de salida Biogás y Metano.

El entrenamiento de la red tiene un error cuadrático medio (MSE) de 0.0022 y la raíz del error cuadrático medio (RMSE) es de 0.043787 La validación se realiza con 45 muestras cuyo resultado fue un MSE de 0.0001 y un RMSE de 0.0013, el coeficiente de determinación (R^2) de predicción de la validación es de 0.99942, la Figura 4.10 muestra su comportamiento.

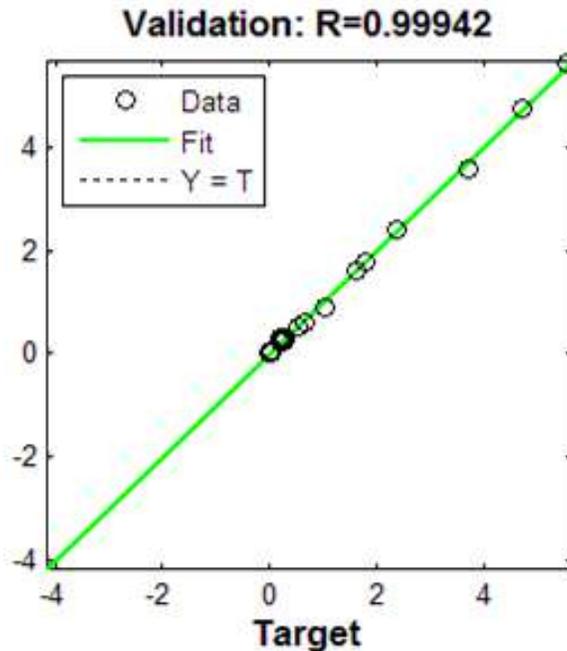


Figura 4.10 Correlación de la validación de la etapa de entrenamiento de la red neuronal artificial de digestión anaerobia en lodo con pretratamiento enzimático con 45.

La capa oculta 1 utiliza pesos sinápticos normalizados de $[-1,1]$, ver Tabla 4.22.

Las bias de las capas se aprecian en las Tablas 4.23 y 4.24.

Tabla 4.22 Pesos sinápticos de la capa oculta 1

Capa 1	Neurona	X1	X2	X3	X4	X5
IW,1	{1,1}(1)'=	1.5671	-1.13	1.5023	0.88354	-2.8023
IW,1	{1,1}(2)'=	-0.0391	-1.1206	-0.0141	0.15757	1.2484
IW,1	{1,1}(3)'=	-0.13848	-0.24061	-0.0863	-1.492	2.0608
IW,1	{1,1}(4)'=	-0.00086	0.46839	-0.04408	1 1.3857	-2.4968
IW,1	{1,1}(5)'=	3.1825	1.2616	1.4188	0.43918	0.0051162
IW,1	{1,1}(6)'=	-0.34179	-1.2142	-2.5342	0.31016	-0.28594
IW,1	{1,1}(7)'=	-3.5727	-0.08349	0.86709	0.80526	0.27613
IW,1	{1,1}(8)'=	4.5545	0.042113	-0.50653	-0.58705	0.51396
IW,1	{1,1}(9)'=	-3.6134	-1.1013	2.0581	0.066476	2.8872
IW,1	{1,1}(10)'=	3.5048	2.4513	-0.33003	0.23351	4.2489

Tabla 4.23 Bias de la capa oculta 1

Bias	Neuronas	b {1}
b{1}	{1,1}(1)'=	-5.6008;
b{1}	{1,1}(2)'=	2.2021;
b{1}	{1,1}(3)'=	2.6471;
b{1}	{1,1}(4)'=	3.4556;
b{1}	{1,1}(5)'=	0.53437;
b{1}	{1,1}(6)'=	3.3777;
b{1}	{1,1}(7)'=	-1.1574;
b{1}	{1,1}(8)'=	-0.078463;
b{1}	{1,1}(9)'=	0.041322;
b{1}	{1,1}(10)'=	-0.45651

Tabla 4.24 Bias de la capa oculta 2

Bias	Neuronas	b {2}
b{1}	{1,1}(1)'=	1.0383
b{1}	{1,1}(2)'=	-0.20865
b{1}	{1,1}(3)'=	1.1864

4.5 Etapa 4: Optimización del proceso de digestión anaerobia

Después de la fase de desarrollo de modelos de lógica difusa para la predicción de patrones de comportamiento, y las redes neuronales artificiales que permitieron estimar el porcentaje de impacto de cada variables de entrada y salida, se desarrollaron modelos mtaemáticos que fueron optimizados por algoritmos genéticos para la incrementar los rendimientos en la producción de biogás, metano y remoción.

4.5.1 Optimización multicriterio del proceso de digestión anaerobia mesofílica mediante algoritmos genéticos

Se desarrollaron modelos matemáticos que se optimizaron por medio de algoritmos genéticos en matlab, durante los meses de Junio a Agosto se trabajó en la optimización de los resultados obtenidos por los modelos de lógica difusa utilizando la herramienta gatoolbox.

Matlab ofrece diversas ventajas en el manejo de algoritmos genéticos, considerando que ya se tienen los modelos de lógica difusa programados en Matlab al igual que las Redes neuronales artificiales, se decidió la utilización de este mismo software para la implementación de los algoritmos genéticos, a continuación se presentan pantallas de la programación realizada y los resultados obtenidos.

Para hacer el algoritmo genético en Matlab, es necesario considerar los modelos de lógica difusa desarrollada previamente, partiendo de los modelos de lógica difusa y de cada conjunto difuso se lleva a cabo la función objetivo, cargando el modelo del cual se definirán las restricciones y los valores a optimizar.

4.5.1.1 Modelación matemática

Para poder desarrollar las optimizaciones multicriterio, fue necesario iniciar con la optimización de un solo criterio, que fueron de utilidad para hacer una exploración de la optimización del proceso, para fines del presente trabajo se presentan los modelos matemáticos realizados y utilizados en la modelación multicriterio.

Para el modelo matemático en producción de biogás con lodo pre-tratado térmicamente se definió la ecuación 10 y 11.

Ecuación 4.7 Modelo matemático.

$$B_{LP} = \left(\frac{b_1 + b_2 \dots b_n}{n} \right) * (Bac_{lp} * P_t * Op)$$

B_{LP} : Cantidad de biogás esperada en lodo con pre-tratamiento térmico (ml)

b_n : Es la cantidad de biogás generada con respecto a las variables de entrada

n : Cantidad de variables de entrada

Op : Modo de operación del proceso de digestión anaerobia.

P_t : Porcentaje de optimización del rendimiento del pre-tratamiento.

Bac_{lp} =Porcentaje de producción de biogás esperada en relación a la bacterias anaerobias.

El coeficiente Bac_{lp} se obtiene:

$((H + A)(0.25)) / 100 = \% \text{ de rendimiento de Biogás en relación a las bacterias hidrolíticas}$

$((Ac)(0.25)) / 100 = \% \text{ de rendimiento de Biogás en relación a las bacterias acetogénicas.}$

$((Me)(0.25)) / 100 = \% \text{ de rendimiento de Biogás en relación a las bacterias metanogénicas.}$

Donde:

H = Porcentaje de concentración de bacterias *Hidrolíticas*

A = Porcentaje de concentración de bacterias *Acidogénicas*

Ac = Porcentaje de concentración de bacterias *Acetogénicas*

Me = Porcentaje de concentración de bacterias *Metanogénicas*

Ecuación 4.8 Función objetivo.

$$\text{Max } B_{LP} = \text{Max} \left(\frac{x_1 + x_2 \dots x_n}{n} \right) * (Bac_{lp} * P_t * Op)$$

X₁: Sólidos totales

X₂: Temperatura (°C)

*X₃ Carga Orgánica (Kg SV/L*d)*

X₄: Tiempo de operación

X₅: pH

X₆: Sólidos volátiles

X₇: Inhibidores

X₈: Bacterias hidrolíticas

X₉: Bacterias acidogénicas

X₁₀: Bacterias acetogénicas

X₁₁: Bacterias metanogénicas

4.5.1.2 Restricciones

El modelo contempla ciertas restricciones para limitar y precisar el comportamiento de las variables, de forma tal que permita una mejor aproximación del algoritmo genético. Las restricciones para las variables x1.....x11 se asignaron los valores mínimos y máximos que pueden alcanzar las variables dentro del proceso. Las restricciones son consideradas de acuerdo al proceso de operación en los digeridos con digestión anaerobia. Es necesario mencionar que las restricciones son iguales en los 8 modelos propuestos.

ST	X1	\geq	0
	X1	\leq	5
CARGA	X2	\geq	1
	X2	\leq	3
SV	X3	\geq	0
	X3	\leq	90
TIEMPO	X4	\geq	20
	X4	\leq	50
Ph	X5	\geq	5
	X5	\leq	10
REMOCION	X6	\geq	38
	X6	\leq	70
INHIBIDORES	X7	\geq	0
	X7	\leq	7
HIDROLITICAS	X8	\geq	0
	X8	\leq	100
ACIDOGÉNICAS	X9	\geq	0
	X9	\leq	100
ACETOGÉNICAS	X10	\geq	0
	X10	\leq	100
METANOGÉNICAS	X11	\geq	0
	X11	\leq	100

4.5.1.3 Optimización Multicriterio

Para el desarrollo de los modelos optimizados por algoritmos genéticos se manejó el software Matlab, para ello fue necesario programar la función objetivo en código Matlab, para posteriormente llamarla desde la herramienta, gatoolbox, que permite optimizar modelos

multicriterio, para este caso se optimizaron las tres variables de salida, biogás, metano y remoción, para ello se consideró y configuró el sistema con una población inicial aleatoria en doble con una distribución uniforme, seleccionando la opción doble vector, en la cual se realiza e cruzamiento por medio del método torneo seleccionando cada padre y eligiendo personas al azar, cuyo número puede especificar por torneo de tamaño y, a continuación se elige el mejor individuo para ser un padre, posteriormente la mutación se lleva a cabo por medio del método de mutación gaussiana que se desarrolla a través de vectores por cada individuo. Este número aleatorio es tomado de una distribución gaussiana centrada en cero.

La función GA multiobjective gamultiobj utiliza un algoritmo genético elitista controlada (una variante del NSGA II). Un elitista GA siempre favorece a los individuos con mejor valor de optimización (ranking). En la tabla 4.25, se muestran los parámetros de operación del algoritmo genético.

Tabla 4.25 Parámetro del algoritmo genético.

Parámetro	Valor
Tasa de mutación	0.1
Tasa de cruzamiento	0.5
Población inicial	1000
Número de generaciones (iteraciones)	1000
Tiempo de optimización	4000 simulaciones
Tiempo de simulación	Convergencia Actual, en cada simulación cada generación debe cumplir con todas las restricciones.
Tiempo de optimización	20 minutos.

4.6 Etapa 5: Desarrollo del sistema de apoyo a la decisión.

La última etapa consistió en el diseño y programación del sistema de apoyo a la decisión, el sistema fue desarrollado en el software Matlab 2014, con la finalidad de darle continuidad a las herramientas desarrolladas en las etapas dos, tres y cuatro.

4.6.1 Desarrollo de un sistema de apoyo a la toma de decisiones

El desarrollo del sistema de apoyo a la decisión que concentra todas las herramientas empleadas para la predicción y optimización del proceso de digestión anaerobia mesofílica. El sistema se compone de una pantalla de inicio de sesión que controla el acceso al sistema para mantener cuestiones de seguridad, en la Figura 4.11 se presenta observa la pantalla de inicio de sesión del sistema.

En la Figura 4.11 se presenta la primera propuesta de pantalla de menú para la selección de la herramienta de predicción para el usuario.

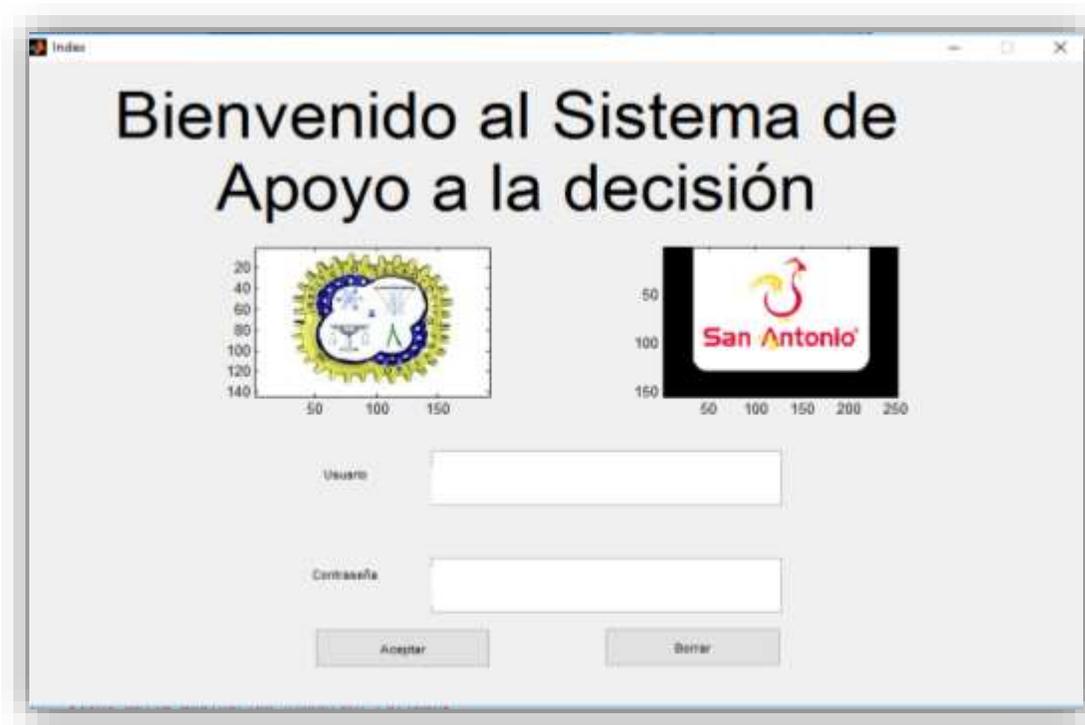


Figura 4.11 Pantalla de inicio de sesión del sistema de apoyo a la decisión.

La pantalla principal del sistema de apoyo se compone en la parte superior de una lista desplegable que permite seleccionar el modelo de lógica difusa o red neuronal que se desea seleccionar para hacer la predicción, en la parte inferior se encuentran 11 cajas de texto que

permiten ingresar los datos de las 11 variables de entrada que se consideran en los modelos, a la derecha se observa tres cajas de texto para visualizar los resultados en el momento de pulsar la tecla calcular, en la Figura 4.12 un ejemplo de una corrida de simulación incluyendo los datos de entrada y datos de salida.

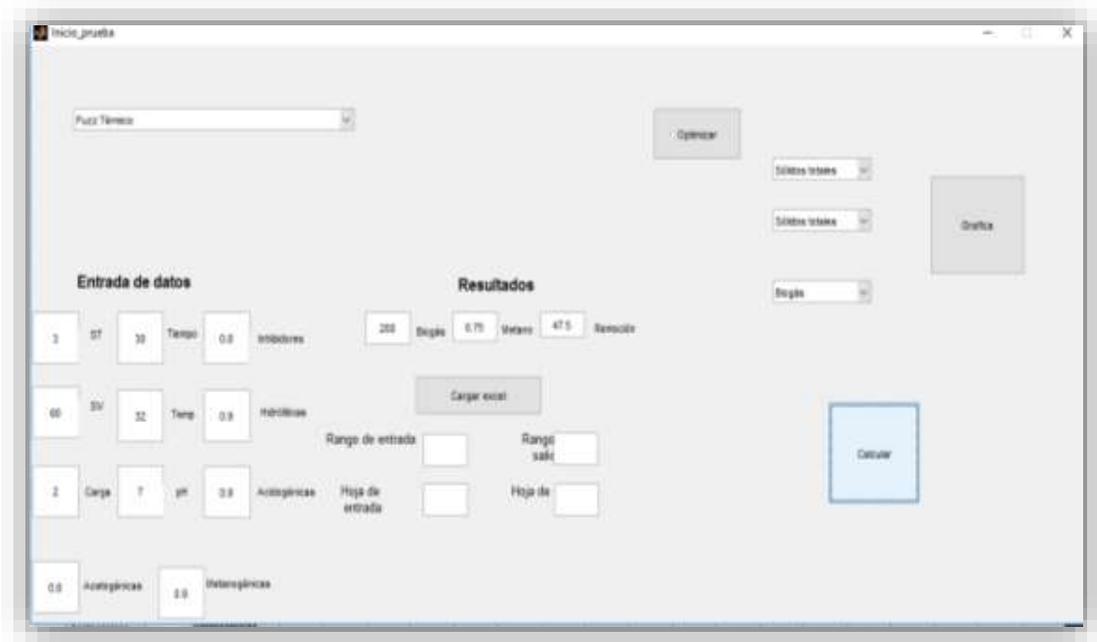


Figura 4.12 Pantalla principal del sistema de apoyo a la decisión.

El sistema cuenta con un apartado para observar los gráficos de superficies de respuesta de los modelos de lógica difusa, en este apartado se cuenta con unas listas de selección de las variables que se desean seleccionar para presentar los gráficos, (Ver Figura 4.13).

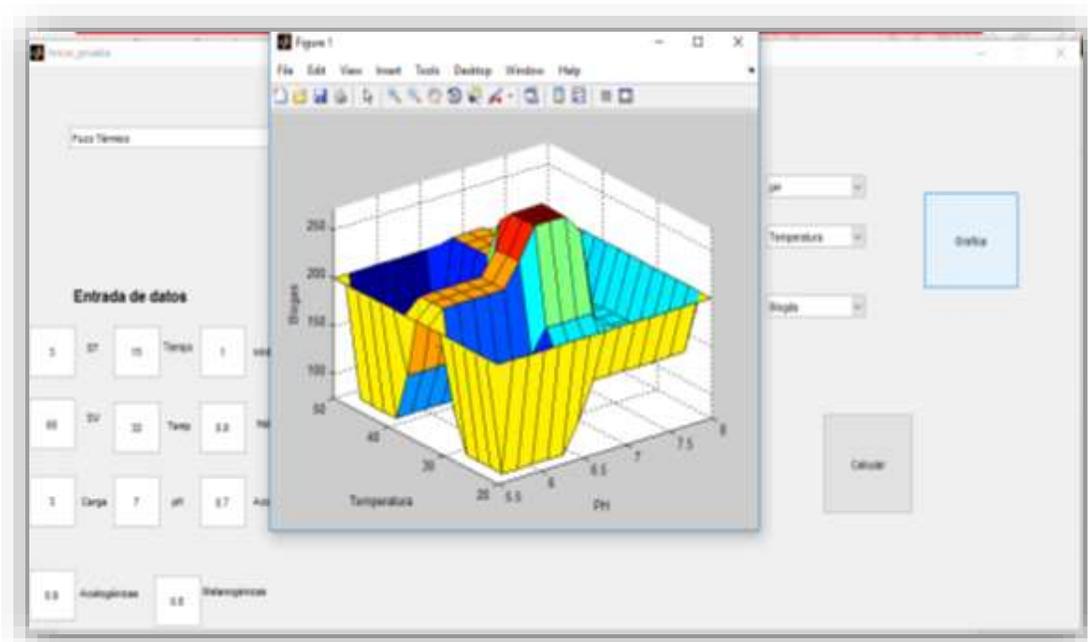


Figura 4.13 Pantalla de opciones y presentación de gráficos de superficies de respuesta.

Se puede seleccionar la opción de redes neuronales artificiales para las predicciones para ello se pueden mantener los datos capturados para simular por lógica difusa, si se pretende hacer una simulación por ambas herramientas, pero también se puede hacer un borrado y una recaptura de datos.

En la Figura 4.14 se presenta un ejemplo de simulación utilizando redes neuronales artificiales.

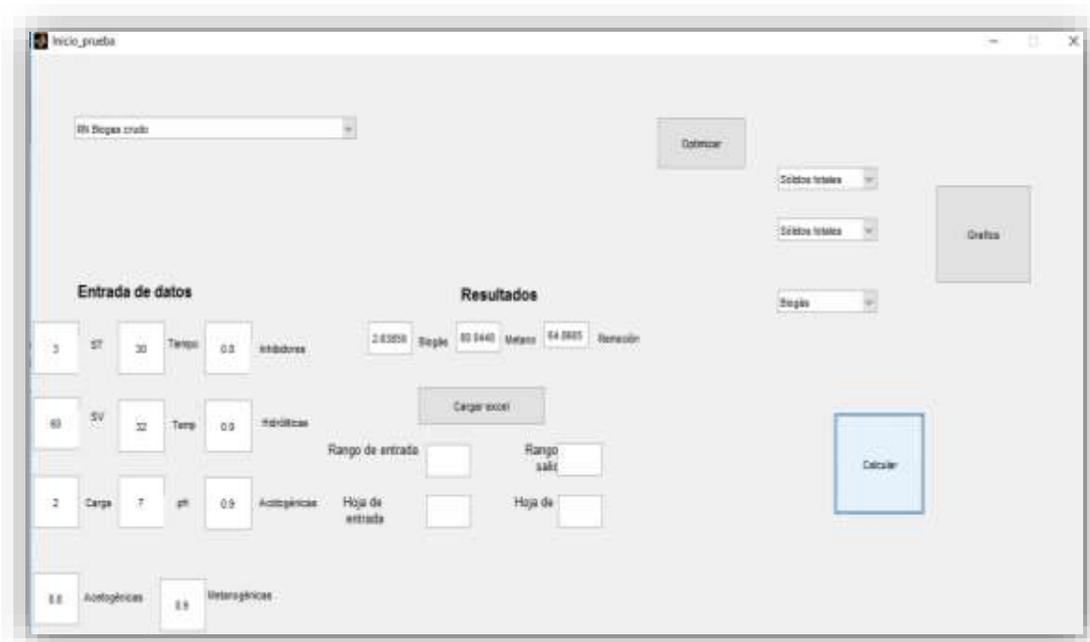


Figura 4.14 Pantalla de predicción por redes neuronales artificiales.

En la pantalla principal también se incluye una opción para hacer la simulación con archivo de datos capturados en hoja de cálculo, para facilitar el trabajo cuando se trata de hacer la predicción para una serie de datos, para ello se encuentra en la parte inferior derecha un apartado para hacer la carga y simulación de hoja de datos, para ello es necesario proporcionar los rangos de filas y columnas de los datos de entrada y los rangos de columnas y filas para los datos de salida (Ver Figura 4.15).

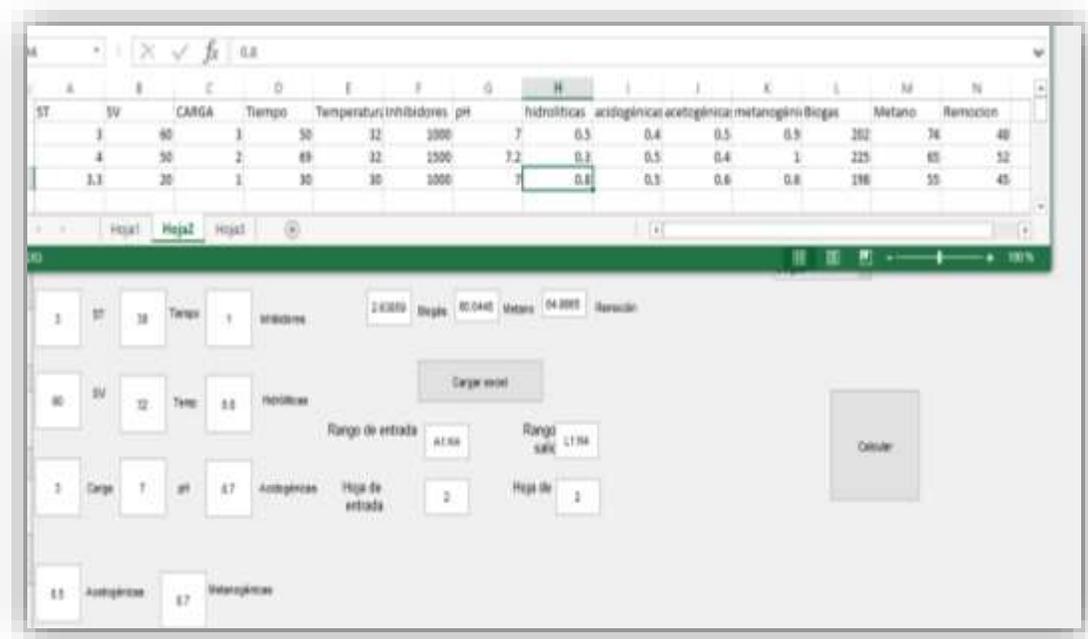


Figura 4.15 Pantalla de simulación con carga de datos desde hoja de cálculo.

Por último en la Figura 4.16 se presenta la pantalla de optimización por medio de algoritmos genéticos, en dicha pantalla se observa que ya se tiene pre-programada la función objetivo, para lo cual el usuario, debe seleccionar los parámetros de cruzamiento, generaciones estimadas, el tipo de torneo para la selección de los padres, considerando los aspectos de optimización para el algoritmo genético multicriterio.

En otro apartado se selecciona la presentación de los datos, estos pueden ser arrojados en tablas, que presentan los parámetros y criterios del algoritmo genético y los valores optimizados de cada variable programada en el algoritmo genético multicriterio.

Es muy importante registrar las restricciones de cada uno de las variables de entrada que intervienen en el modelo matemático, debido a que es necesario determinar los rangos mínimos y máximos que se obtienen de los modelos de lógica difusa.

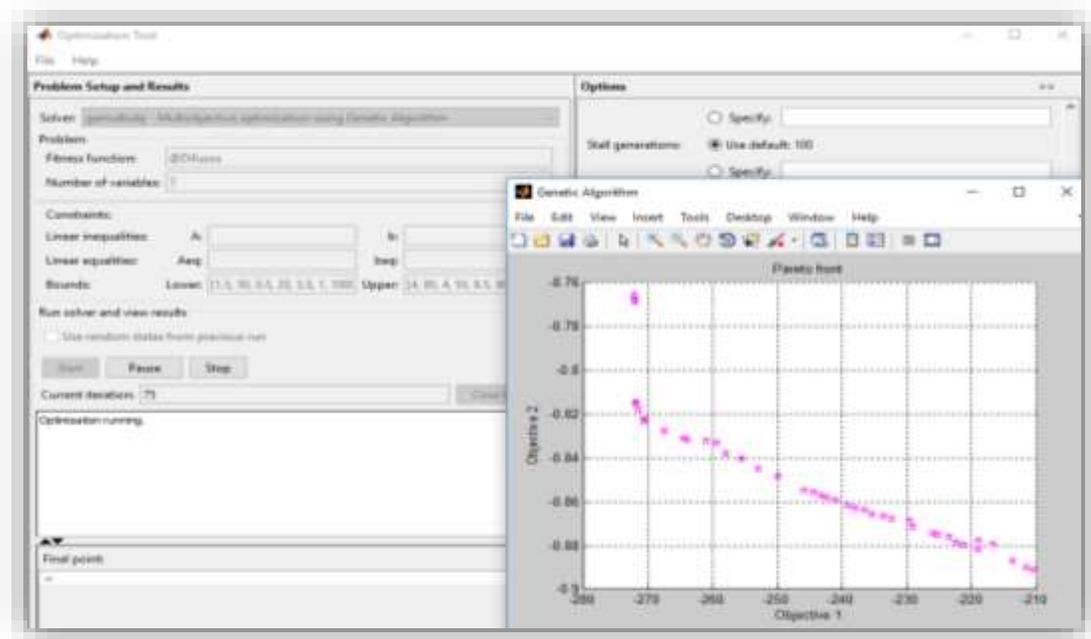


Figura 4.16 Pantalla de optimización.

4.7 Conclusión del Capítulo

En este capítulo se presenta el diseño de la metodología propuesta que contribuye al desarrollo del sistema experto de apoyo a la decisión. La primera parte consistió en la recolección de las bases de datos, para ello se llevaron cabo diversas pruebas de laboratorio, en el laboratorio de ambiental. Posteriormente se analizaron el comportamiento de las variables para estimar los parámetros de control del proceso y así lograr definir un patrón de comportamiento de las variables, para ello se utilizaron lógica difusa y redes neuronales artificiales. De las técnicas de inteligencia artificial se obtuvieron las superficies de respuesta del proceso, así como predicciones de los resultados a obtener.

Se analizaron las superficies de respuesta obtenidas de la Lógica Difusa, para que a partir de ellas se diseñaran geoméricamente los modelos matemáticos multicriterio para realizar la optimización del proceso por medio de algoritmos genéticos, para finalizar se desarrolló el sistema experto, que integra los resultados de las diferentes técnicas de inteligencia artificial realizadas.

Capítulo V

RESULTADOS

Capítulo V. Resultados

5.1 Introducción del Capítulo

El desarrollo del sistema experto de apoyo a la decisión está integrado por un conjunto de resultados obtenidos de cada una de las técnicas de inteligencia artificial implementadas. En el capítulo cinco se presenta un resumen de los principales resultados obtenidos, iniciando por los resultados obtenidos en las pruebas llevadas a cabo en el laboratorio de ambiental.

Del desarrollo de los modelos de lógica difusa se obtuvieron superficies de respuesta que permitieron hacer un análisis de los patrones de comportamiento del proceso de digestión anaerobia con los pretratamientos abordados, también se presentan las predicciones de los rendimientos obtenidas por el desarrollo de redes neuronales artificiales.

Posteriormente se desarrollaron escenarios de optimización del proceso en sus diferentes pretratamientos, se emplearon algoritmos genéticos para obtener los resultados óptimos de las bases de datos empleadas durante la investigación.

El conjunto de resultados obtenidos por cada una de las técnicas implementadas se concentran en el sistema experto de apoyo a la decisión, el cual cuenta con un módulo para la determinación de patrones a través de lógica difusa y redes neuronales, para ello, es necesario incluir datos de entrada al proceso, también cuenta con un apartado para la optimización de los datos ingresados.

5.2 Resultados de la caracterización de lodos residuales

La caracterización fisicoquímica y microbiológica de los LR se llevó a cabo en base a la NOM-004 SEMARNAT 2002 y a las técnicas analíticas mencionadas en la tabla 5.1, dentro de los parámetros que se determinaron se puede observar que para ambos sustratos el pH es cercano al neutro, este parámetro favorece el proceso de digestión anaerobia, sin embargo el contenido

de sólidos totales de 1.56 % en el lodo residual es muy bajo por lo que fue necesario concentrarlo para utilizarlo.

Tabla 5.1 Caracterización de los lodos residuales

Físicos	Lodos	Unidad
pH	6.89±0.2	
Temperatura	23±2	°C
Sólidos Totales	1.56±0.5	% m/m
Sólidos Totales Volátiles	70.43±6.23	% m/m
Químicos	Lodos	Unidad
Nitrógeno Total	6.5±0.42	g N-NT /kg ST
Nitrógeno Amoniacal	4.9±0.54	g N-NH ₃ /kg ST
Fósforo	25±4.82	ppm
Relación de Alcalinidad	0.22±.05	Alc. 5.75 / Alc 4.3

5.3 Evaluación de la pre-hidrólisis térmica en la solubilización de la materia orgánica

La Figura 5.1 muestra la evolución de los sólidos volátiles durante las pruebas de digestión anaerobia por lote. Una remoción del 38% de los sólidos volátiles fue usada como criterio operacional para cumplir con los requerimientos de atracción de vectores (US-EPA, 1993) y para la estabilización de lodo crudo y pre-hidrolizado. La Figura 5.1 muestra que 27 días de tratamiento fueron requeridos para alcanzar el criterio operación en el lodo crudo. Solo 13 días fueron necesarios para remover el 38% de la concentración inicial de sólidos volátiles en la digestión anaerobia de lodos tratados térmicamente. Es claro que el tratamiento térmico aplicado al lodo reduce el tiempo de digestión para alcanzar niveles similares de estabilización de lodo.

Como se muestra en la Figura 5.2, el pre-tratamiento térmico aplicado tuvo un efecto positivo en la producción diaria de biogás y metano en las pruebas por lote, resultando en un rendimiento de biogás y metano para el lodo crudo de $0.66 \text{ L}_{\text{biogás}} \text{ g}^{-1} \text{ SV}_{\text{rem}}$ y $0.53 \text{ L}_{\text{CH}_4} \text{ g}^{-1} \text{ SV}_{\text{rem}}$, respectivamente. Esos rendimientos son bajos comparados con aquellos obtenidos durante las pruebas con lodo tratado térmicamente ($Y_{\text{biogás}} = 1.0 \text{ L}_{\text{biogás}} \text{ g}^{-1} \text{ SV}_{\text{rem}}$ y $Y_{\text{CH}_4} = 0.81 \text{ L}_{\text{CH}_4} \text{ g}^{-1} \text{ SV}_{\text{rem}}$). Estos resultados muestran que el proceso con lodo pre-tratado térmicamente fue más eficiente para los rendimientos de biogás y metano. Una rápida asimilación de la

materia orgánica en su forma soluble inducida por el pre-tratamiento térmico resultó en un incremento del 52% en la producción de metano Figura 5.3.

En estudios previos, se obtuvieron porcentajes de 17.81% de grado de solubilización al aplicar un pre-tratamiento térmico de 90°C durante 60 minutos a lodos activados (Appels et al.,2010). Por otra parte Kim et al., (2003) encontró que aplicando un tratamiento con NaOH (7 g/L) y elevando la temperatura de los mismos (121°C) durante 30 min se logra una solubilización de hasta un 80%. En otros estudios se ha investigado el efecto del pre-tratamiento térmico de lodo primario con temperaturas de 70°C seguido por digestión anaerobia mesofílica y termofílica, obteniendo mejores resultados en producción y rendimiento de biogás al someter el lodo primario a digestión anaerobia termofílica (Gavala et al., 2003).

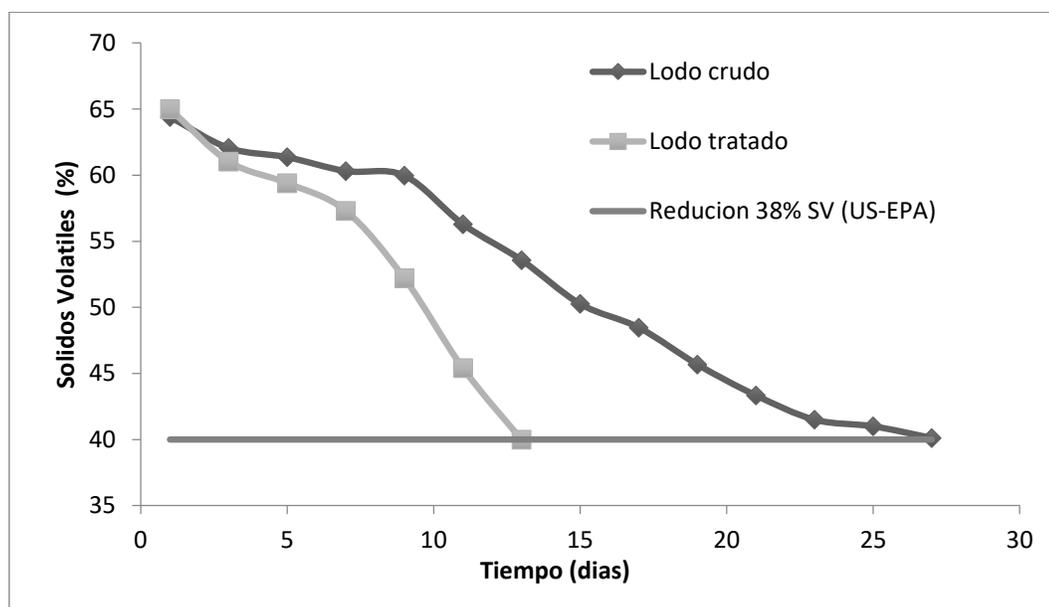


Figura 5.1 Remoción en lodo crudo y pre hidrolizado térmicamente en modo batch.

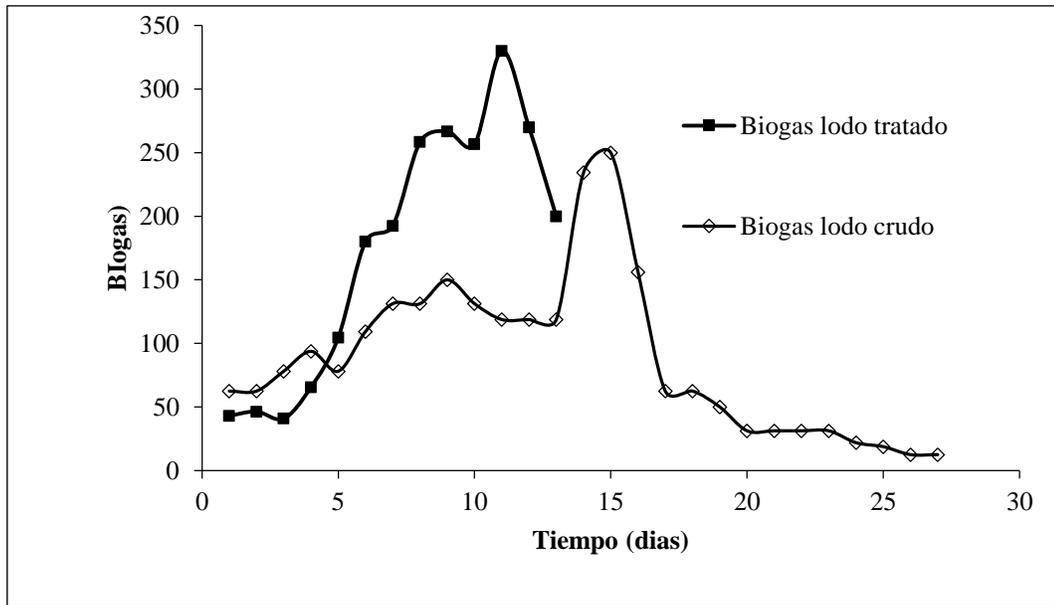


Figura 5.2 Producción de biogás en lodo crudo y pre hidrolizado térmicamente en modo batch.

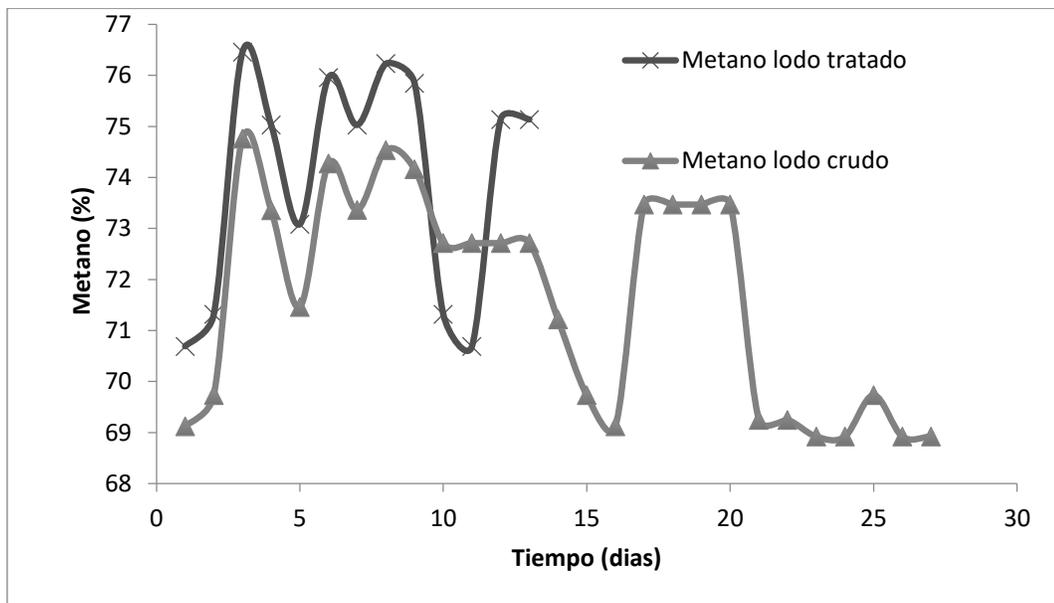


Figura 5.3 Producción de metano CH_4 en lodo crudo y pre hidrolizado térmicamente en modo batch.

5.3.1 Incremento de la carga volumétrica aplicada en la digestión anaerobia de lodo crudo fisicoquímico y con pre-tratamiento térmico

El comportamiento de la remoción de sólidos volátiles y el incremento de la carga volumétrica aplicada (CVA) en alimentación semicontinua durante un tiempo de 90 días de la digestión de lodo crudo y pre-tratado térmicamente es mostrado en la Figura 5.4. En el primer periodo de operación (1-30 d), la cinética 1 fue alimentada con lodo pre-hidrolizado y una CVA inicial relativa de $1 \text{ Kg SV m}^{-3} \text{ d}^{-1}$, mientras que la cinética 2 fue alimentada con lodo crudo sin pre-tratamiento térmico y una CVA inicial baja de $0.5 \text{ Kg SV m}^{-3} \text{ d}^{-1}$, la diferencia en la CVA se basó en los resultados obtenidos durante la primera etapa de este experimento con pruebas por lote. Para esta etapa, un promedio de remoción de sólidos volátiles de 58.81 %, un TRH de 22 d, mientras que 46.68% de remoción de sólidos volátiles, un TRH de 40 para la cinética 2. Durante este período, rendimientos de metano de $Y = 0.82 \text{ L}_{\text{CH}_4} \text{ g}^{-1} \text{ SVrem}$ y $0.5 \text{ L}_{\text{CH}_4} \text{ g}^{-1} \text{ SVrem}$ para la cinética 1 y 2 fueron obtenidos respectivamente (Ver Figuras 5.5 y 5.6).

Un incremento de la CVA a $2 \text{ Kg SV m}^{-3} \text{ d}^{-1}$ y $1 \text{ Kg SV m}^{-3} \text{ d}^{-1}$ para las cinética 1 y 2 respectivamente fueron evaluados en el segundo periodo (31-60 d), mostrando un ligero decremento en la remoción de sólidos volátiles debido a la adaptación a la nueva CVA en ambos sistemas (- 7.03% para la cinética 1 y -4.21 % para la cinética 2). Sin embargo, producto del incremento en la CVA una reducción del 50% en el TRH fue obtenida en ambas cinéticas (22 a 11 d en cinética 1 y 40 a 20 d en la cinética 2), acortando el tiempo para cumplir con el criterio de estabilización de la materia orgánica en este periodo.

En el tercer periodo de este proceso, la cinética 1 fue alimentado con una CVA $3 \text{ Kg SV m}^{-3} \text{ d}^{-1}$ y la cinética 2 con una CVA $1.5 \text{ Kg SV m}^{-3} \text{ d}^{-1}$, en este último incremento de carga la cinética 1 presentó una rápida adaptación. Sin embargo, la eficiencia de remoción presentó un decremento de aproximadamente 9 % en comparación con la eficiencia obtenida en el periodo inicial, esto se debe a que el sistema tuvo un incremento del 200% en la capacidad de tratamiento (CVA) en comparación con los primeros 30 días de operación y del 100% con el segundo periodo (31-60 d).

Adicionalmente, un valor promedio en el rendimiento de metano de $Y = 0.81 \text{ L}_{\text{CH}_4} \text{ g}^{-1} \text{ SV}_{\text{rem}}$ fue obtenido, el cual se mantuvo muy similar al de las cargas anteriores corroborando que el sistema es estable y soporta adecuadamente el incremento en la CVA.

Este rendimiento de metano es muy similar al obtenido por Jolis (2008), quien reporta un rendimiento de metano de entre 0.8 a 1.1 $\text{L}_{\text{CH}_4} \text{ g}^{-1} \text{ SV}_{\text{rem}}$ para lodos municipales que fueron sometidos a pre-hidrólisis térmica de 170 °C durante 25 min, cabe señalar que en el estudio mencionado la temperatura utilizada es casi el doble de la recomendada en la presente investigación (90 °C). (Ver Figura 5.6).

Los últimos 6 días, el proceso no cumplió con los requerimientos de remoción del 38%, este comportamiento indica que el límite de CVA para la cinética está muy próximo.

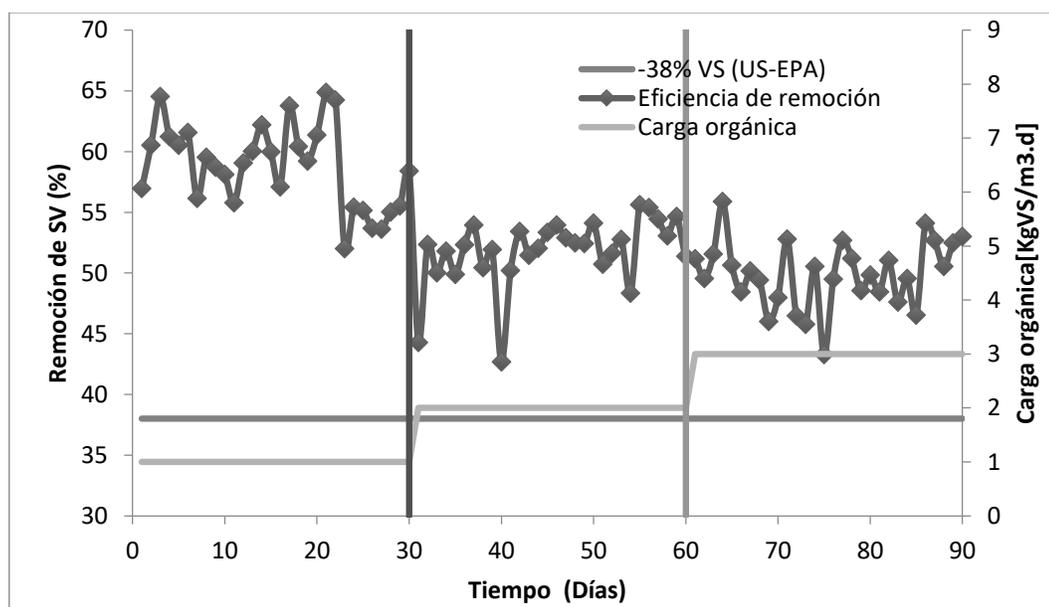


Figura 5.4 Remoción diaria e incremento de la CVA en la digestión de lodos

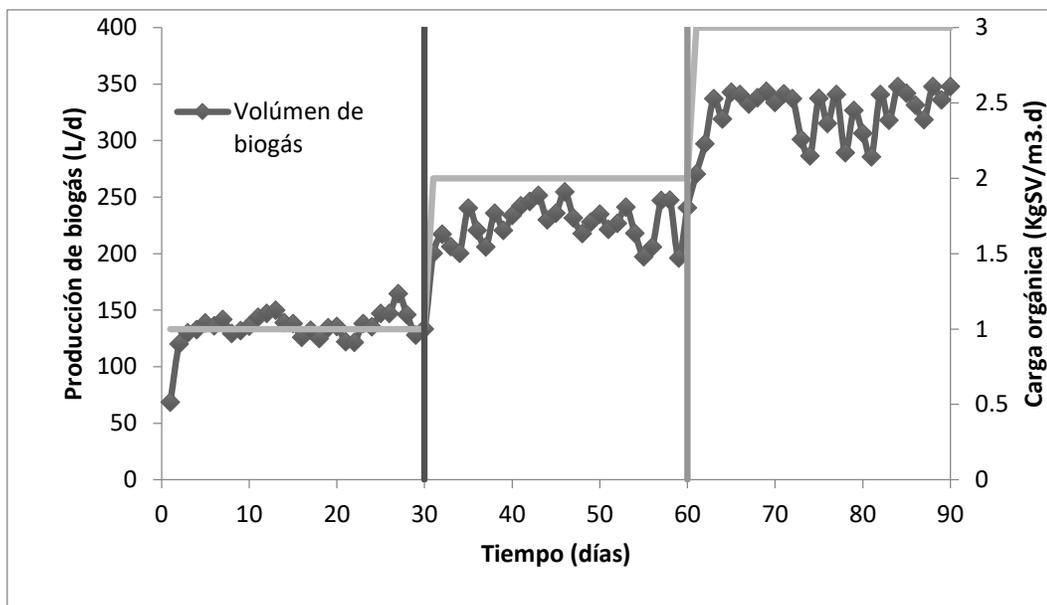


Figura 5.5 Producción de biogás diaria e incremento de la CVA en la digestión de lodos

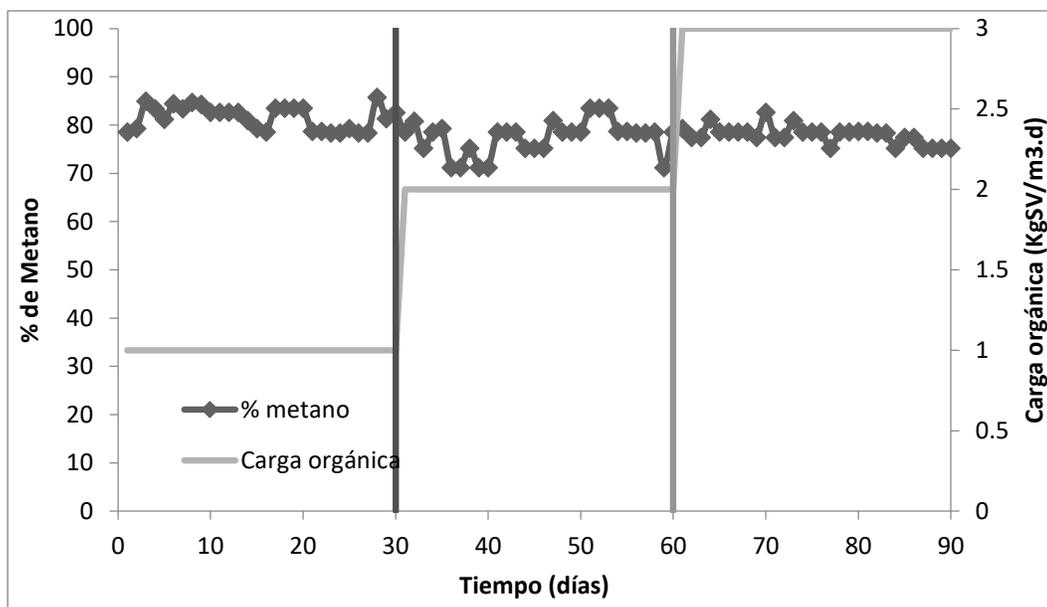


Figura 5.6 Producción de biogás diaria e incremento de la CVA en la digestión de lodos

5.4 Producción de biogás con hidrólisis con ácido acético

Se realizó el monitoreo de pruebas en cinéticas, utilizando lodo residual hidrolizado con ácido acético, operada inicialmente en *batch* y posteriormente se escaló a alimentación diaria y cargas de 1, 2 y 3 Kg SV m⁻³ d⁻¹. En la Figura 5.7 se muestra el comportamiento de la remoción de la materia orgánica dichas pruebas en cinéticas, en la cual se obtuvo la remoción del 38% de STV en el día 16, obteniéndose una producción diaria de biogás máxima de 576 ml., con el incremento de carga, se obtuvo un rendimiento máximo de 774 ml., se operaron los reactores adaptados a 90 días, con incrementos de carga cada periodo de 30 días y en la figuras en las figuras 5.8 y 5.9 se observa el comportamiento de la producción de biogás y metano en los primeros 30 días, y en las figuras 5.10 y 5.11 se observan los comportamientos con los incrementos de carga.

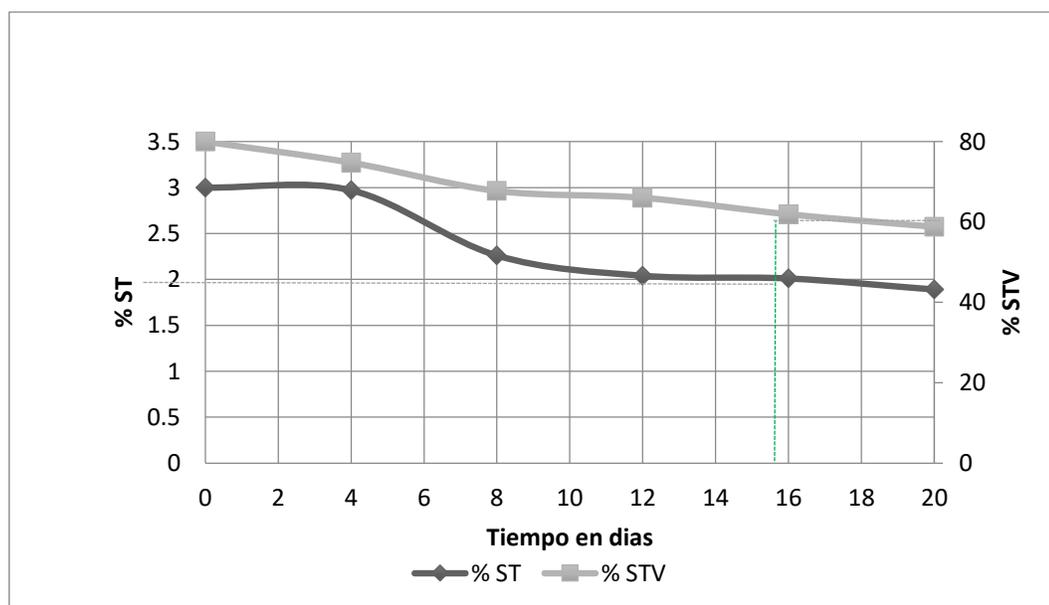


Figura 5.7 % de Sólidos totales y sólidos volátiles en lodo con pretratamiento ácido acético.

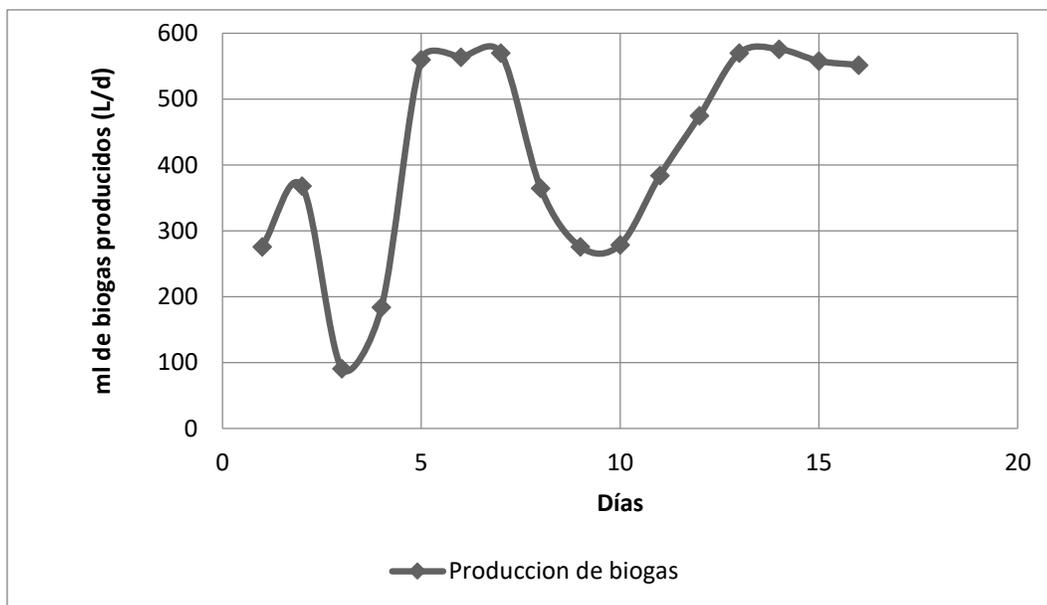


Figura 5.8 Producción de biogás en lodo pre tratado con ácido acético.

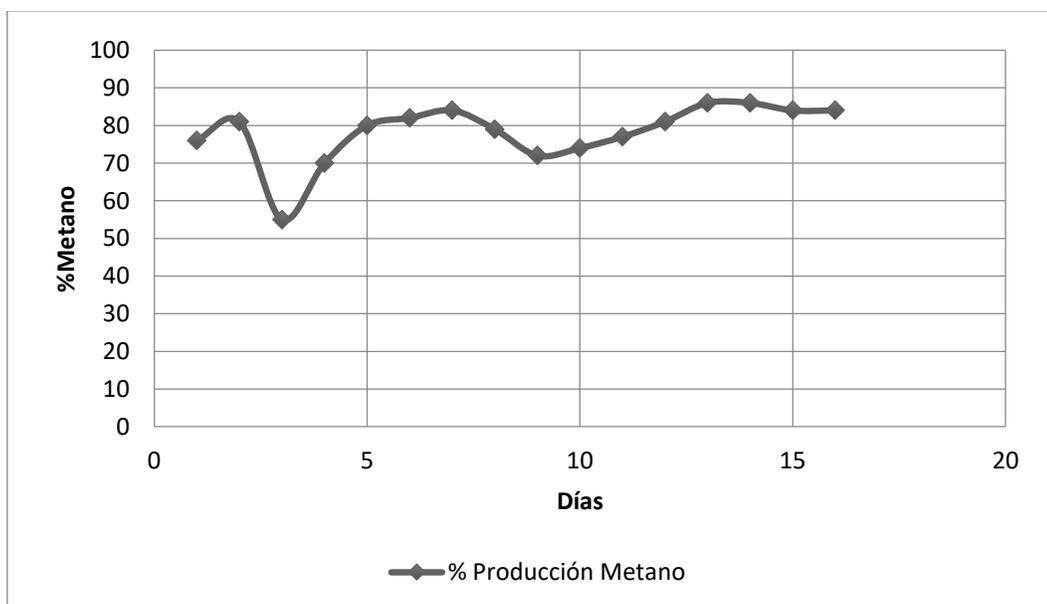


Figura 5.9 Producción de Metano en lodo tratado con ácido acético

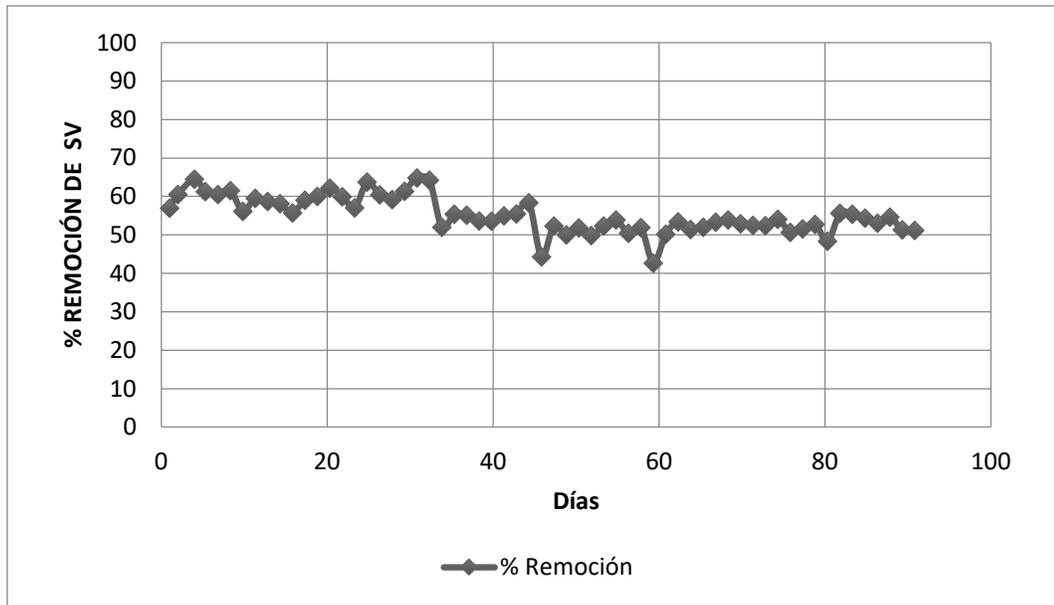


Figura 5.10 % de remoción en lodo con pre hidrolisis ácida en semi continuo

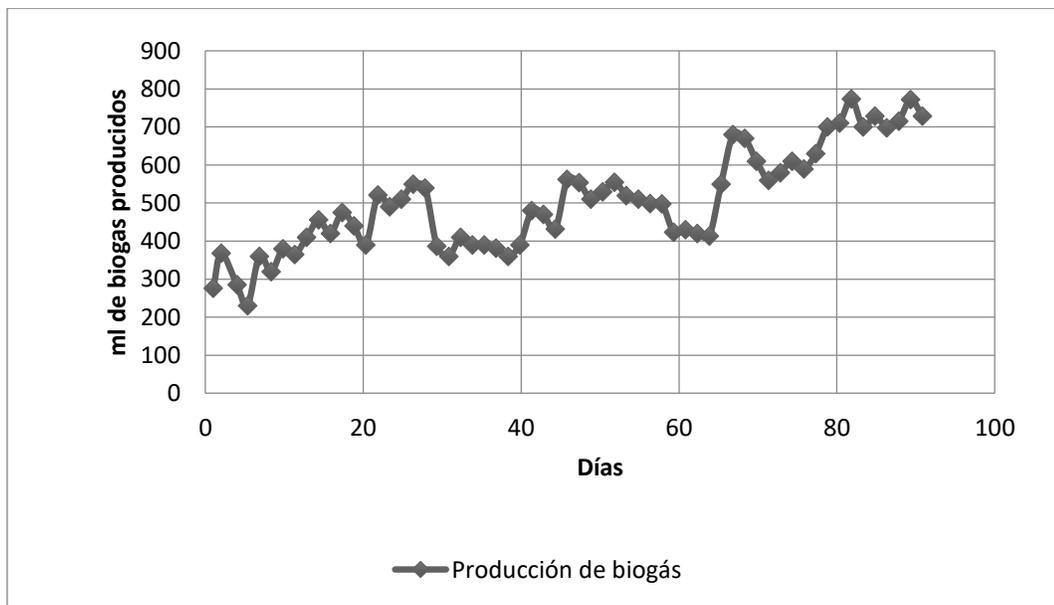


Figura 5.11 Producción de biogás en lodo con pre hidrolisis ácida en semi-continúo

5.5 Producción de biogás con hidrólisis enzimática

Se realizó la cinética con pre hidrólisis ácida considerando iniciando la operación en modo *batch* a 30 días y posteriormente se hizo un incremento de cargas de 1, 2 y 3 Kg SV m⁻³ d⁻¹ de carga orgánica, en la figura 38 se muestra el comportamiento de la remoción de la materia orgánica de ésta cinética, en la cual se obtuvo la remoción del 38% de STV en el día 12, obteniéndose una producción de biogás máxima de 200 ml en operación *Batch* (Ver Figura 5.12), con metano de 88% (Ver Figura 5.13), y una producción de biogás máxima de 630 ml (Ver Figura 5.14), en operación semicontinua, en las Figuras 5.15, 5.16 y 5.17 se muestra el comportamiento de remoción, producción de biogás y Metano Ch₄ al operar durante 90 días con un incremento de carga cada 30 días.

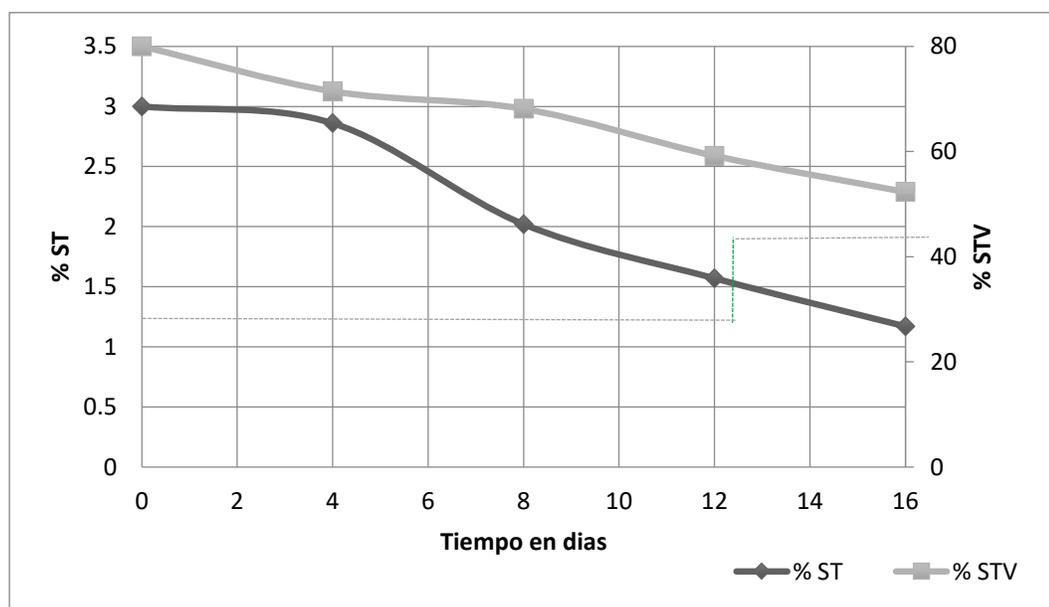


Figura 5.12 Remoción diaria en lodo con pretratamiento enzimático en batch.

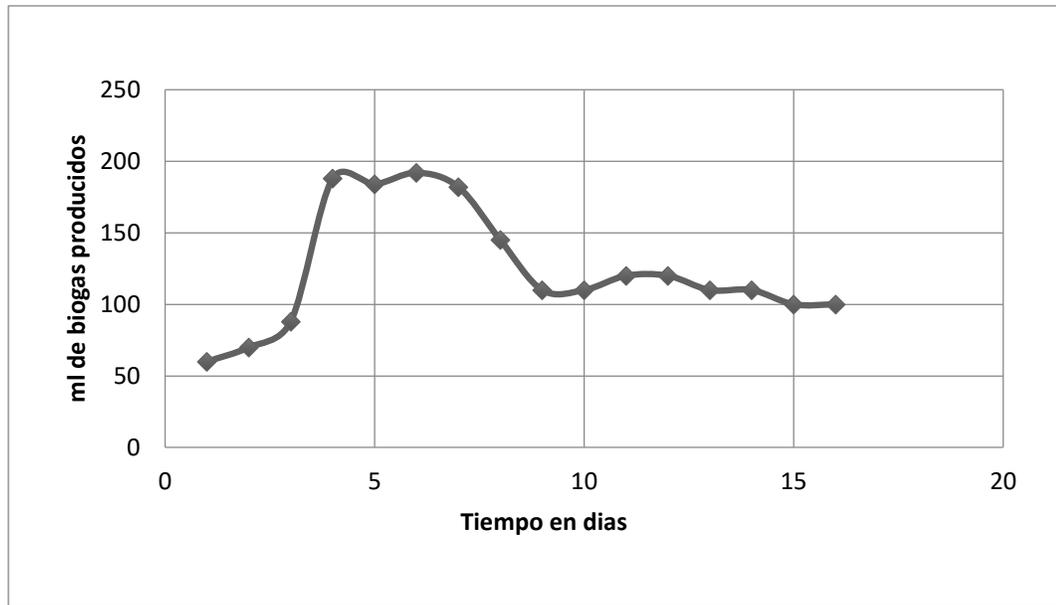


Figura 5.13 Producción de biogás en lodo con pretratamiento enzimático en *batch*.

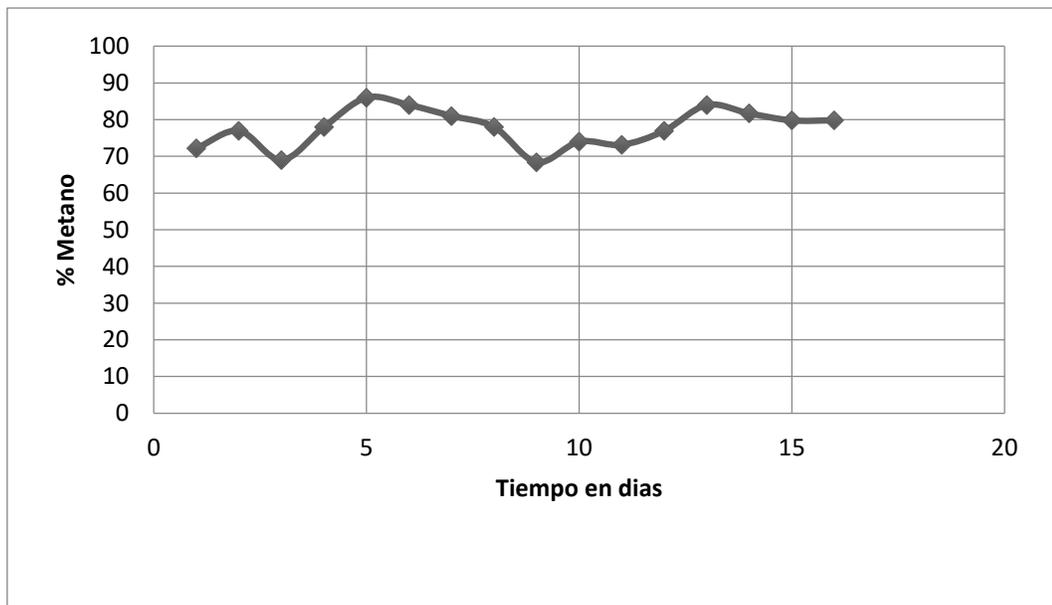


Figura 5.14 Producción de Metano en lodo con pretratamiento enzimático.

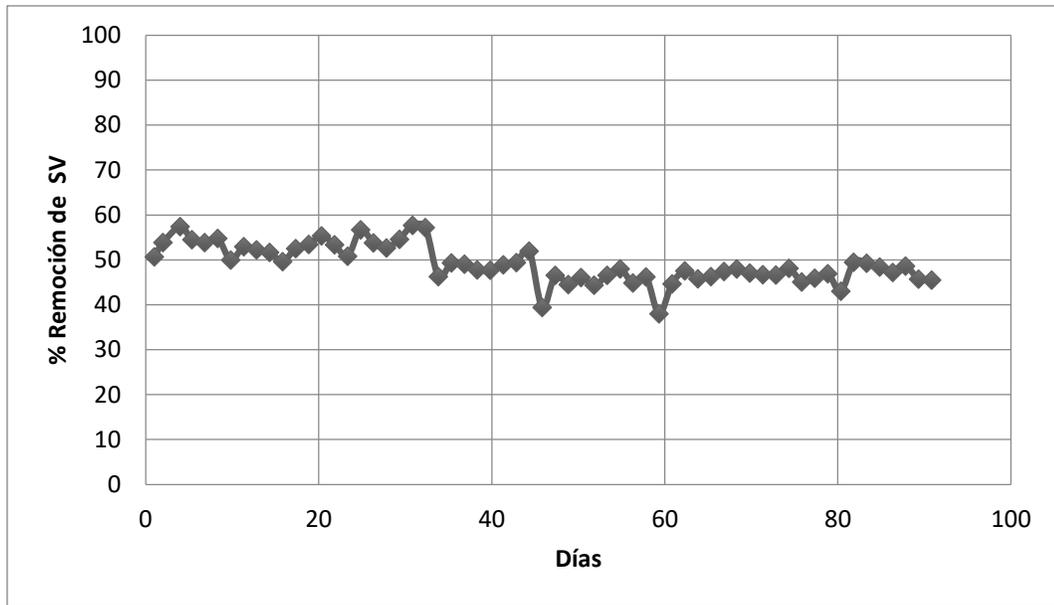


Figura 5.15 % de Remoción en lodo con pretratamiento enzimático.

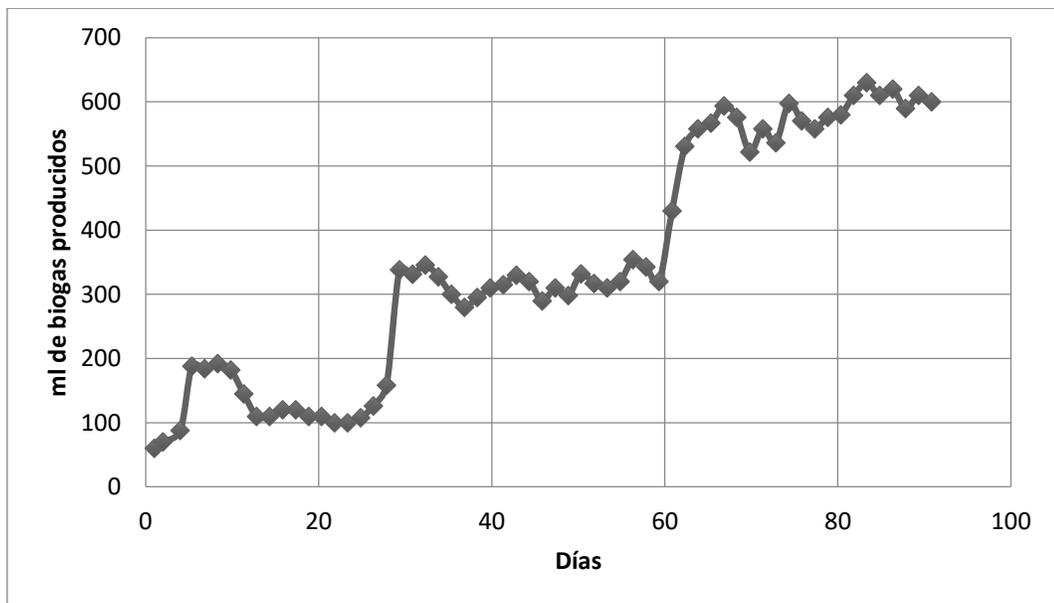


Figura 5.16 Producción de biogás en lodo con pretratamiento enzimático

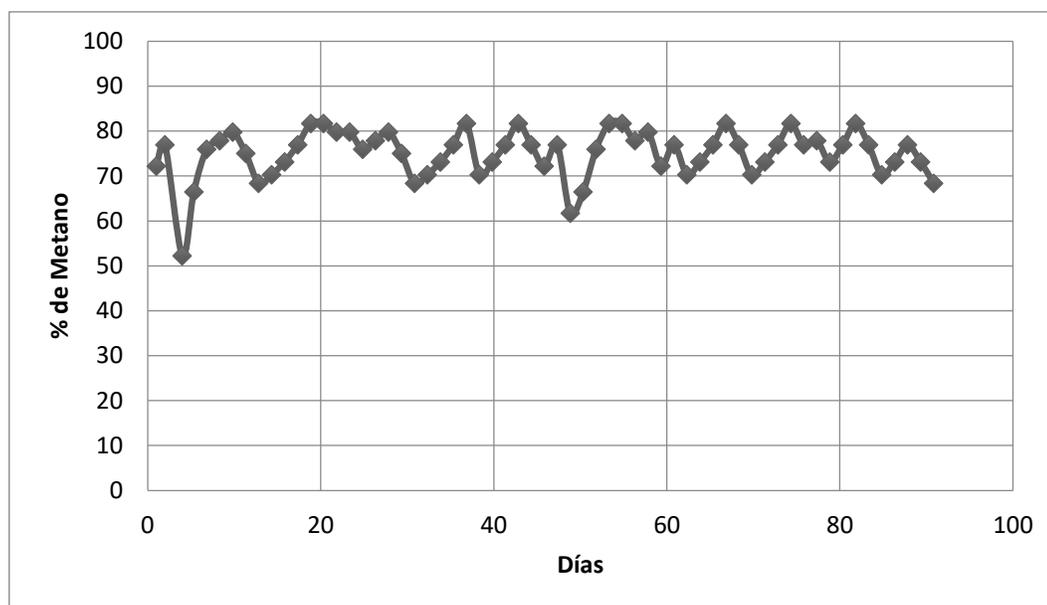


Figura 5.17 Producción de Metano en lodo con pretratamiento enzimático

5.6 Análisis de superficies de respuesta de los modelos de lógica difusa de los diferentes sustratos con y sin pre hidrolizado

El software de Matlab nos permite observar los resultados obtenidos en la interacción de las variables de entrada con las variables de salida en función de sus reglas de inferencia, para poder observar los resultados fue necesario hacer un análisis de las superficies de respuesta de las variables de entrada, considerando su impacto en la variable de salida biogás y Metano CH_4 .

A continuación se presentan graficas de superficies de respuesta de los modelos de lógica difusa, desarrollados para los diferentes sustratos.

En el análisis del modelo de lógica difusa de lodo sin pretratamiento se puede observar que los parámetros óptimos, para las variables remoción y sólidos volátiles, se estiman en un porcentaje de 75% de sólidos volátiles y cuando existe una remoción superior a 60% (Figura 5.18), estos datos coinciden con lo presentado por (Ruiz,2012) y (Valente, 2011).

Como se puede observar en la Figura 5.19, existe una fuerte relación entre el porcentaje de sólidos totales que componen el sustrato con el porcentaje de sólidos volátiles, debido a que se asume que los sólidos totales son aquellos residuos que quedan una vez que la parte líquida se ha evaporado y el remanente se ha secado a peso constante y a una temperatura de 103 °C, y los sólidos volátiles se refieren a aquellos residuos resultantes de una calcinación a temperaturas mayores de 550°C (Henry &W.Heinke,1999), por lo que en su interacción con la variable de salida biogás se puede observar que el punto máximo de producción de biogás se encuentra entre 2 y 3.5 % de sólidos totales y entre 70 y 80% de sólidos volátiles, coincidiendo con la adecuación que realiza Ruiz en el 2012, que se ve en la necesidad de acondicionar el sustrato para mantenerse en (Ruiz at el. 2012) con las adecuaciones descritas en y se observa en la Figura 5.20, como los sólidos totales se mantienen (Ruiz at el. 2012) . En la figura 5.21 se observa el comportamiento de las variables de entrada con respecto al comportamiento de la variable de salida biogás, el cual tiene un comportamiento similar al de biogás ya que es una variable dependiente del volumen de biogás producido.

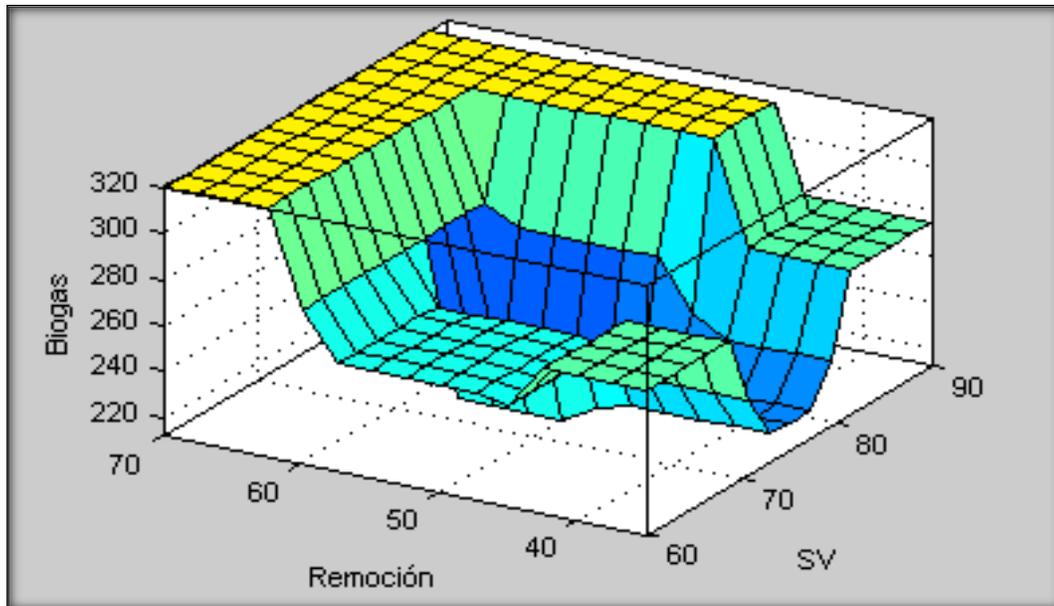


Figura 5.18 Gráficas de superficie de respuesta del impacto de las variables de entrada % remoción.

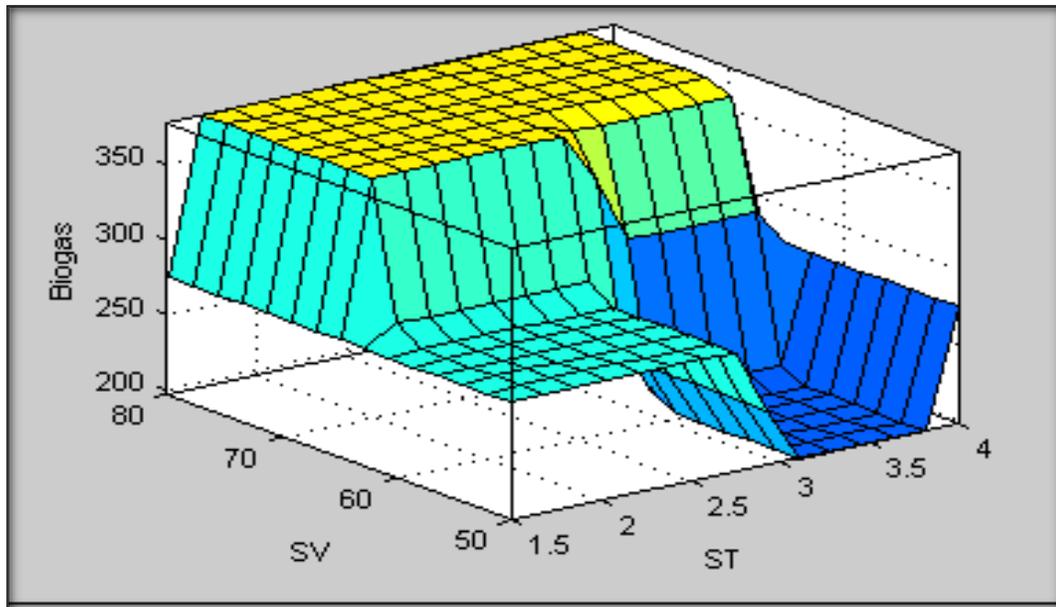


Figura 5.19 Gráfica de superficie de respuesta del impacto de las variables de entrada % sólidos totales en la variable de salida biogás y Metano, en lodo con prehidrolisis térmica

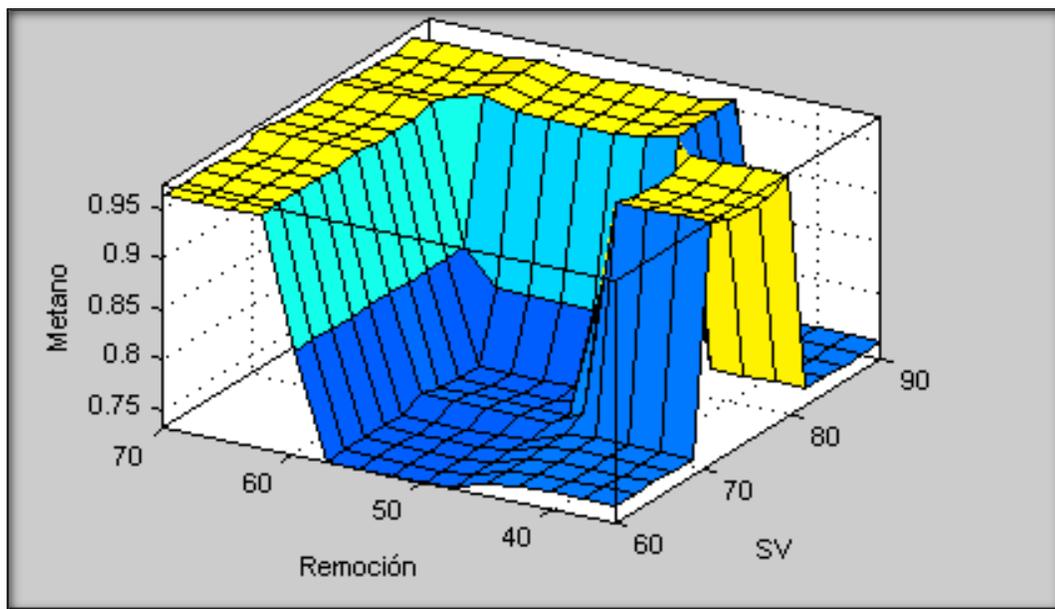


Figura 5.20 % sólidos volátiles, en las variables de salida biogás y Metano, del lodo sin pretratamiento.

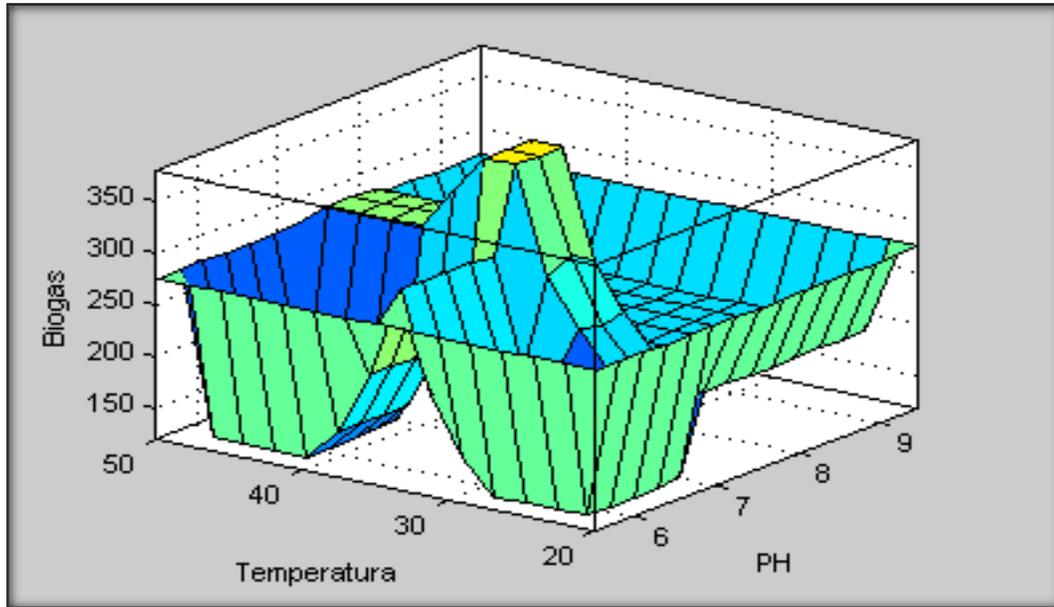


Figura 5.21 Gráfica de superficie de respuesta del impacto de las variables de entrada de temperatura y pH, en la variable de salida biogás y Metano, en lodo con prehidrolisis térmica

La variable carga es una de las variables más importantes en el proceso de digestión anaerobia mesofílica, ya que la cantidad de carga orgánica es el factor de alimentación del proceso, las superficies de respuesta muestran el comportamiento de las variables de entrada carga orgánica y pH, como se puede observar en las Figura 5.22, el modelo de lógica difusa arroja una superficie de respuesta en donde se el área sombreada en color amarillo representa la mayor producción de biogás y esto concuerda con lo reportado por (M. Polit et al, 2002), en que desarrolla conjuntos difusos para la variable lingüística pH y estima el área factible para la mayor producción de biogás y la operación óptima del proceso en un rango de 7 ± 5 . Con respecto a la variable carga orgánica, se observa que se estima que la mayor producción en valores de 3 a 4 Kgs SV $m^{-3} d^{-1}$, de carga orgánica y de acuerdo a los resultados obtenidos por (López et al. 2014) las cargas con mayor eficiencia en el proceso de Digestión anaerobia se estiman entre cargas de 1 y 3 a 4 Kgs SV $m^{-3} d^{-1}$ ya que a partir de 5, el reactor tiende a saturarse y la producción de biogás se inhibe y la producción de biogás, empieza a decaer. La producción de Metano se comporta de manera similar, considerando que su producción se encuentra correlacionada con la producción de volumen de biogás (Figura 5.23).

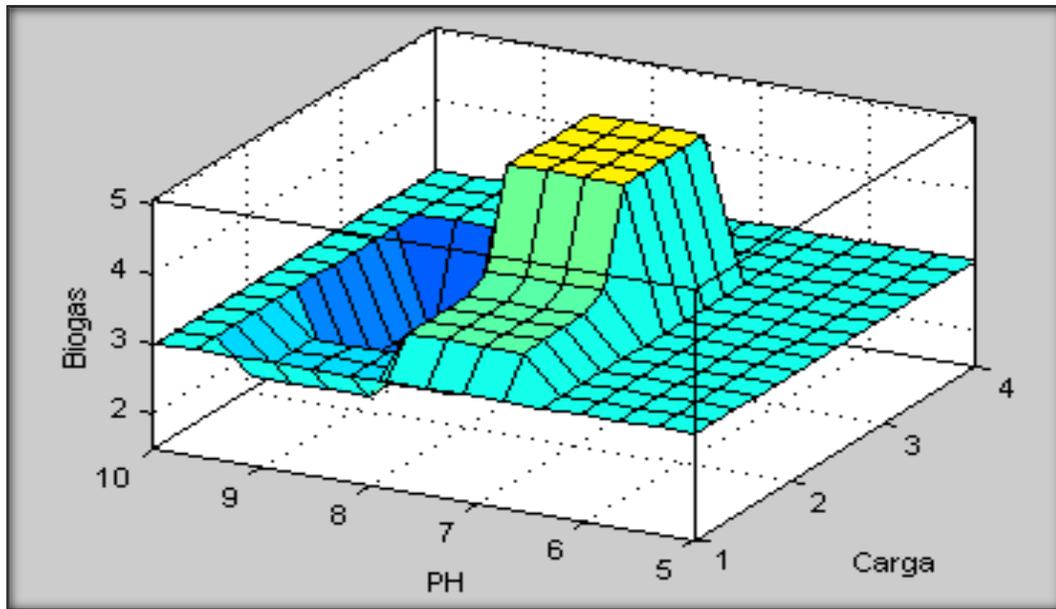


Figura 5.22 Gráfica de superficie de respuesta del impacto de las variables de entrada Carga Kgs SV m-3 d-1 y pH, en la variable de salida biogás, con pre hidrolisis térmica.

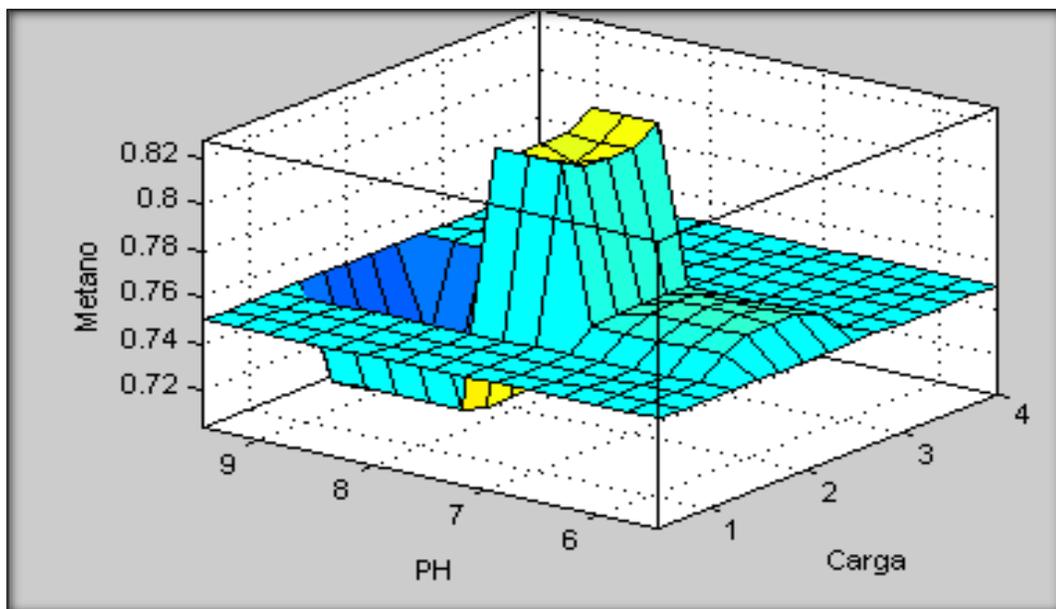


Figura 5.23 Gráfica de superficie de respuesta del impacto de las variables de entrada pH y Carga en la variable de salida biogás y Metano, en lodo con prehidrolisis térmica.

Las variables temperatura y la variable operación se encuentran relacionadas con las variables de operación del proceso de digestión anaerobia, (Metcalf & Eddy, 2003) Mencionan que la temperatura para que las bacterias mesofílicas sobrevivan se encuentran entre 20 y 45 ° C, sin embargo las condiciones óptimas del proceso se estiman entre 30 y 35 °C, en las superficies de respuesta que arroja el modelo de lógica difusa se observa que las condiciones óptimas del proceso se encuentra entre 30 y 37 °C (Figura 5.24 y 5.25), resultados que se encuentran muy cercanos a los datos reportados por diversos investigadores, y el tiempo de operación es proporcional a la carga orgánica, ya que se hicieron incrementos de carga graduales, cada 30 días, por lo que se puede observar claramente que la carga 3, es la cantidad favorable, en la producción de biogás, ya que tiene una mayor cantidad de materia orgánica que puede ser digerida por los reactores, considerando (cinéticas).

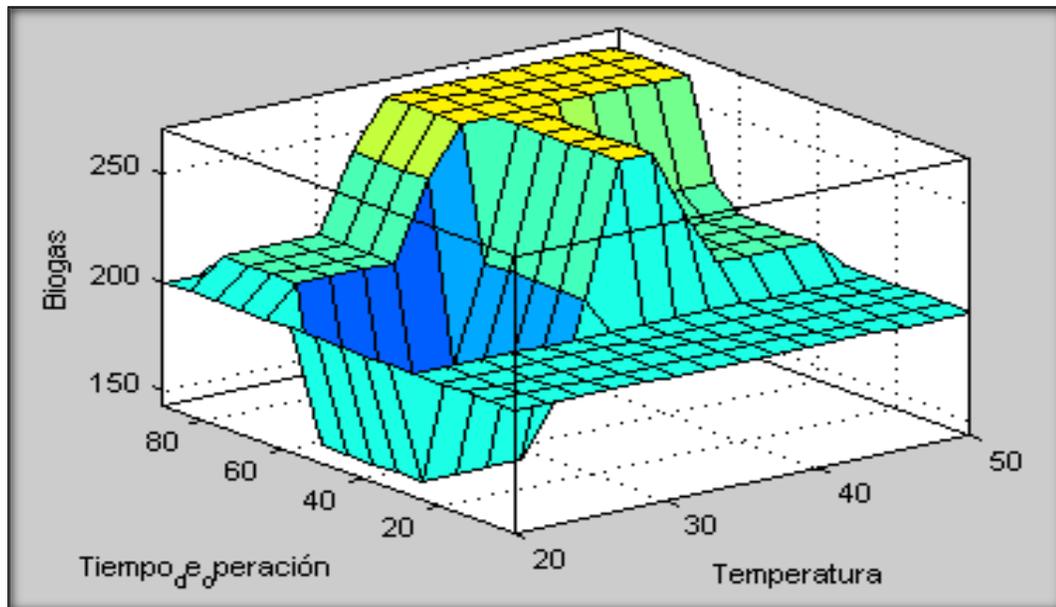


Figura 5.24 Gráficas de superficie de respuesta del impacto de las variables de entrada Temperatura y tiempo de operación con impacto en la variable de salida biogás.

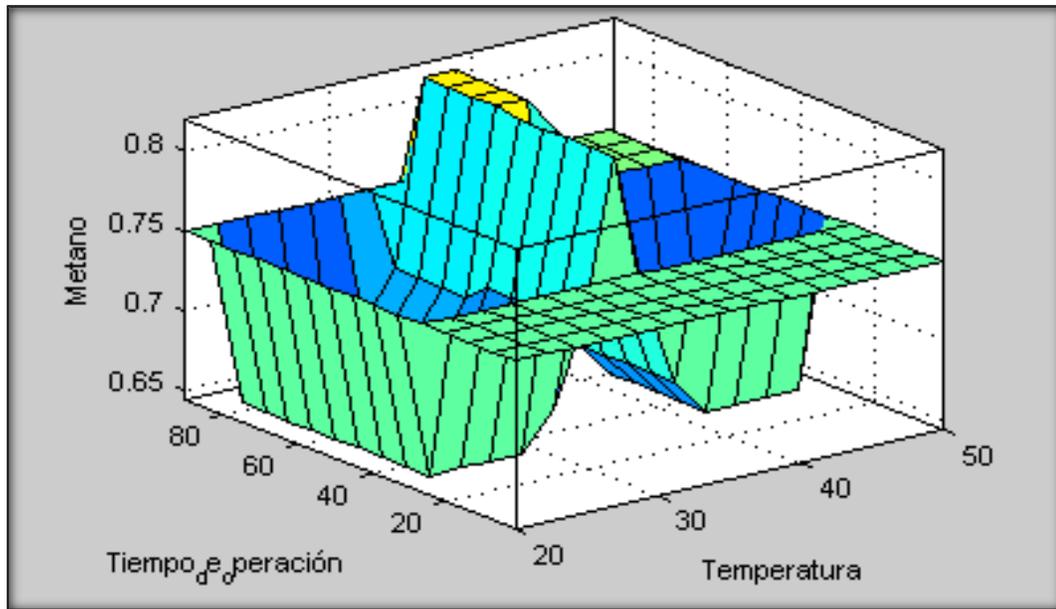


Figura 5.25 Gráficas de superficie de respuesta del impacto de las variables de entrada Temperatura y tiempo de operación con impacto en la variable de salida Metano.

Muchos investigadores han reportado efectos significativos de la temperatura en la comunidad microbiana que interviene en el proceso de digestión anaerobia y sus diferentes fases, la estabilidad del proceso y el rendimiento de metano (Dela-Rubia et al, 2002) (Bouallagui et al, 2009); (Riau et al., 2010).

Las temperaturas más bajas durante provocan una importante disminución del crecimiento microbiano, la remoción de materia orgánica, y la producción de biogás (Kim et al, 2006), (Trzcinski y Stuckey, 2010). En contraste, las altas temperaturas también pueden provocar que las tasas de producción de biogás se vean afectadas, lo que puede dar como resultado tasas de rendimiento inferiores a la media, debido a la producción de gases volátiles tal como amoníaco que suprime la actividad de las bacterias metanogénicas (Fezzani y Cheikh, 2010).

Cabe mencionar que es muy importante el control de la temperatura en relación al nivel de pH, ya que si no hay un equilibrio el proceso puede inhibirse, en la Figura 5.26 se presenta la superficie de respuesta que muestra el rango óptimo de operación del proceso de digestión anaerobia en correlación del nivel de pH y temperatura y los resultados en la producción de biogás, y en la Figura 5.27 en el impacto en Metano (El-Mashad et al., 2003).

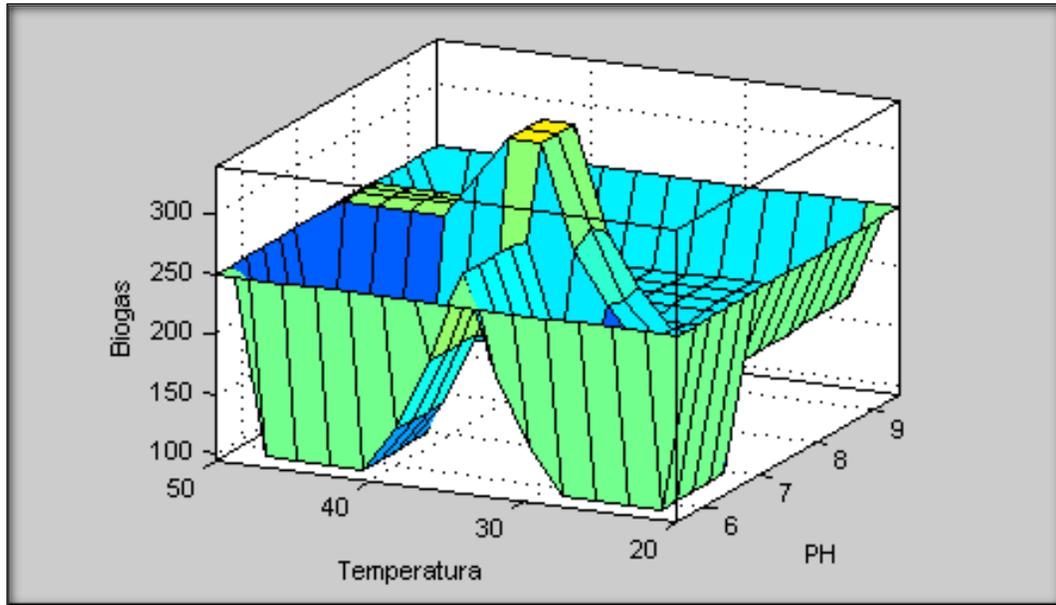


Figura 5.26 Gráficas de superficie de respuesta del impacto de las variables de entrada Temperatura y Tiempo de operación, en la variable de salida Biogás con pre-hidrolisis ácida.

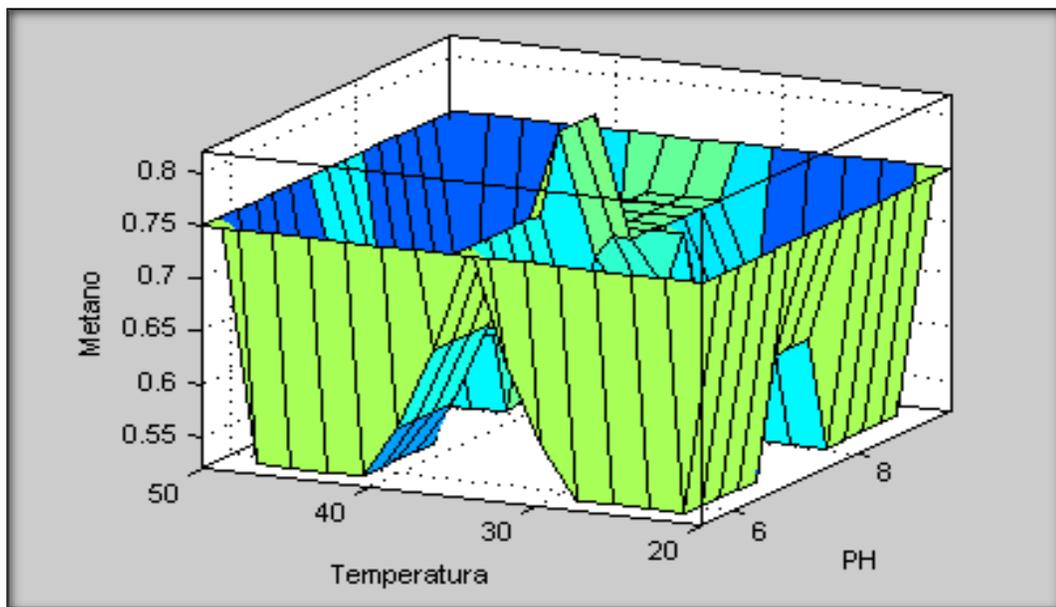


Figura 5.27 Gráficas de superficie de respuesta del impacto de las variables de entrada Temperatura y Tiempo de operación, en la variable de salida Metano en lodo con pre-hidrolisis ácida.

Posteriormente se hizo la validación del modelo, se realizó un análisis del coeficiente de determinación R^2 y se llevó a cabo la determinación de un coeficiente de correlación se determinó únicamente para las variables de salida biogás y metano CH_4 , es importante considerar que la variable metano depende de la cantidad de biogás obtenida; para poder estimar el coeficiente de correlación se consideraron los 90 datos obtenidos de la recolección de datos experimentales, y que de igual manera fueron el fundamento de la validación de las reglas de inferencia del modelo de lógica difusa.

Una vez obtenida la base de datos, se introdujeron al modelo de lógica difusa, obteniendo 90 datos de salida de la variable biogás y metano CH_4 datos que fueron comparados y correlacionados por medio de herramientas estadísticas, para poder determinar el coeficiente de correlación. Se obtuvo un coeficiente de determinación R^2 de 97% para la variable biogás y un coeficiente de determinación R^2 de 92% para la variable Metano CH_4 (Ver Tablas 5.2, 5.3, 5.4 y Figura 5.28).

Tabla 5.2. Muestra del coeficiente de correlación del modelo de lógica difusa de digestión anaerobia mesofílica en lodo pre tratado térmicamente.

DATOS	VOLUMEN DE BIOGÁS (Datos experimentales) Lts.	VOLUMEN DE BIOGÁS (Datos obtenidos por el modelo de lógica difusa) Lts.	VOLUMEN DE METANOCh₄ (Datos experimentales) Lts.	VOLUMEN DE METANOCh₄ (Datos obtenidos por el modelo de lógica difusa) Lts.
1	1.10	1.34	0.44	0.44
2	1.92	1.97	0.73	0.74
3	2.08	2.14	0.80	0.80
4	2.13	2.17	0.84	0.84
5	2.22	2.16	0.88	0.88
6	2.18	2.22	0.90	0.85
7	2.07	2.03	0.96	0.95
8	2.11	1.89	0.96	0.95
9	2.18	1.89	0.76	0.75
10	2.36	1.94	0.81	0.81
11	2.40	2.08	0.91	0.91
12	2.22	2.9	0.96	0.95
13	2.21	2.6	0.80	0.81
14	2.02	2.23	0.80	0.81
15	2.12	2.33	0.88	0.81
16	2.00	2	0.90	0.89
17	2.15	2.65	0.86	0.85
18	2.17	2.1	0.91	0.89
19	1.95	2.1	0.79	0.80
20	1.95	2.1	0.79	0.80
21	2.17	2.19	0.84	0.85
22	2.36	2.19	0.84	0.85
23	2.36	2.19	0.77	0.75
24	2.64	2.19	0.81	0.81
25	2.34	2.17	0.81	0.81
26	2.05	2.16	0.86	0.80
27	2.14	2.15	0.87	0.87
28	3.21	2.13	0.84	0.84
29	3.48	3.63	0.84	0.87
30	3.30	3.58	0.87	0.88
Coeficiente de correlación biogás		0.972	Coeficiente de correlación Metano 0.926	

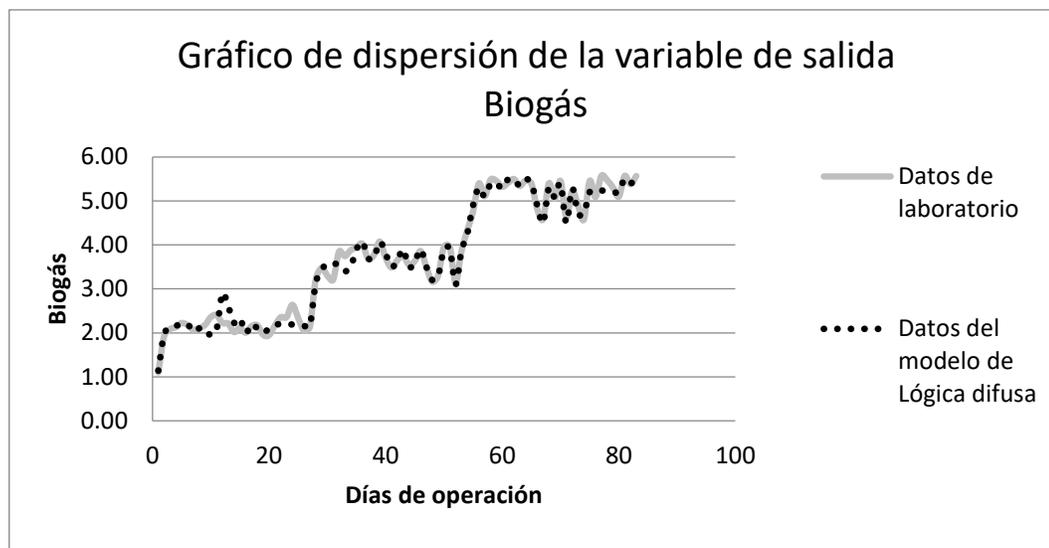


Figura 5.28 Gráfico de comparación de datos experimentales y del modelo de lógica difusa del proceso de digestión anaerobia mesofílica en lodo pre tratado térmicamente.

Tabla 5.3 Muestra del coeficiente de correlación del modelo de lógica difusa de digestión anaerobia mesofílica en lodo con pre hidrolisis ácida.

DATOS	VOLUMEN DE BIOGÁS (Datos experimentales) Lts.	VOLUMEN DE BIOGÁS (Datos obtenidos por el modelo de lógica difusa) Lts.	VOLUMEN DE METANO _{CH₄} (Datos experimentales) Lts.	VOLUMEN DE METANO _{CH₄} (Datos obtenidos por el modelo de lógica difusa) Lts.	
1	267	265	79	77	
2	356	355	79	78	
3	89	88	85	82	
4	178	168	83	84	
5	623	624	81	80	
6	534	534	84	83	
7	534	534	83	82	
8	133.5	135	85	85	
9	267	268	84	85	
10	267	269	83	83	
11	356	355	83	81	
12	445	446	83	81	
13	534	535	83	80	
14	534	350	81	79	
15	534	500	79	78	
16	534	500	79	76	
17	450	425	83	84	
18	500	490	83	81	
19	600	590	83	84	
20	550	524	83	84	
Coeficiente de correlación biogás		0.967	Coeficiente de correlación Metano		0.912

Tabla 5.4 Muestra del coeficiente de correlación del modelo de lógica difusa de digestión anaerobia mesofílica en lodo con pre hidrolisis enzimática.

DATOS	VOLUMEN DE BIOGÁS (Datos experimentales) Lts.	VOLUMEN DE BIOGÁS (Datos obtenidos por el modelo de lógica difusa) Lts.	VOLUMEN DE METANOCh₄ (Datos experimentales) Lts.	VOLUMEN DE METANOCh₄ (Datos obtenidos por el modelo de lógica difusa) Lts.
1	60	80	76	76
2	70	81	81	81
3	88	87	55	55
4	188	182	70	70
5	184	185	80	80
6	192	189	82	82
7	182	181	84	84
8	145	140	79	79
9	110	112	72	72
10	110	108	74	74
11	120	122	77	77
12	120	124	81	81
13	110	115	86	86
14	110	115	86	86
15	100	109	84	84
16	100	110	84	84
17	108	109	80	80
18	126	130	82	82
19	158.4	160	84	84
20	338.4	340	79	79
Coeficiente de correlación biogás		0.972	Coeficiente de correlación Metano	
			0.926	

Al determinar las variables de impacto del proceso de digestión anaerobia mesofílica con pretratamiento térmico, se observa que las variables que más afectan a las predicciones son: Temperatura, Ph y Carga de acuerdo a los gráficos de superficie de respuesta, por lo que se comparan éstas con los gráficos de superficies del modelo de Lógica Difusa.

5.7 Resultados de las redes neuronales

En la Figura 5.29 se muestran los resultados del entrenamiento de la red neuronal artificial muestran que las diferencias entre los valores reales y la predicción de la validación con 60 casos con una R2 de 96.4% (el coeficiente de determinación R^2 , indica un ajuste perfecto mientras más se acerque a 1), se puede decir que hay una fuerte relación lineal positiva, por lo que se considera que la red esta entrenada adecuadamente).

Los resultados de la prueba con 30 casos nuevos se presentan en la figura 5.30, muestran un coeficiente de determinación (R^2) de 94%, logrando que las predicciones sean exitosas. Una vez entrenada la red neuronal artificial y validada mediante la prueba, ya se pueden simular diferentes parámetros de las variables de entrada, en las tablas 5.5 y 5.6 se observa la predicción de forma automática en 60 y 30 casos respectivamente.

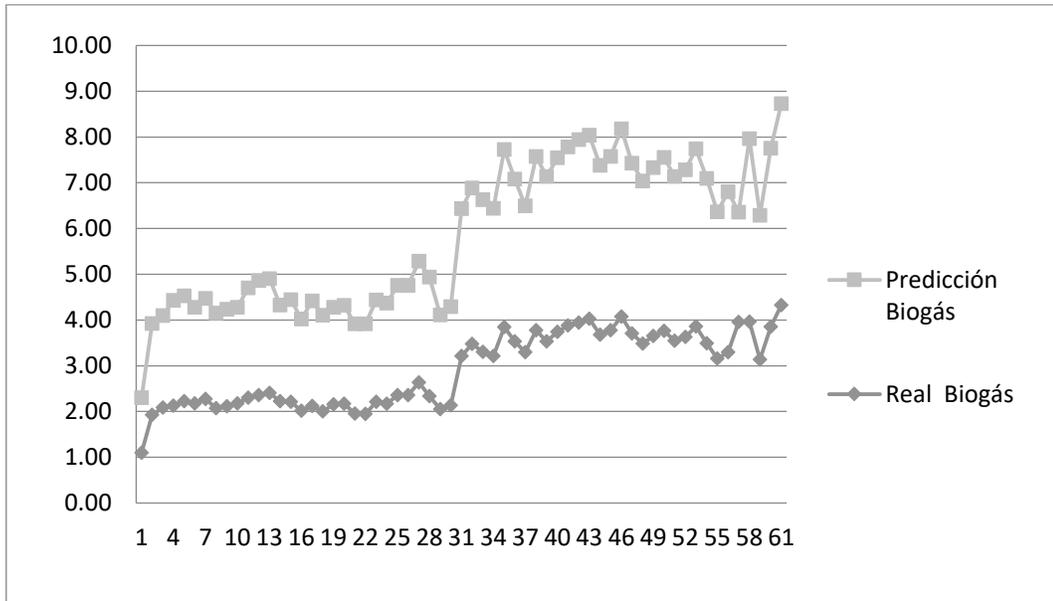


Figura 5.29 Validación de la predicción de la red neuronal con 60 casos.

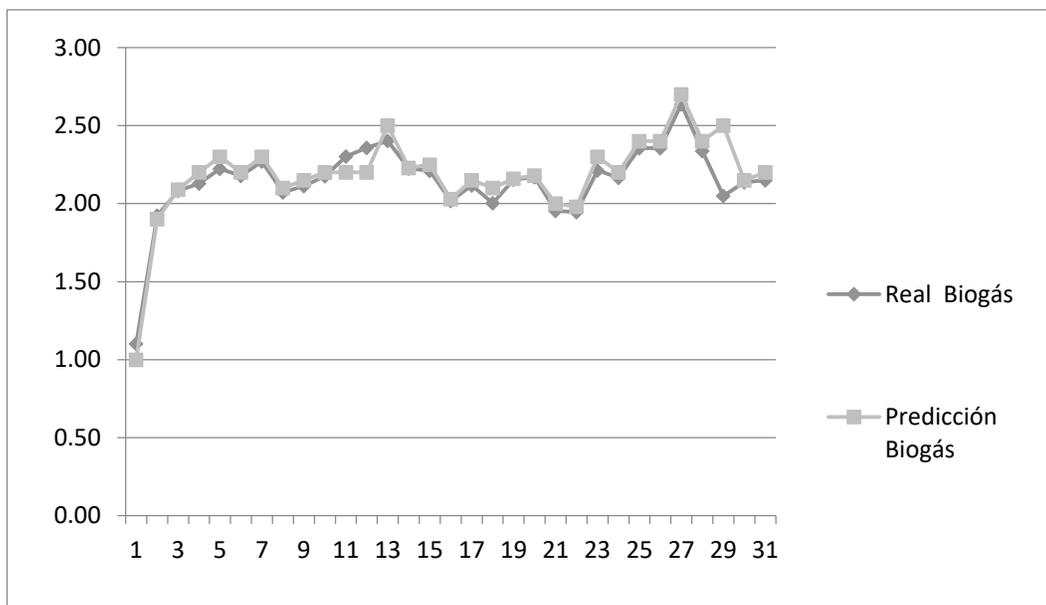


Figura 5.30 Validación de la predicción de la red neuronal con 30 casos.

En la Figura 5.30 se observa la producción de Metano, en ella se puede analizar que los datos obtenidos por la predicción, son muy cercanos a los datos obtenidos por experimentación, es importante mencionar que existe una importante variación entre los datos, debido al comportamiento de las bacterias metanogénicas y a composición del sustrato, así como variación en el incremento de alimentación del reactor.

Tabla 5.5 Predicción de la red neuronal con 60 casos

ST	SV	CARGA	Ph	TIEMPO	BIOGÁS	METANO	REMOCIÓN
3	69	3.000	7.1	65	3.2977	72.1615	43.7425
3.7	68.2	1.070	7.2	35	1.492	85.6179	63.3242
3.2	68.1	2.000	7	34	2.8436	79.3948	45.8723
4	68.2	1.080	7.11	2	1.5349	85.6778	63.5592
3.5	68.5	3.000	7.4	20	3.2879	85.4792	49.9505

Tabla 5.6 Predicción de la red neuronal con 30 casos

ST	SV	CARGA	pH	TIEMPO	BIOGÁS	METANO	REMOCIÓN
3	75	3.000	7.1	75	2.6265	84.4445	64.8156
3.7	68.2	2.000	7.2	43	2.5963	78.6785	53.0405
3.2	70	2.000	7	38	2.6263	84.5151	64.8153
4	68.2	1.080	7.11	29	2.3772	78.3201	63.6311
3.5	65	1.000	7.4	20	2.407	83.0234	63.8559

Se estima un porcentaje de predicción del 94% con respecto a las variables de entrada ST%, SV%, tiempo, temperatura, carga orgánica y Ph. A continuación se observa la gráfica de predicción en la Figura 5.31 y en la Figura 5.32 se puede observar el porcentaje de impacto de cada variable de entrada, cabe mencionar que la variable de temperatura no se consideró en la predicción debido a que los datos obtenidos de la experimentación en laboratorio se operó el proceso en un valor constante de 32° C.

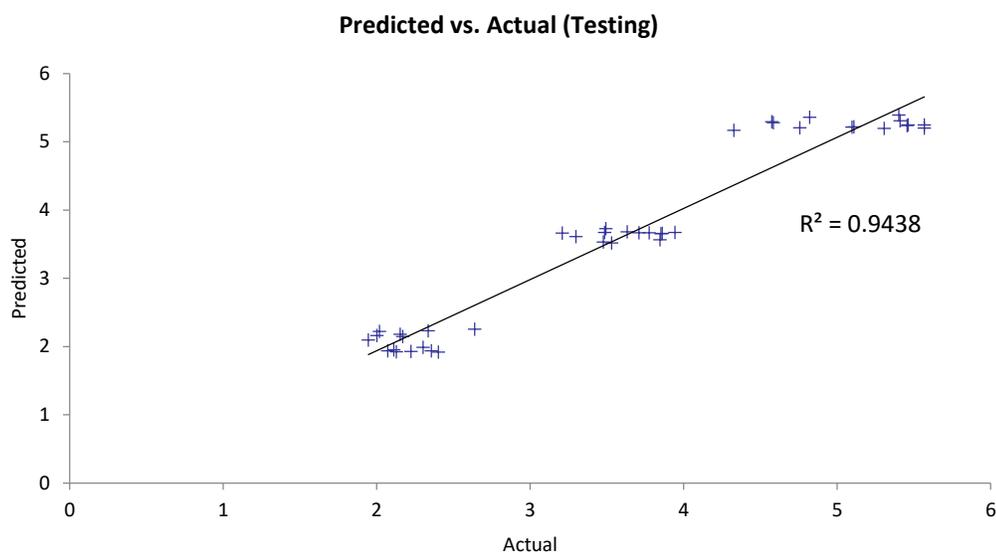


Figura 5.31 Gráfico de predicción o de la red neuronal del proceso de digestión anaerobia mesofílica en lodo pretratado térmicamente.

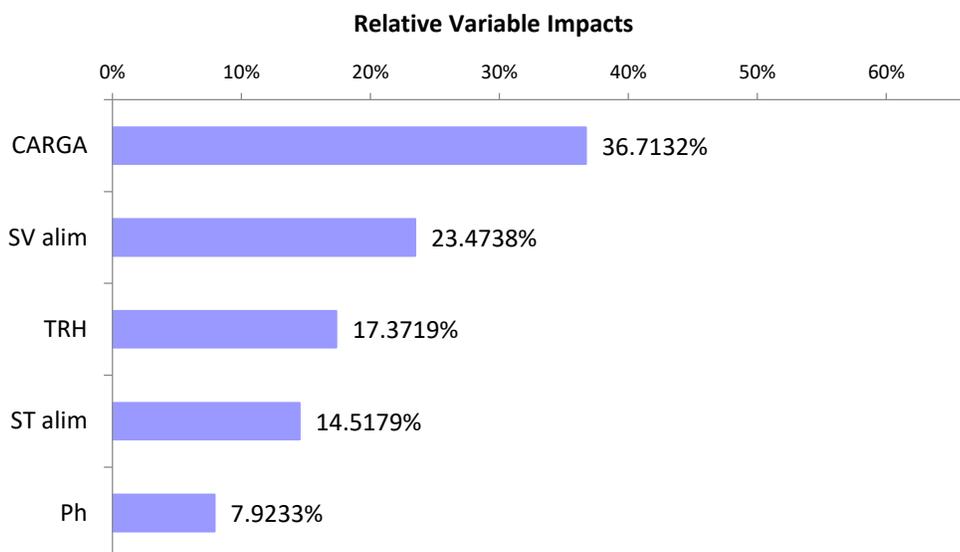


Figura 5.32 Gráfico de porcentajes de impacto de las variables de entrada de la red neuronal del proceso de digestión anaerobia mesofílica en lodo pretratado térmicamente.

5.8 Resultados Algoritmos genéticos multicriterio

Para la optimización del proceso de digestión anaerobia se elaboraron modelos matemático que permiten estimar la mayor cantidad de producción de biogás, metano y remoción, los modelos matemáticos fueron pre-cargados en el sistema Matlab.

5.8.1 Resultados Algoritmo genético multicriterio en lodo prehidrolizado térmico semi-continuo en Matlab

Para el desarrollo de los algoritmos genéticos fue necesario programar la función objetivo en código Matlab, para posteriormente llamarla desde la herramienta, gatoolbox, que permite optimizar modelos multicriterio, para este caso se optimizaron las tres variables de salida, biogás, metano y remoción, para ello se consideró y configuró el sistema con una población inicial aleatoria doble con una distribución uniforme, seleccionando la opción doble vector, en la cual se realizó el cruzamiento por medio del método de torneo, seleccionando a cada padre

por generación y eligiendo individuos al azar, cuyo número se puede especificar por tamaño de torneo y, a continuación se elige el mejor individuo para ser un padre, posteriormente la mutación se lleva a cabo por medio del método de mutación gaussiana que se desarrolla a través de vectores por cada individuo. Este número aleatorio es tomado de una distribución gaussiana centrada en cero. En la tabla 5.7 se presenta un ejemplo de tres optimizaciones obtenidas del algoritmo genético, mismas que se seleccionaron por medio de la herramienta de selección Topsis.

Tabla 5.7 Datos optimizados por algoritmos genéticos.

Biogás	Metano	Remoción
270.002252	0.89235447	58.4294347
270.912852	0.88242515	59.4694347
271.329252	0.8811091	53.4694347

El software Maltlab permite configurar la herramienta gatoolbox para presentar los resultados de diversas formas, el Pareto es una de las gráficas que permiten mostrar el comportamiento de los datos, en la Figura 5.33 se presenta el comportamiento de dos de las variables de salida del modelo, biogás y metano, en la cual se puede observar que los mejores rendimiento de biogás se dan en los 271 ml de biogás por día y 88% de rendimiento de metano.

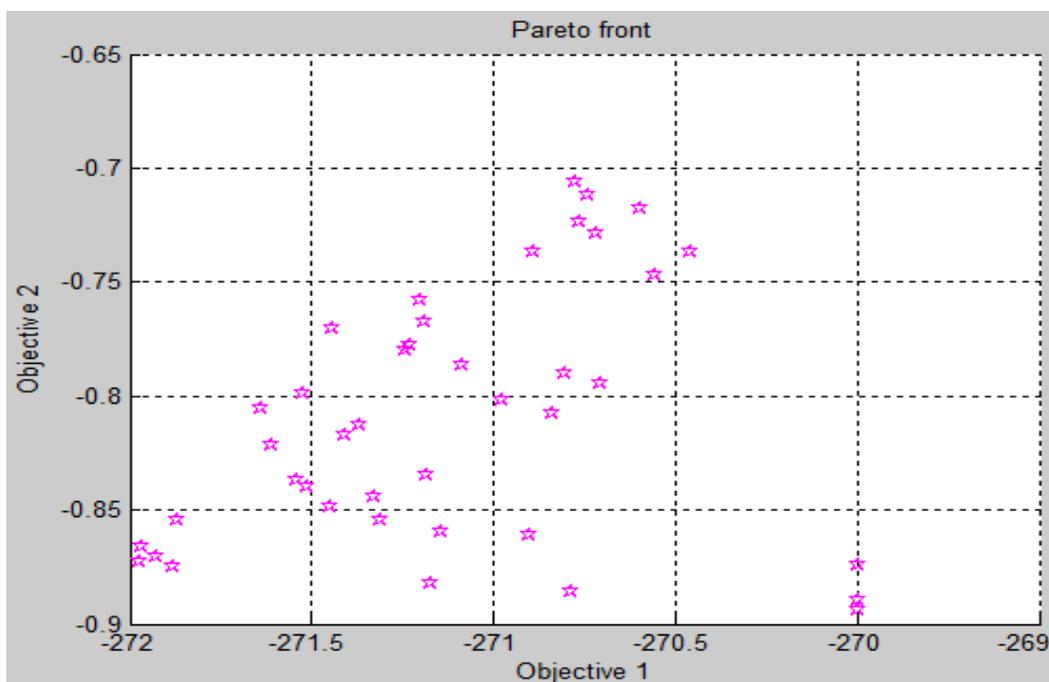


Figura 5.33 Optimización algoritmo genético multicriterio biogás y metano.

Por último para una mejor representación del comportamiento y una mejor apreciación de los valores optimizados de las variables de salida, se presenta la Figura 5.34, un gráfico tridimensional que permite visualizar el agrupamiento de los datos en la zona en donde se presenta la mayor producción de las tres variables de salida, como se puede observar los datos se concentran los 270 ml, metano superior al 80% y remoción en valores superiores a 0.50.

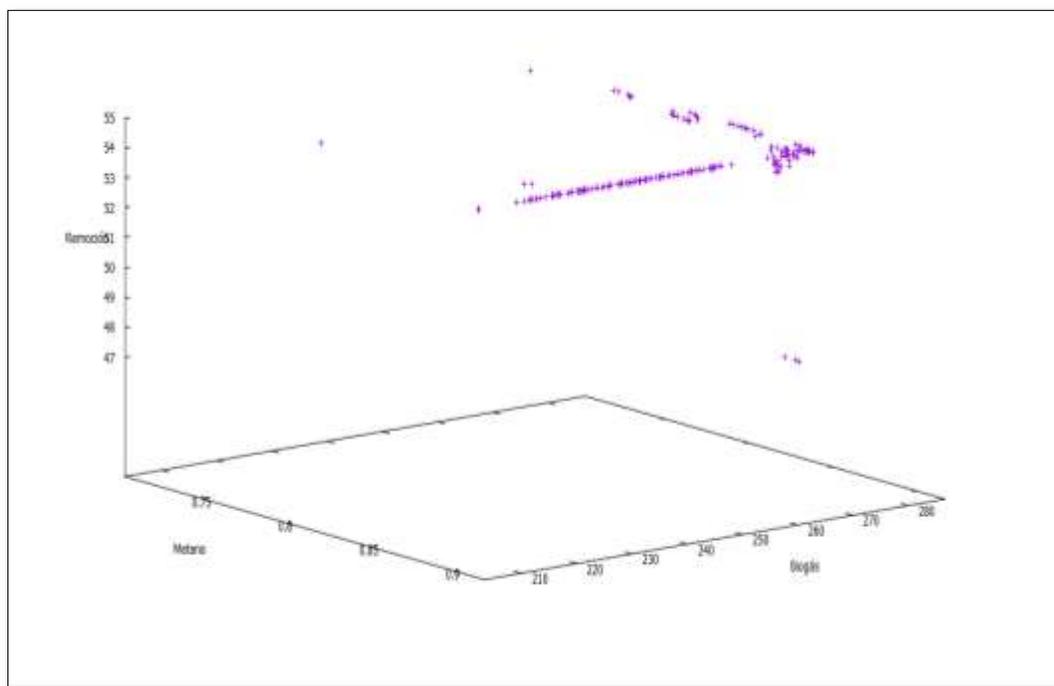


Figura 5.34 Resultados de optimización algoritmo genético multicriterio, biogás, metano y remoción.

5.8.2 Resultados Algoritmo genético multicriterio en lodo prehidrolizado térmico en modo batch en Matlab

A continuación se presentan los resultados obtenidos del algoritmo genético multicriterio desarrollado por medio de Matlab para el lodo pre hidrolizado térmico en modo *batch*. En la Tabla 5.8 se presentan las tres principales optimizaciones obtenidas del algoritmo genético.

Tabla 5.8. Datos optimizados por algoritmos genéticos para lodo pre tratado térmicamente en modo batch.

Biogás	Metano	Remoción
270.913405	0.88050689	48.5
271.994761	0.8917503	49.7622682
269.829959	0.8892548	50.7394878

Los rendimientos de biogás y metano en lodo pretratado térmicamente en modo batch se observan ligeramente inferiores a los obtenidos en la optimización del lodo con pretratamiento térmico, esto se debe a la alimentación continua del reactor, en la Figura 5.35 se presenta el frente de Pareto que muestra el comportamiento de las variables de salida biogás y metano en un mismo cuadro, para analizar el impacto de las variables de entrada en los resultados de las variables de manera conjunta, se puede observar que los mejores rendimientos de biogás y metano se dan en los 270 ml de biogás por día y 89% de rendimiento de metano.

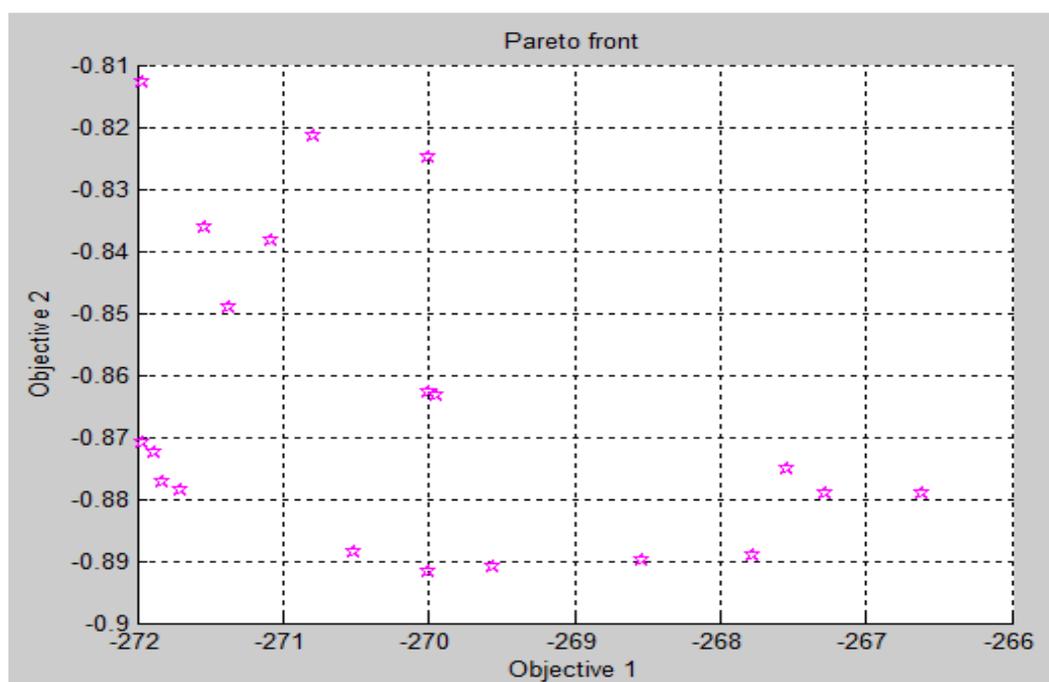


Figura 5.35 Optimización algoritmo genético multicriterio biogás y metano.

En el gráfico tridimensional (Figura 5.36) que permite visualizar el agrupamiento de los datos en la zona en donde se presenta la mayor producción de las tres variables de salida, se observa que los datos se encuentran agrupados en los índices de biogás de 265 ml y 270 ml, y un porcentaje de 85% a 90% de Metano.

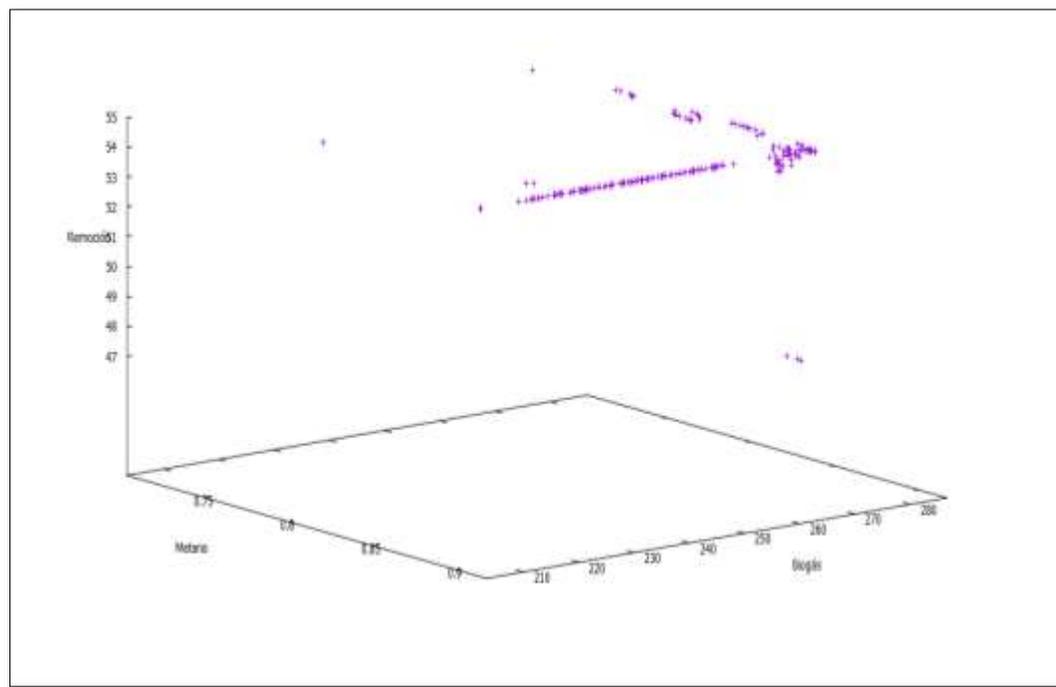


Figura 5.36 Resultados de optimización algoritmo genético multicriterio, biogás, metano y remoción para lodo con pre tratamiento térmico en modo batch.

5.8.3 Resultados Algoritmo genético multicriterio en lodo crudo en modo semi-continuo en Matlab

Para el caso del sustrato lodo sin tratamiento se presentan los resultados obtenidos del algoritmo genético multicriterio en la Tabla 5.9 muestran los tres principales resultados de la optimización, como se puede observar existe una diferencia en los resultados obtenidos con respecto al sustrato pre-tratado térmicamente, ya que no hay un pretratamiento que influya en las condiciones de operación en los rendimiento de biogás producido.

Tabla 5.9 Datos optimizados por algoritmos genéticos para lodo pre tratado térmicamente en modo batch.

Biogás	Metano	Remoción
270.91961	0.8338275	47.5
269.994761	0.8417503	51
269.829959	0.8692548	47.5

El comportamiento y los resultados obtenidos de la optimización para el lodo sin tratamiento de las variables de salida biogás y metano y se puede observar que los resultados óptimos se registran entre los 270.91 ml de biogás por día, 83 % de rendimiento de metano y 47.5 de remoción (Figura 5.37).

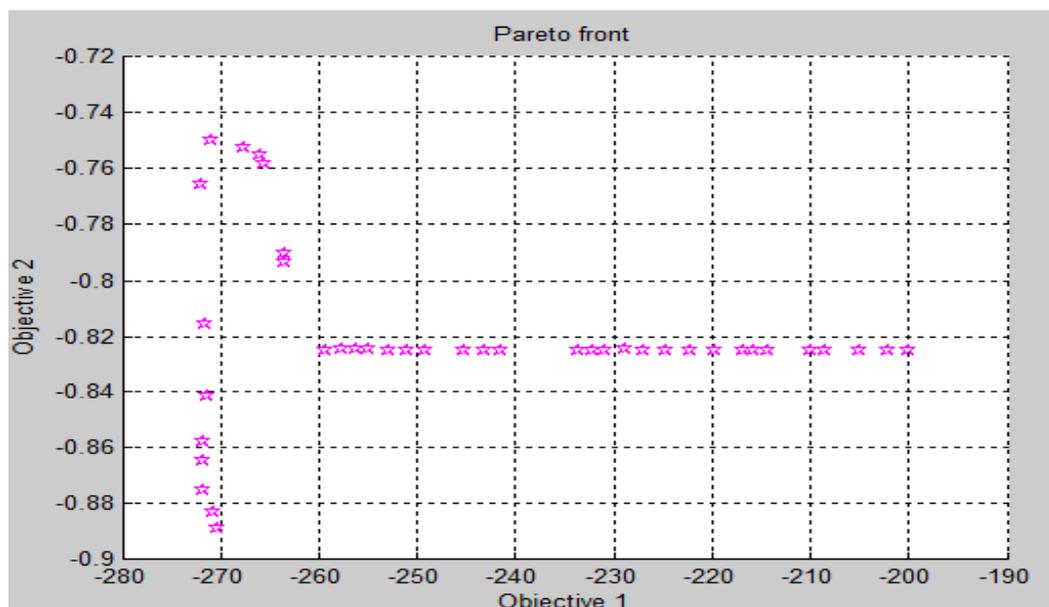


Figura 5.37 Optimización algoritmo genético multicriterio biogás y metano.

En cuanto al comportamiento de los tres criterios de salida en la gráfica tridimensional (Figura 5.38) en se muestran los índices de biogás en 270 ml a 278ml, y un porcentaje de metano 75% a 80% de Metano, cabe mencionar que los valores de producción de biogás que se registraron

superiores a 270 ml/d, presentan un bajo nivel de remoción por lo que, la selección realizada por medio de topsis, no los considera como los resultados de salida más óptimos.

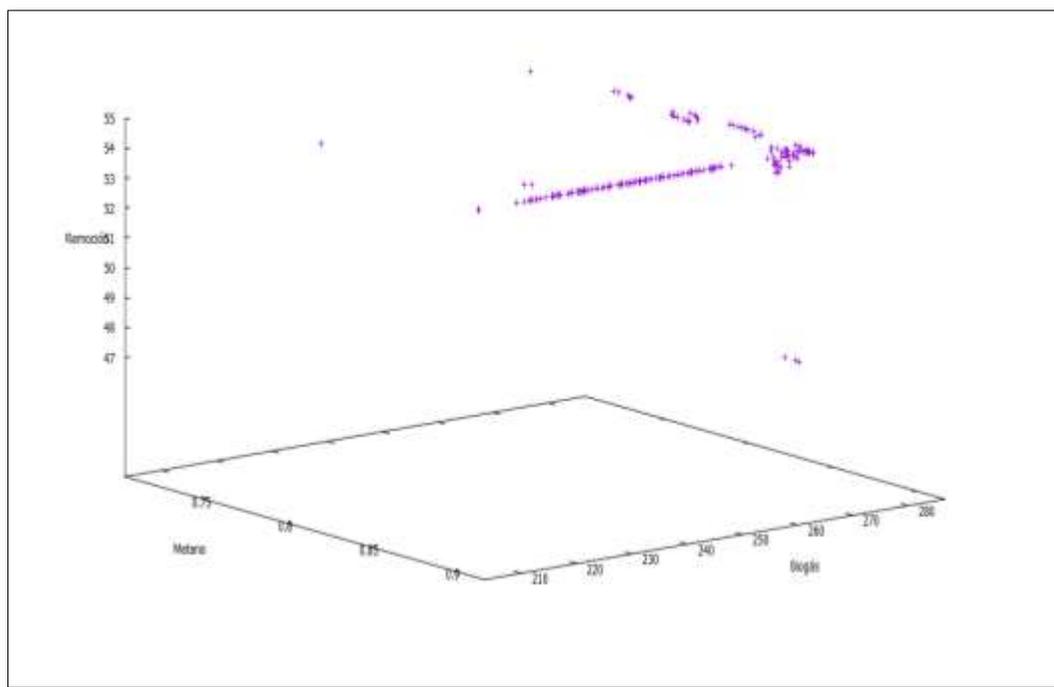


Figura 5.38 Resultados de optimización algoritmo genético multicriterio, biogás, metano y remoción para lodo crudo en operación semi continuo.

5.8.4 Resultados Algoritmo genético multicriterio en lodo crudo en modo *batch* en Matlab

En la Tabla 5.10 se presenta los datos arrojados por la optimización realizada a la base de datos del sustrato lodo sin pre-tratamiento en modo *batch*, como se puede observar los datos se muestran muy reducidos en comparación en la operación semi-continuo, en los datos obtenidos por la optimización el dato que representa una mayor producción de biogás, 266 ml de biogás, 74% de rendimiento en metano y 54.77 % en remoción

Tabla 5.10 Datos optimizados por algoritmos genéticos para lodo sin pre-tratamiento en modo batch.

Biogás	Metano	Remoción
266.794219	0.74731376	54.7565225
267.969314	0.73575831	54.3930351
266	0.69552092	54.7621001

El comportamiento y los resultados obtenidos de la optimización para el lodo sin tratamiento de las variables de salida biogás y metano y se puede observar que los resultados óptimos se registran entre los 266 ml de biogás por día, 74 % de rendimiento de metano y 54 % de remoción (Figura 5.39).

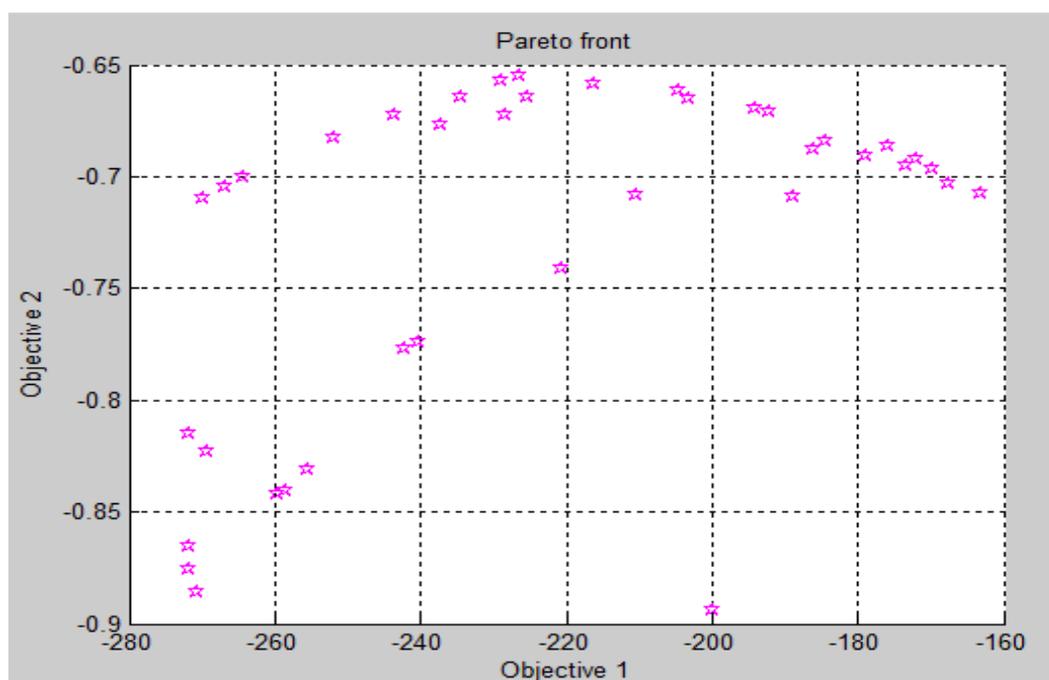


Figura 5.39 Optimización algoritmo genético multicriterio biogás y metano.

En cuanto al comportamiento de los tres criterios de salida en la gráfica tridimensional (Figura 5.40) en se muestran los índices de biogás entre 266 ml a 270ml, y un porcentaje de metano 75% a 87% de Metano.

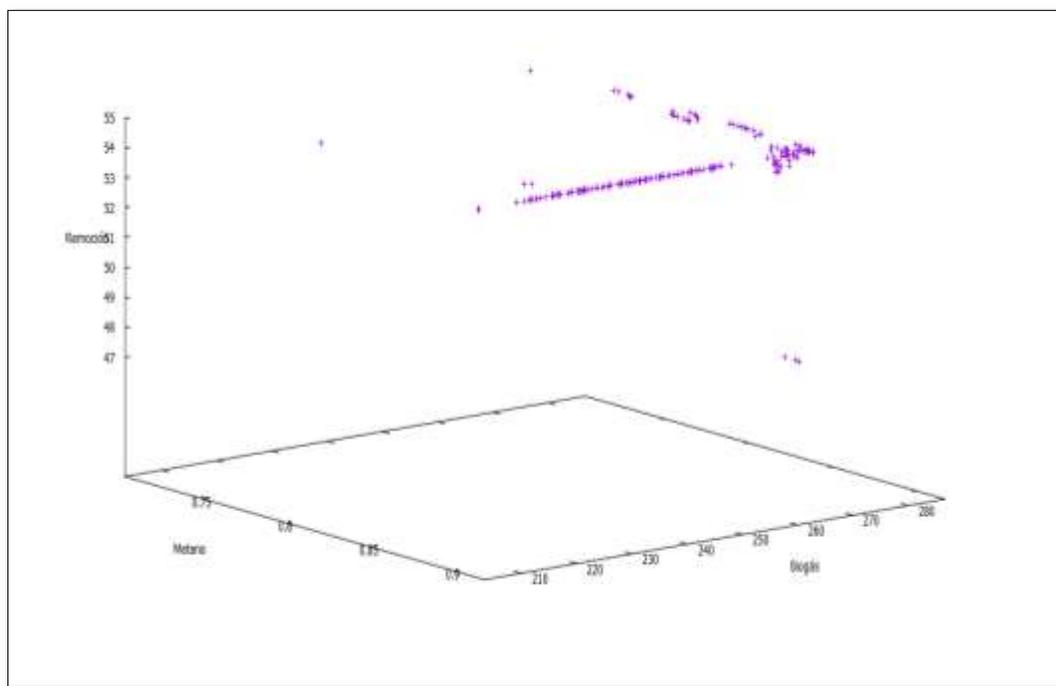


Figura 5.40 Resultados de optimización algoritmo genético multicriterio, biogás, metano y remoción para lodo crudo en operación *batch*.

5.8.5 Resultados Algoritmo genético multicriterio en pre-tratamiento ácido en operación en modo semi-continuo desarrollado en Matlab

Para la optimización de lodo con tratamiento ácido se tuvieron resultados superiores a los 272 ml de biogás, y se observa un buen rendimiento en la producción de Metano, los porcentajes oscilan entre el 87 y 88%, en la Tabla 5.11 se observan los tres obtenidos de la optimización después de haber sido analizados por medio del software TOPSIS, estos resultados indican que existe un efecto positivo en el pretratamiento realizado con ácido, sin embargo, a pesar de que los niveles de biogás y metano incrementaron, se observa una baja en la variable remoción.

Tabla 5.11 Datos optimizados por algoritmos genéticos para lodo ácido en semicontinua.

Biogás	Metano	Remoción
272	0.87	50.16
270.06	0.88	52.23
270.49	0.8714823	51.76

De acuerdo a los resultados obtenidos y observado por medio del frente de Pareto (Figura 5.41) el resultado que presenta un mejor comportamiento en relación a los dos criterios de salida de biogás el resultado óptimo es 272 ml de biogás por día, ya que presenta un 88 % de rendimiento de metano y 52 % de remoción.

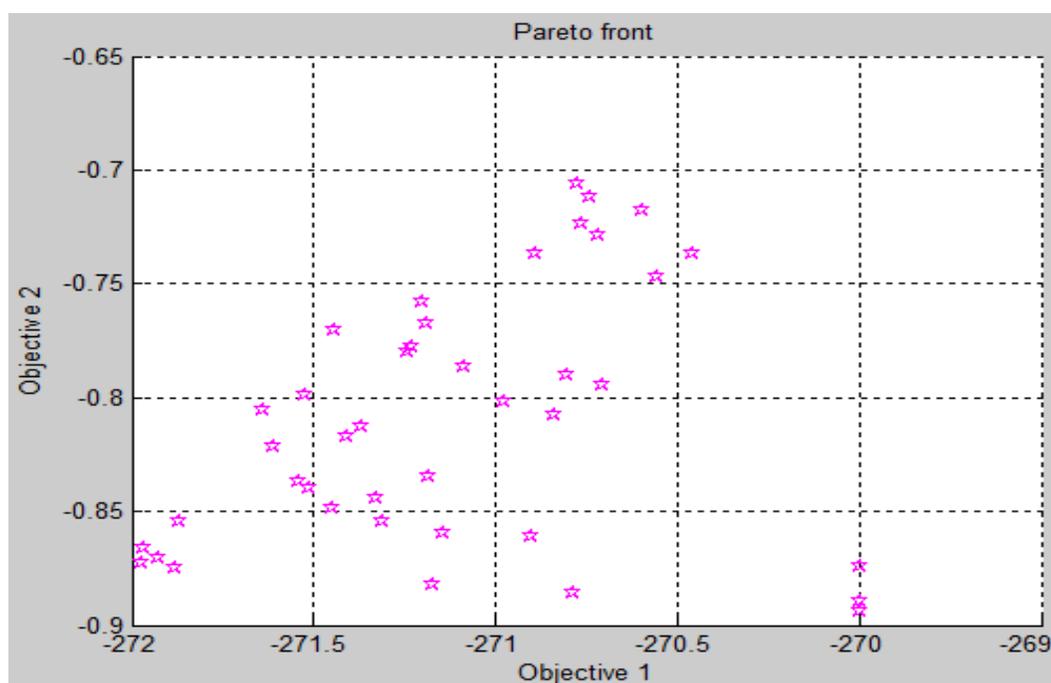


Figura 5.41 Optimización algoritmo genético multicriterio biogás y metano en lodo ácido semi continuo.

En cuanto al comportamiento de los tres criterios de salida en la gráfica tridimensional (Figura 5.42) en se muestran los índices de biogás entre 270 ml a 272ml, y un porcentaje de metano 80% a 87% de Metano, para el caso de la remoción se observa por valores de entre 45 y 50%.

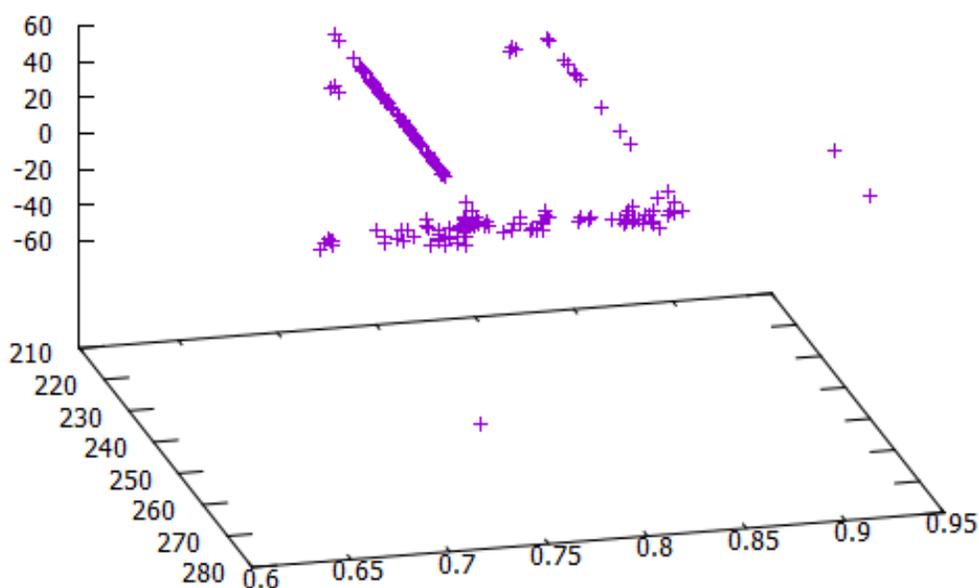


Figura 5.42 Resultados de optimización algoritmo genético multicriterio, biogás, metano y remoción para lodo ácido semi-continuo

5.8.6 Resultados Algoritmo genético multicriterio en pre-tratamiento ácido en operación batch desarrollado en Matlab.

Para la optimización de lodo con tratamiento ácido en modo batch se obtuvieron resultados entre los 268 a 270 ml de biogás, es interesante observar que a pesar de que la producción de biogás, el cálculo de rendimiento de metano se ve favorecidos y se reportaron buenos niveles de Metano, en la Tabla 5.12 se puede observar los porcentajes oscilan entre el 85 y 89, esto indica que las bacterias metanogénicas proliferaron en mayor medida en este lodo con pretratamiento ácido.

Tabla 5.12 Datos optimizados por algoritmos genéticos para lodo ácido en *batch*.

Biogás	Metano	Remoción
268.1	0.88	55.32
270.3	0.89	53.1632574
267.9	0.89	54.7622118

El resultado que se presenta demuestra un mejor comportamiento en relación a los tres criterios de salida dando un rendimiento óptimo de 200 ml de biogás por día, y un rendimiento de metano del 88 % y 58 % de remoción (Figura 5.43).

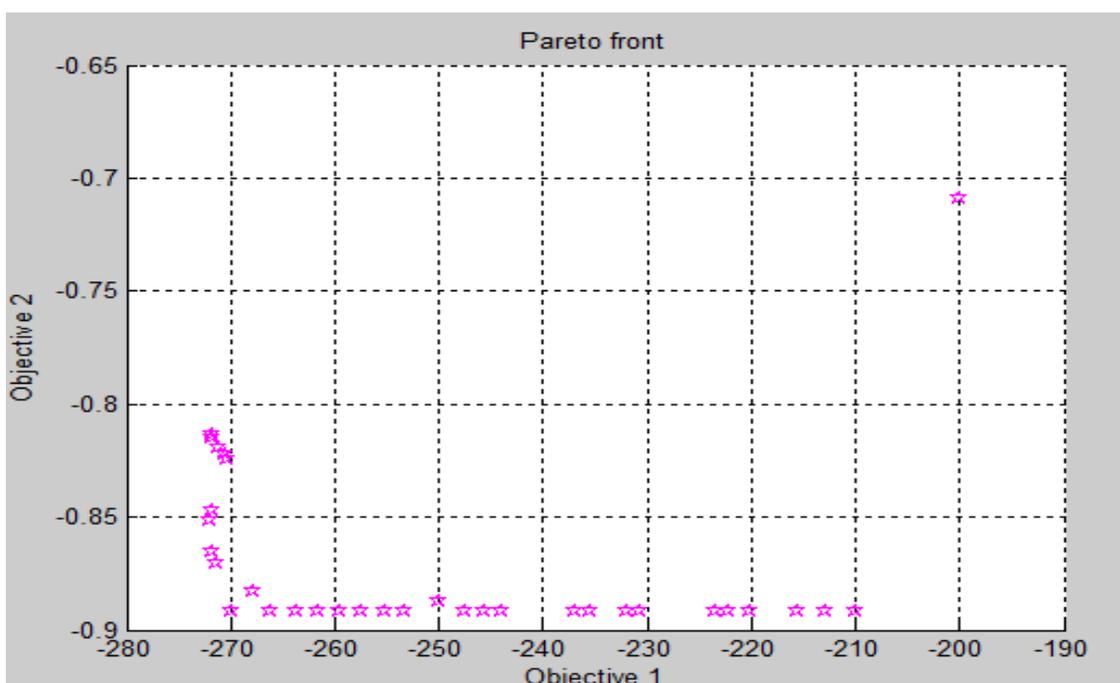


Figura 5.43 Optimización algoritmo genético multicriterio biogás y metano en lodo ácido *batch*.

Con respecto al comportamiento de los tres criterios de salida en la gráfica tridimensional (Figura 5.44) en se muestran los índices de biogás entre 268 ml a 270 ml, y un porcentaje de metano 85% a 89% de Metano.

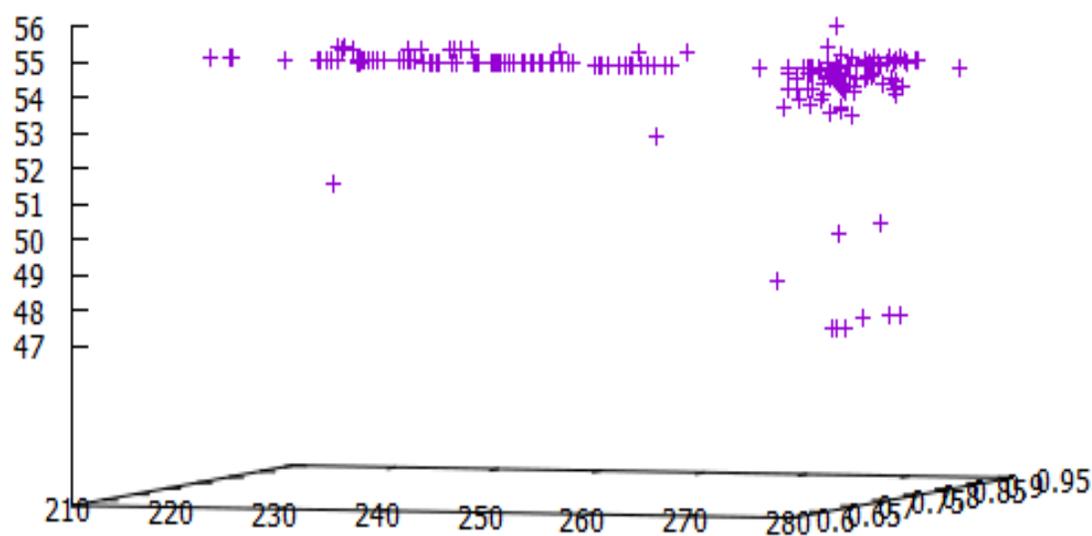


Figura 5.44 Resultados de optimización algoritmo genético multicriterio, biogás, metano y remoción para lodo ácido *batch*.

5.8.7 Resultados Algoritmo genético multicriterio en pre-tratamiento enzimático en operación semicontinua desarrollado en Matlab

En la optimización del sustrato lodo con tratamiento enzimático en modo semicontinuo se obtuvieron resultados inferiores a los registrados en la operación continua, los valores de rendimiento oscilan entre 265 a 270 ml de biogás, y presentan un buen rendimiento en la producción de Metano, con valores de entre el 85 y 88%, (Tabla 5.13).

Tabla 5.13 Datos optimizados por algoritmos genéticos para lodo ácido en batch.

Biogás	Metano	Remoción
265.1	0.85	55.32
267.3	0.86	53.1632
268.1	0.88	54.7622

El mejor rendimiento óptimo asociado a los tres criterios de salida corresponde es 268 ml de biogás por día, el cual se compone de un 88 % de rendimiento de metano y representa un 58 % de remoción (Figura 5.45)

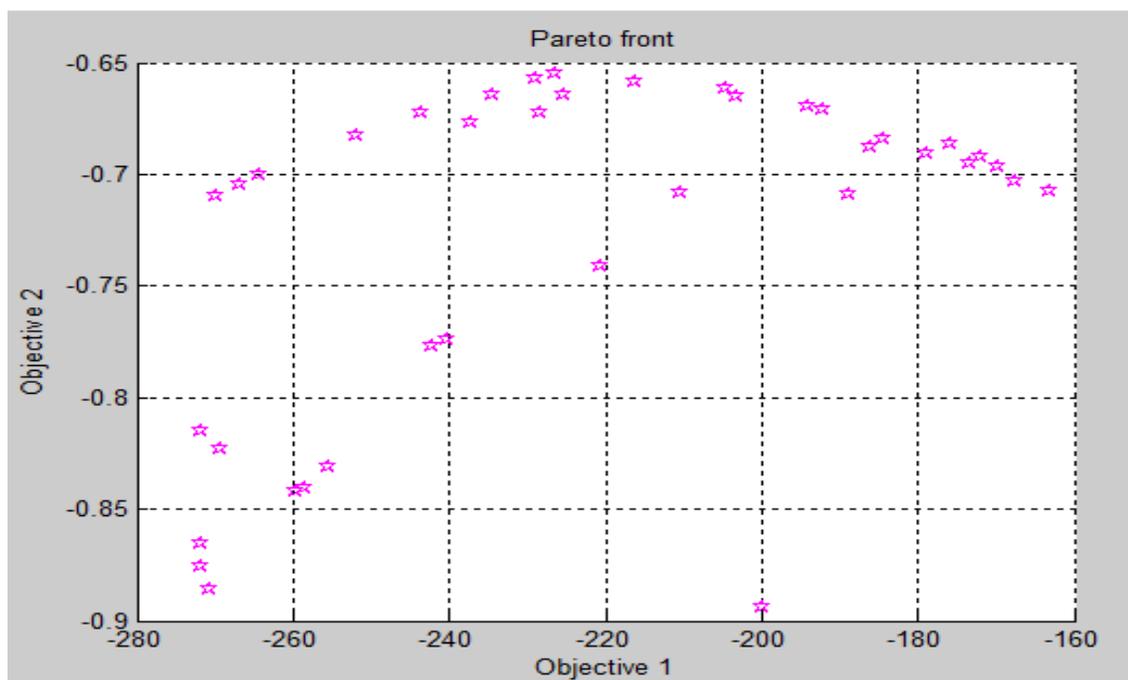


Figura 5.45 Optimización algoritmo genético multicriterio biogás y metano en lodo ácido batch.

En cuanto a la gráfica tridimensional (Figura 5.46) los resultados en producción de biogás se agrupan entre los rangos de 260 y 270 ml de biogás diario y porcentajes de metano de entre 80 y 88% con una remoción de 50 a 55%.

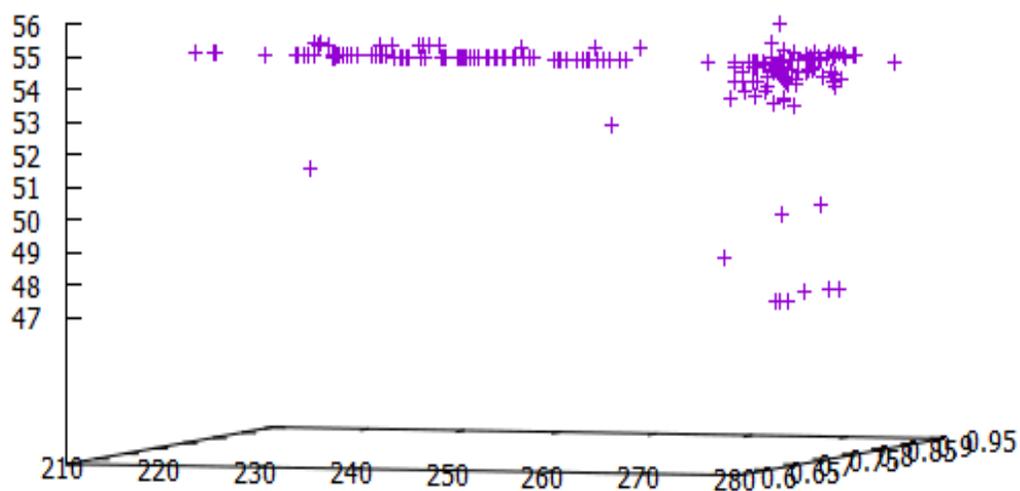


Figura 5.46 Resultados de optimización algoritmo genético multicriterio, biogás, metano y remoción para lodo ácido *batch*.

5.9 Resultados del sistema de apoyo a la toma de decisiones

La pantalla principal del sistema de apoyo se compone en la parte superior de una lista desplegable que permite seleccionar el modelo de lógica difusa o red neuronal que se desea seleccionar para hacer la predicción, en la parte inferior se encuentran 11 cajas de texto (text inbox) que permiten ingresar los datos de las 11 variables de entrada que se consideran en los modelos, a la derecha se observa tres cajas de texto que permiten visualizar los resultados al momento de pulsar la tecla calcular, en la Figura 5.47 se presenta un ejemplo de una corrida de simulación incluyendo los datos de entrada y datos de salida.

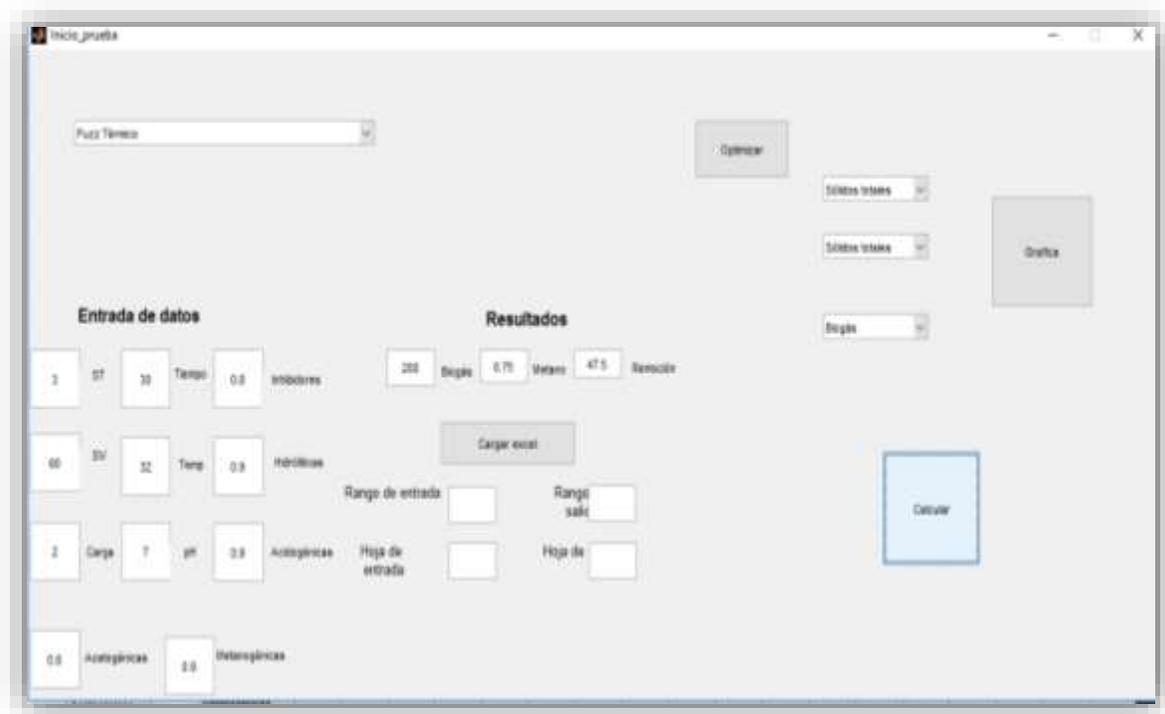


Figura 5.47 Pantalla principal del sistema de apoyo a la decisión.

El sistema cuenta con un apartado para observar los gráficos de superficies de respuesta de los modelos de lógica difusa, en este apartado se cuenta con unas listas de selección de las variables que se desean seleccionar para presentar los gráficos, (Figura 5.48).

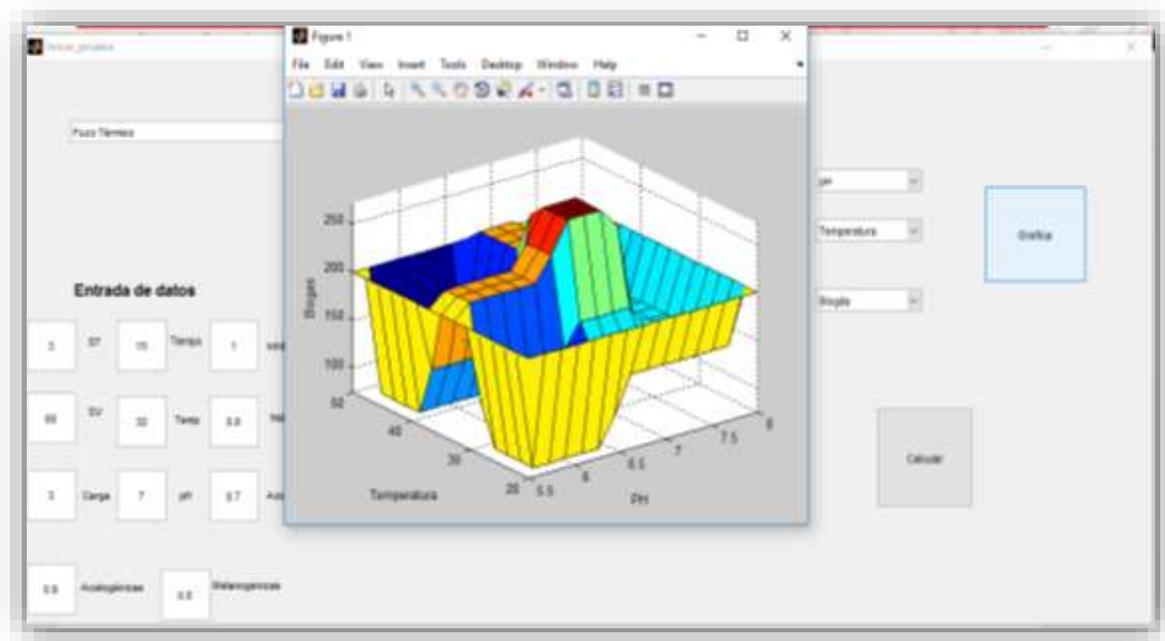


Figura 5.48 Pantalla de opciones y presentación de gráficos de superficies de respuesta.

Se puede seleccionar la opción de redes neuronales artificiales para las predicciones para ello se pueden mantener los datos capturados para simular por lógica difusa, si se pretende hacer una simulación por ambas herramientas, pero también se puede hacer un borrado y una recaptura de datos. En la Figura 5.49 se presenta un ejemplo de simulación utilizando redes neuronales artificiales.

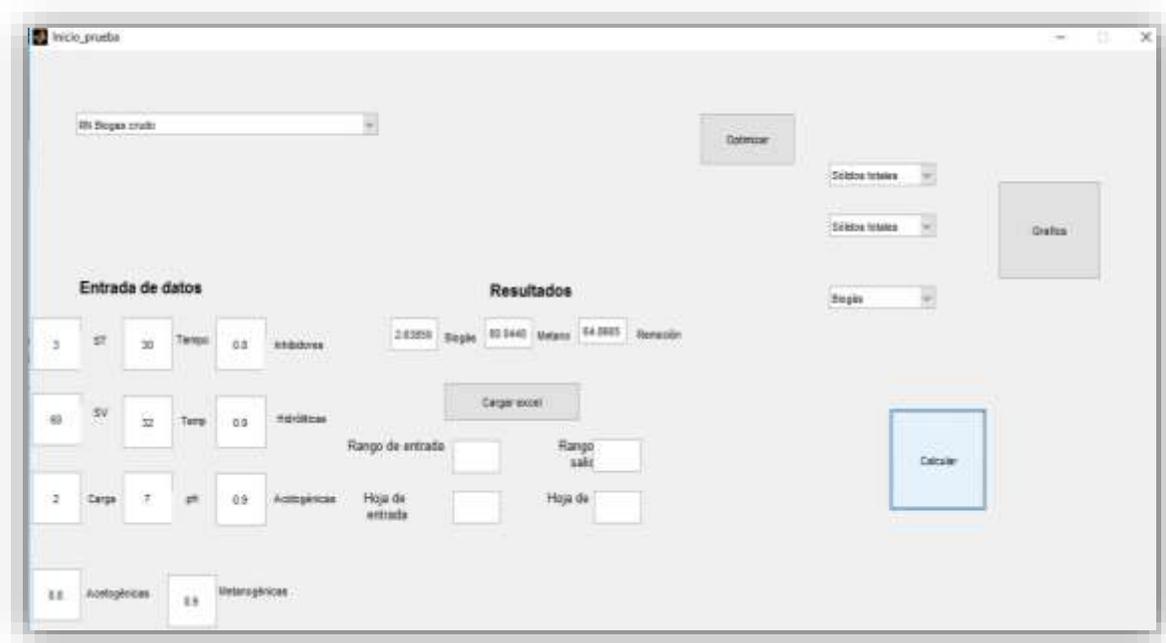


Figura 5.49 Pantalla de predicción por redes neuronales artificiales.

En la pantalla principal también se incluye una opción para hacer la simulación con archivo de datos capturados en hoja de cálculo, para facilitar el trabajo cuando se trata de hacer la predicción para una serie de datos, para ello se encuentra en la parte inferior derecha un apartado para hacer la carga y simulación de hoja de datos, para ello es necesario proporcionar los rangos de filas y columnas de los datos de entrada y los rangos de columnas y filas para los datos de salida (Figura 5.50).

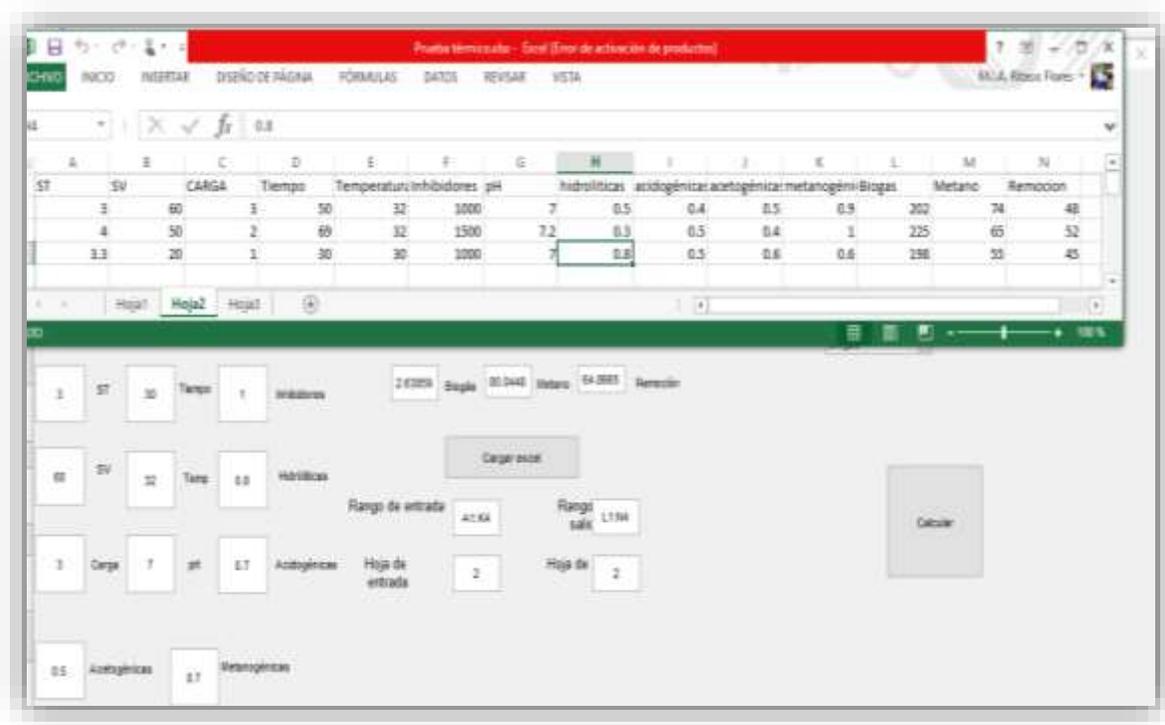


Figura 5.50 Pantalla de simulación con carga de datos desde hoja de cálculo.

Por último en la Figura 5.51 se presenta la pantalla de optimización por medio de algoritmos genéticos, en dicha pantalla de observa que ya se tiene pre-programa la función objetivo, para lo cual el usuario solo debe seleccionar los parámetros requeridos para el algoritmo genético, considerando los aspectos de optimización para el algoritmo genético multicriterio.

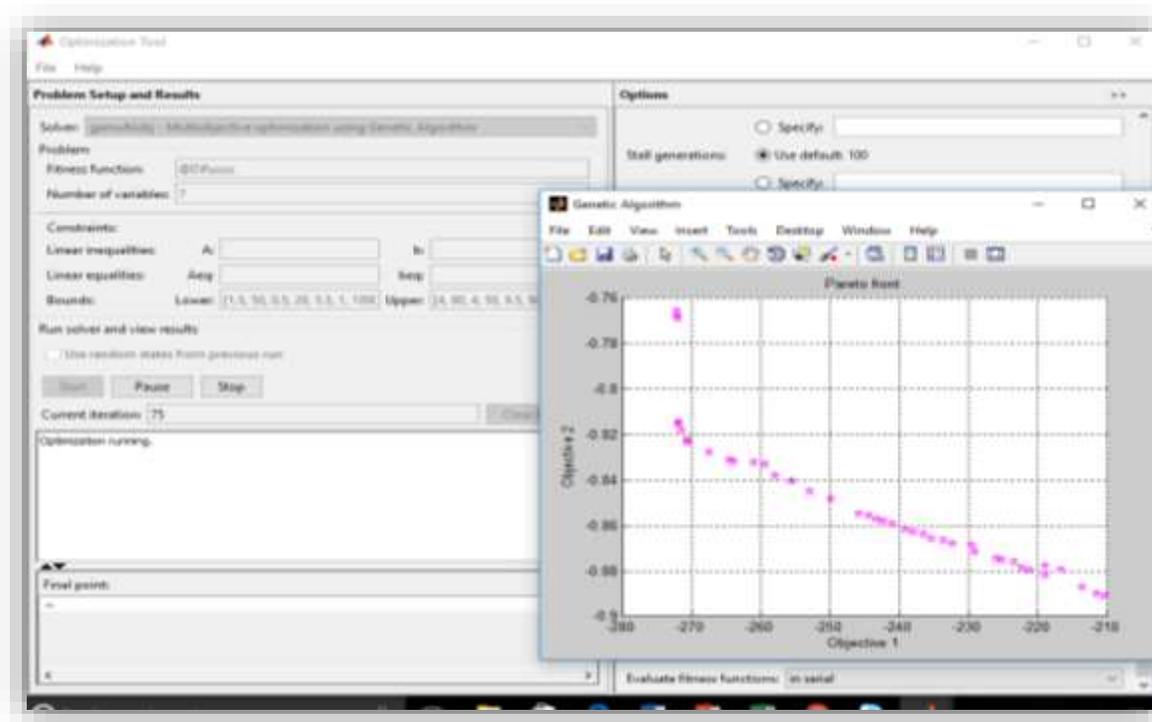


Figura 5.51 Pantalla de optimización.

5.10 Conclusión del Capítulo

En este capítulo se presentaron los resultados obtenidos en conjunto de técnicas de inteligencia artificial utilizadas en la construcción del sistema experto de apoyo a la decisión. Los modelos de lógica difusa demuestran que son una buena alternativa para determinar patrones de comportamiento capitalizando el conocimiento de los expertos.

Las redes neuronales presentaron un análisis de las variables utilizando minería de datos, haciendo una predicción de los resultados del proceso (biogas, metano y remoción), y una interpretación del factor de impacto en las variables de control que intervienen en el proceso. Por otro lado los modelos matemáticos desarrollados son una importante aportación al conocimiento científico, dichos modelos son el punto de partida para la construcción de escenarios optimizados por algoritmos genéticos. Por último el sistema de experto de apoyo a la decisión será una excelente herramienta de apoyo para los científicos en los laboratorios de investigación ambiental.

6. Conclusiones:

- Debido a que la digestión anaerobia termofílica es un proceso considerado relativamente costoso en su implementación y operación, lo que la limita su aplicación en la estabilización de lodos residuales, en el desarrollo de la presente investigación se utilizaron dos medios de sustratos lodo crudo y lodo hidrolizado, ya que el efecto combinado del pre-tratamiento térmico y la temperatura de operación del proceso, aumenta significativamente la velocidad y la capacidad de tratamiento del proceso en comparación con el tratamiento termofílico convencional, además el pre-tratamiento térmico es uno de los más empleados para el mejoramiento del proceso de digestión anaerobia porque logra una alta solubilidad y un alto porcentaje de reducción de materia orgánica al final de tratamiento de entre el 28 y 29% (Menert, et al., 2008), (Nilgun Ayman, et al., 2004), (Kim, et al., 2004).
- Al someter las mezclas al pre-tratamiento térmico, se obtuvieron porcentajes de tasa de hidrólisis entre 0.85%-6.56%, incrementándose el porcentaje de tasa de hidrólisis conforme se incrementó la temperatura y tiempo de exposición. El análisis estadístico indicó que si se deseaba maximizar el porcentaje de tasa de hidrólisis se recomienda emplear el tratamiento térmico a 90°C y 90 min. El pre-tratamiento térmico aplicado a las mezclas de sustrato resultó significativo en la producción de metano en las pruebas de biodegradabilidad, e incrementó la producción de biogás en un 50% con respecto a la prueba control, de igual manera disminuyó el TRH de 26 a 15 días, a su vez se concluyó que las mejores condiciones de operación del pre-tratamiento térmico fueron 90°C y 90 min, y así obtener un mayor rendimiento de metano y maximizar el potencial energético del proceso de digestión anaerobia.

- Con base a los resultados obtenidos al aplicar los tres pre-tratamientos, se concluye que el tiempo de exposición del pre-tratamiento es significativo para incrementar el porcentaje de tasa de hidrólisis, sin embargo, el porcentaje de tasa de hidrólisis no se puede relacionar directamente con la producción de biogás en la digestión anaerobia.
- Al someter a comparación los distintos pre-tratamientos y mezclas de sustrato durante la operación semi-continua de digestión anaerobia se concluyó que los pre-tratamientos mejoran la viabilidad de la digestión anaerobia obteniendo resultados similares al aplicar pre-tratamientos físicos, químicos o biológicos respetando las condiciones de pretratamiento sugeridas en este trabajo, hecho que permite al usuario de este proceso elegir entre estas opciones la que más le convenga en términos operacionales.
- El pre-tratamiento térmico a 90°C y 90 min fue la prueba seleccionada para llevar a operación planta piloto, ya que fue la que mejor rendimiento de metano obtuvo con respecto a los demás pre-tratamientos.
- Esta investigación contribuye a mejorar la viabilidad de la digestión anaerobia mediante la estrategia utilizada (pre-tratamiento térmico) aumentando la capacidad del proceso, la eficacia del tratamiento, la conversión de biogás, y reduce la cantidad de desechos y consumo de energía. Las condiciones de operación que se encuentran en esta investigación se pueden aplicar a los procesos anaeróbicos, incluso si desea escalar el proceso.
- El uso de técnicas de inteligencia artificial tales como lógica difusa, redes neuronales y algoritmos genéticos para el desarrollo de la investigación permitió determinar los escenarios óptimos para la máxima producción de biogás, metano y remoción de materia orgánica.
- Las redes de neuronales artificiales permitieron calcular el porcentaje de impacto de las 5 principales variables que intervienen en el proceso de digestión anaerobia. La variable que representa el mayor impacto en proceso de digestión anaerobia mesofílica fue la variable carga con porcentaje de impacto del 36.7%. La variable sólidos volátiles

representó el segundo lugar de factor de impacto con un porcentaje del 23.5%, esta variable representa al igual que la carga orgánica, las variables que miden el contenido de materia orgánica que puede ser degradado y convertida en Metano a través del proceso de digestión anaerobia, en tercer lugar, tiempo de residencia hidráulica, en cuarto sólidos totales y en quinto pH, con porcentajes de impacto de 17.5%, 14.5 % y 7.9 % respectivamente.

- El uso de técnicas de inteligencia artificial tales como lógica difusa y redes neuronales para el desarrollo de la investigación permitió determinar el comportamiento de las variables, para poder estimar el impacto de cada una de ellas en la máxima producción de biogás y metano. Para la validación de los resultados obtenidos se determinó el coeficiente de correlación del modelo de lógica, fue superior al 0.9, teniendo mayor correlación en los resultados obtenidos por lógica difusa considerando la comparación del trabajo con datos obtenidos experimentalmente.
- A su vez, para la validación de los resultados obtenidos en lógica difusa, se generó una interpretación de las superficies de respuesta obtenidas para cada variable de salida, las cuales se analizaron para determinar el comportamiento de las variables de entrada (temperatura, pH, carga orgánica, tiempo de operación, sólidos totales y volátiles) y las interacciones entre ellas mismas, y en base a los comportamientos se puede concluir que las variables con mayor impacto en el proceso son la variable carga orgánica, sólidos volátiles y tiempo de operación, se observa una importante diferencia en el caso de la comparación con los resultados obtenidos en redes neuronales con respecto al modelo de lógica difusa, se observa que la variable no es considerada como variable de alto impacto en redes neuronales, pero sin embargo en las superficies de respuesta se plantea muy marcada el área de factibilidad, y esto es debido a que los datos con los que se entrenó la red neuronal artificial son datos experimentales que se operaron en condiciones óptimas y por lo tanto se operaron en parámetros permitidos de 7 a 7.5, por lo que podemos decir que existe poca variación en dicha variable, y esto provoca que la red neuronal artificial la reconozca como una variable de poco impacto.

- El algoritmo genético multicriterio mostró la configuración óptima de las variables de entrada del proceso de digestión anaerobia mesofílica la cual permite tener un máximo valor en las variables de salida de manera individual. Se llevó a cabo la optimización multicriterio a través de Matlab.
- Los resultados obtenidos muestran los escenarios óptimos de operación del proceso de digestión anaerobia mesofílica, ya que a través de éstos es posible hacer una predicción de los valores óptimos para maximizar los rendimientos en la generación de biogás y la calidad de los biosólidos producidos, a su vez sirve de apoyo a la toma de decisiones ya que al proyectar los escenarios óptimos de aplicación del proceso permite hacer una evaluación en términos de rentabilidad económica, ya que al conocer las condiciones óptimas del proceso es posible minimizar tanto el tiempo de experimentación en el laboratorio como los recursos empleados.
- Un sistema de apoyo a la decisión que integre redes neuronales artificiales, lógica difusa y algoritmos genéticos es una herramienta útil para la predicción de rendimiento de biogás metano y remoción, con la finalidad de optimizar recursos y mejorar los resultados esperados

Evolución estado del arte del tema en estudio

El proceso de digestión anaerobia ha sido tema que ya ha sido abordado por diversas investigaciones, varios autores han hecho aportaciones al proceso, en algunos casos han utilizado herramientas de inteligencia artificial, algunos de ellos se centran en el control, diseño y operación de bio-reactores.

En el año 2010, Waewsak y colaboradores presentan un sistema de control desarrollado para el reactor anaeróbico híbrido (AHR), para ello desarrollaron una red neuronal artificial y un modelo de lógica difusa, considerando las variables pH, ácidos volátiles totales (ATV) y alcalinidad (ALK) en el efluente del reactor anaerobio. El resultado del trabajo presenta un

incremento en la producción de biogás, un aumento en la eficiencia de eliminación de DQO y una adecuada estabilización del proceso (Waewsak et al.2010). Centrándose en el control del reactor y considerando solo algunas variables que intervienen en el proceso, dejando de lado algunas otras como la temperatura, la carga orgánica y el conjunto de microorganismos que son determinantes para el óptimo progreso del proceso y de sus resultados en rendimiento de biogás y metano.

Otros investigadores aportaron herramientas de monitoreo del proceso, tratando de controlar variables importantes del proceso realizaron estudios utilizando desechos orgánicos de un restaurante, con el fin de evaluar el efecto de la temperatura en la calidad del biogás obtenido y la concentración volumétrica de metano (CH_4) y dióxido de carbono (CO_2).Se desarrolló un sistema de lógica difusa como controlador de los niveles de temperatura, sin embargo; no se incorporó información de los fenómenos fisicoquímicos dentro del reactor, por lo que no se obtuvo ningún modelo matemático del proceso. (Ruge Ruge & Hernández Sarabia, 2011).

En el caso de trabajo realizado por Polit en el 2002, utilizan la lógica difusa para determinar un coeficiente de impacto de las variables pH y temperatura, el resultado de modelo difuso se introduce a un modelo matemático para calcular el balance de masas, los parámetros de pH y temperatura no se encuentran calculados explícitamente en el modelo matemático, por lo que se multiplica el coeficiente de pH y temperatura obtenidos por el modelo difuso con la tasa de crecimiento estimado para la biomasa, los resultados obtenidos se comparan con datos experimentales del proceso (M. Polit et al, 2002). Sin embargo, las metodologías empleadas en los modelos de lógica difusa son muy simples y con un número amplio de variables de operación, sin olvidar que no hay reportes de sistemas expertos de apoyo a la decisión que integren múltiples herramientas de inteligencia artificial.

Aportación de la investigación al conocimiento científico

Al hacer uso de herramientas de inteligencia artificial (RNA y LD) se logra identificar el patrón de comportamiento de las variables que intervienen el proceso de digestión anaerobia,

incluyendo modelos de lógica difusa que interpretan el comportamiento de microorganismos dentro del proceso.

Se logra determinar el rendimiento energético de los residuos agroindustriales y la comparación de los rendimientos utilizando tres diferentes pretratamientos para la aceleración del proceso de hidrólisis en el PDAM.

La aportación de este trabajo establece una metodología de cinco etapas para el desarrollo de un sistema experto de apoyo a la decisión para evaluar y optimizar los lodos pretratados del PDAM., para mejorar los rendimientos de biogás y metano a partir de residuos agroindustriales para su aprovechamiento con fines energéticos.

Por medio de las redes neuronales artificiales se identificaron las variables de control impactantes en el proceso de digestión anaerobia mesofílica, pH, temperatura, carga, sólidos totales y sólidos volátiles, así como, a través de los modelos de lógica difusa se estimaron los parámetros de operación óptimos para la proliferación de microorganismos anaerobios.

En resumen, las aportaciones de este trabajo de investigación al conocimiento son:

- Una metodología de evaluación de lodos con tres diferentes pretratamientos.
- El análisis y modelación por medio de técnicas de inteligencia artificial de variables de operación como, sólidos totales, sólidos volátiles, carga, tiempo de operación, inhibidores y microorganismos, que no han sido exploradas en el estado de arte.
- Una metodología de cinco etapas para el desarrollo de un sistema experto que incluye el comportamiento de grupos de microorganismos anaerobios.
- Aporta la definición de modelos matemáticos multicriterio que determinan una correcta operación del proceso de digestión anaerobia.
- Esta investigación permite evaluar y optimizar a través de algoritmos genéticos un proceso microbiológico para el aprovechamiento de la biomasa, incrementando los rendimientos de biogás, metano y remoción.
- Aporta una nueva metodología para capitalizar el conocimiento de los expertos del área de ambiental a partir de modelos de lógica difusa.
- El desarrollo de un sistema experto de apoyo a la decisión que servirá de herramienta para los laboristas, que permitirá el ahorro de costos y tiempo de experimentación, ya

que permitirá hacer una predicción de los resultados en términos de rendimientos de biogás, metano y remoción.

- La incursión de técnicas de inteligencia artificial en la predicción de un proceso de biodegradación de la materia.

Productividad

Los productos derivados del presente trabajo de investigación son resultado del conocimiento alcanzado durante el periodo del desarrollo e investigación de un sistema experto de soporte a la decisión para determinar la rentabilidad de los procesos de digestión anaerobia mesofílica de lodos residuales fisicoquímicos.

A continuación se presentan los productos académicos alcanzados:

- Presentación en el Doctoral Consortium del Congreso: “Desarrollo de un sistema de soporte a la decisión para determinar la rentabilidad de los procesos de digestión anaerobia mesofílica utilizando técnicas de inteligencia artificial”. Consorcio Doctoral; MICAI; Chiapas: Noviembre 2014.
- Artículo publicado: *“Use of artificial neuronal networks for prediction of the control parameters in the process of anaerobic digestion with thermal pre-treatment”* Journal of Environmental Science and Health, Part A. Taylor & Francis, pertenece al JCR con factor de impacto = 1.425

Artículos por enviar:

- *“Analysis of the behavior of the operation parameters in the Anaerobic Digestion process with thermal pre-treatment, using fuzzy logic”*, Journal of Environmental

Science and Health, Part A. Taylor & Francis, pertenece al JCR con factor de impacto = 1.425

- “Multicriteria Optimization through Genetic Algorithms of the Mesophylic Anaerobic Digestion Process” Journal of Environmental Science and Health, Part A. Taylor & Francis, impact factor = 1.425

Aportación tecnológica

- La aportación de un Sistema Experto de Apoyo a la Decisión para el proceso de digestión anaerobia del tratamiento de lodos residuales industriales de un proceso avícola. Este Sistema Experto será registrado ante INDAUTOR para obtener sus Derechos de Autor lo pueda ser utilizado por una empresa avícola del Grupo Porres S.A. de C.V.

Referencias bibliográficas:

- Appels, L., Dewil, R., Baeyens, J., & Degreève, J. (2008). Ultrasonically enhanced anaerobic digestion of waste activated sludge. *International Journal of Sustainable Engineering*, 1(2). , 94-104.
- Acosta-Cervantes, M.C.; Villarreal-Marroquín, M.G.; Cabrera-Ríos, M. Estudio de validación de un método para seleccionar técnicas de pronóstico de series de tiempo mediante redes neuronales artificiales. *Ing. Investig. y Tecnol.* **2013**, 14(1), 53–63.
- A guide to the biosolids risk assessments US Environmental Protection Agency. EPA part 503 rule, Washington, D. C. 1996.
- Ahring, B. K., Sandberg, M. and Angelidaki, I. 1995. Volatile fatty acids as indicators of process imbalance in anaerobic digesters. *Applied microbiological Biotechnology*. 43(3):559-565.
- Ahring, B.K., Angelidaki, I., Johansen, K. (1992). Anaerobic treatment of manure together with industrial waste. *Water Science Technology*. Vol. 25 (7), pag. 311-318.
- Ahring, B.K., Mladenovska Z., Iranpour R. y Westermann, P. (2002). State of the art and future perspectives of thermophilic anaerobic digestion. *Wat. Sci. Tec.* 45(10), 293-298.
- Alatraste-Mondragón, Felipe; Samar, Parviz; Cox, Huub H. J; Ahring, Birgitte K; Iranpour, Reza (2006). Anaerobic Codigestion of Municipal, Farm, and Industrial Organic Wastes: A Survey of Recent Literature. *Water Environment Research*. Volume 78, Number 6, June 2006, pp. 607-636(30)
- Anderson, N.J.; Dixon, D.R.; Harbour, P.J.; Scales, P.J. Complete characterization of thermally treated sludges. *Water Sci. Technol.* 2002, 46 (10), 51–54.
- Angelidaki, I., Ellegaard, L. and Ahring, B.K. 1999. A comprehensive model of anaerobic bioconversion of complex substrates to biogas. *Biotechnology and Bioengineering*. 63(3):363-372.
- Appels, L.; Degreève, J.; Van der Bruggen, B.; Van Impe, J.; Dewil, R. Influence of lowtemperature thermal pre-treatment on sludge solubilisation, heavy metal release and anaerobic digestion. *Bioresour. Technol.* 2010, 101(15), 5743-5748.

- Aquino, S.F. and Stuke, D.C. 2007. Bioavailability and toxicity on metal nutrients during anaerobic digestion. *Journal of environmental Engineering*. 133(1): 28-35.
- Aranowski, R., Hupka, J., Jungnickel, C., 2010. Changes in Rheological Properties during Anaerobic Digestion of Activated Sludge. *Physicochemical Problems of Mineral Processing*. (44), 13-22.
- Ahring, B. K. y Westermann, P. 1987. Thermophilic anaerobic degradation of butyrate by a Butyrate-utilizing bacterium in coculture and triculture with methanogenic bacteria. *Applied and Environmental Microbiology*., 53(2):434-439
- Ahring, B. K., Sandberg, M. y Angelidaki, I. 1995. Volatile fatty acids as indicators of process imbalance in anaerobic digestors. *Applied microbiological Biotechnology*., 43(3):559-565.
- Alastair J. Ward, Phil J. Hobbs, Peter J. Holliman, David L. Jones. 2008. Optimisation of the anaerobic digestion of agricultural resources. *Bioresource Technology*, Volume 99. Pages 7928-7940.
- Altunay Perendeci, Sever Arslan, Serdar S. Çelebi, Abdurrahman Tanyolaç. 2008. Prediction of effluent quality of an anaerobic treatment plant under unsteady state through ANFIS modeling with on-line input variables. *Chemical Engineering Journal*, Volume 145. Pages 78-85.
- Angelidaki, I. y Ahring, B.K. 1993. Thermophilic anaerobic digestion of livestock waste: the effect of ammonia. *Applied Microbiology and biotechnology*., 38(1): 560-564.
- Angelidaki, I. y Ahring, B.K. 1997. *Anaerobic digestion in Denmark*. Past, Lleida.
- Angelidaki, I., Ellegaard, L. y Ahring, B.K. 1999. A comprehensive model of anaerobic bioconversion of complex substrates to biogas". *Biotechnology and Bioengineering*., 63(3):363-372.
- Antoine Genovesi, Jérôme Harmand, Jean-Philippe Steyer. 1999. A fuzzy logic based diagnosis system for the on-line supervision of an anaerobic digester pilot-plant Original Research Article. *Biochemical Engineering Journal*, Volume 3. Pages 171-183.
- Atenodoro-Alonso, J.; Ruíz-Espinoza, J.E.; Alvarado-Lassman, A.; Martínez-Sibaja, A.; Martínez-Delgadillo, S.A.; Méndez-Contreras, J.M. The enhanced anaerobic

- degradability and kinetic parameters of pathogenic inactivation of waste water sludge using pre- and post-thermal treatments part 2. *Revista Mexicana. Ingen. Quim.* **2015**, *14(2)*, 311–319.
- Bagi, Z., Acs, N., Bálint, B., Horváth, L., Dobó, K., Perei, K. R., Rákhely, G. and Kovács, K. 2007. Biotechnological intensification of biogas production. *Applied Microbiology and Biotechnology.* 76:473–482.
 - Bermudez, J. J., Canovas, M., Manjon, A., Iborra, J. L., & Howell, J. A. (1988). *La digestión anaerobia*. Universidad de Murcia.
 - Buckley, J.J.; Feuring, T. *Fuzzy and Neural; Interactions and applications*. Ed. Springer, New York 1999.
 - Bailey, W. J., Weir, I. S., 1998. Investigation of methods for direct rheological model parameter estimation. *Journal of Petroleum Science and Engineering.* 21(1–2), 1-13.
 - Balagurusamy, N. 2005. Anaerobic bioremediation – an untapped potencial, *Revista Mexicana de Ingeniería Química*, 4(3): 273- 287
 - Bourcier, Daniéle, *Inteligencia Artificial y Derecho*. Editorial UOC, S. L., 2003.
 - Cabirol, N., Mendoza, S. L., Noyola, R., & Fernán, A. (2000). Estabilización de lodos municipales por digestión anaerobia termófila: metodología de seguimiento de las bacterias metanógenas por PCR(reacción en cadena de la Polimerasa) durante la adaptación de un inóculo mesófilo a condiciones termófilas. XXVII Congreso Interamericano de Engenharia Sanitária e Ambiental, Rio Grande do Sul, Brasil.
 - Castells, X. E. (2012). *Biomasa y bioenergía*. Madrid: Ediciones Díaz de Santos.
 - Cabirol, N., Mendoza, S. L., Noyola, R., A., Fernández P. F. J., Cisneros O. M. 2000. Estabilización de lodos municipales por digestión anaerobia termófila: metodología de seguimiento de las bacterias metanógenas por PCR(reacción en cadena de la Polimerasa) durante la adaptación de un inóculo mesófilo a condiciones termófilas. *Memorias del XXVII Congreso Interamericano de Engenharia Sanitária e Ambiental*, Rio Grande do Sul, Brasil.
 - Carlos Alberto Coelho Belchior, Rui Alexandre Matos Araújo, Jorge Afonso Cardoso Landeck. 2012. Dissolved oxygen control of the activated sludge wastewater treatment process using stable adaptive fuzzy control. *Computers & Chemical Engineering*, Volume 37. Pages 152-162.

- Carlos García-Diéguez, Olivier Bernard, Enrique Roca. 2013. Reducing the Anaerobic Digestion Model No. 1 for its application to an industrial wastewater treatment plant treating winery effluent wastewater. *Bioresource Technology*, Volume 132. Pages 244-253.
- Chen, Y.; Cheng, J.J.; Creamer, K.S. Inhibition of anaerobic digestion process: A review. *Bioresour. Technol.* **2008**, 99(10), 4044–4064
- Chaiwat Waewsak, Annop Nopharatana, Pawinee Chaiprasert. 2010. Neural-fuzzy control system application for monitoring process response and control of anaerobic hybrid reactor in wastewater treatment and biogas production. *Journal of Environmental Sciences*, Volume 22. Pages 1883-1890.
- Chegini, G.R.; Khazaei, J.; Ghobadian, B.; Goudarzi, A.M. Prediction of process and product parameters in an orange juice spray dryer using artificial neural networks. *J. Food Eng.* **2008**, 84(4), 534–543.
- Chaiwat Waewsak, Annop Nopharatana, Pawinee Chaiprasert. Diciembre 2010, *Journal of Environmental Sciences*, Volume 22, Issue 12, Pages 1883-1890.
- Chien-Hsien Wen, C.A. Vassiliadis . 1998. Applying hybrid artificial intelligence techniques in wastewater treatment Original Research Article, *Engineering Applications of Artificial Intelligence*, Volume 11, Pages 685-705.
- Dilek Erdirencelebi, Sukran Yalpir. 2011. Adaptive network fuzzy inference system modeling for the input selection and prediction of anaerobic digestion effluent quality. *Applied Mathematical Modelling*. Volume 35. Pages 3821-3832.
- Dalzell, H., Biddlestone, A., Gray, K. & Thurairajan, K., 1991. Manejo del suelo: producción y uso del composte en ambientes tropicales y subtropicales.. Roma: Organización de las Naciones Unidas para la Agricultura y la Alimentación.
- Diego Mas, J. A., Optimización de la distribución en planta de instalaciones industriales mediante algoritmos genéticos. Aportación al control de la geometría de las actividades. Departamento de Proyectos de Ingeniería, Universidad Politécnica de Valencia, 2006.
- Díaz-González, L.; Hidalgo-Dávila, C.A.; Santoyo, E.; Hermosillo-Valadez, J. Evaluación de técnicas de entrenamiento de redes neuronales para estudios

- geotermométricos de sistemas geotérmicos. *Revista Mexicana. Ingen. Quim.* **2013**, *12*(1), 105–120.
- E.B. Gueguim Kana, J.K. Oloke, A. Lateef, M.O. 2012. Modeling and optimization of biogas production on saw dust and other co-substrates using Artificial Neural network and Genetic Algorithm. *Renewable Energy*, Volume 46, Pages 276-281.
 - E.F Carrasco, J Rodríguez, A Puñal, E Roca, J.M Lema .2002. Rule-based diagnosis and supervision of a pilot-scale wastewater treatment plant using fuzzy logic techniques Original Research Article. *Expert Systems with Applications*. Volume 22Pages 11-20.
 - E.F. Carrasco, J. Rodríiguez, A. Puñal, E. Roca, J.M. Lema. 2004. Diagnosis of acidification states in an anaerobic wastewater treatment plant using a fuzzy-based expert system. *Control Engineering Practice*. Volume 12.Pages 59-64.
 - Ernst Murnleitner, Thomas Matthias Becker, Antonio Delgado. 2002. State detection and control of overloads in the anaerobic wastewater treatment using fuzzy logic. *Water Research*, Volume 36. 2002. Pages 201-211.
 - Enrique Yacuzzi y Víctor M. Rodríguez. 1995. Diseño e implantación de un sistema de apoyo a las decisiones basado en el modelo de transporte. Universidad del CEMA. Universidad de Belgrano.
 - Ferry, J. G. (Ed.). 1994. *Methanogenesis. Ecology, physiology & genetics*. Chapman & Hall. USA.
 - F. Ilter Turkdogan-Aydinol, Kaan Yetilmezsoy. 2010. A fuzzy-logic-based model to predict biogas and methane production rates in a pilot-scale mesophilic UASB reactor treating molasses wastewater. *Journal of Hazardous Materials*, Volume 182, Pages 460-471.
 - Gallert, C.; Winter, J. Propionic acid accumulation and degradation during restart of a full-scale anaerobic biowaste digester. *Bioresour. Technol.* **2008**, *99*(1), 170–178.
 - Gavala H. N.; Yenil U.; Skiadas I.V.; Westermann P.; Ahring B.K.; 2003. Mesophilic and thermophilic anaerobic digestion of primary and secondary sludge. Effect of pretreatment at elevated temperature. *Water Research*, Vol 37, 4561-4572.
 - Gallegos M, Celis LB, Razo–Flores E. Competencia por sustrato durante el desarrollo de biomasa sulfatorreductora a partir de un lodo metanogénico en un reactor UASB.

Revista internacional de contaminación ambiental [revista en internet]* Mayo 2010. [acceso 20 Mayo 2015]; 26(2). Disponible en: http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0188-49992010000200002

- Girovich, M. J. 1996. Biosolids Treatment and Management. Ed Marcel Decker, Inc . N. Y., E.U.A.
- Goldberg, D. (1989) Genetics Algorithms in Search, Optimization and Machine Learning. Addison Wesley.
- Guadarrama, S.(2000) Representación del conocimiento impreciso: Revisión parcial de las teorías de conjuntos borrosos. Ed Facultad de informática. Universidad Politécnica de Madrid.
- Gueguim Kana, E., Oloke, J., Lateef, A. & Adesiyun, M., 2012. Modeling and optimization of biogas production on saw dust and other co-substrates using Artificial Neural network and Genetic Algorithm. Elsevier, Volumen 46, pp. 276-281.
- Harmon, P. & King, D., 1985. Sistemas expertos. Aplicaciones de la inteligencia artificial en la actividad empresarial. Madrid: Díaz de Santos.
- Hansen, K., Angelidaki, I. y Ahring, B.K. 1998. Anaerobic digestion of swine manure: inhibition by ammonia. Wat. Res., 32(1): 5-12.
- Henze, M., Gujer, W., Mino, T., Matsuo, T., Wentzel, M. y Marais G. 1995. Activated Sludge model n° 2. IAWQ Scientific and Technical Report n°3. Int. assoc. Water Qual. Londres.
- Hill, D. T. y Holmberg, R. D. 1988. Long chain volatile fatty acid relationship anaerobic digestion of swine waste. Biological wastes., 23:195-214.
- Hills, D.J. y Nakano, K. 1984. Effects of particle size on anaerobic digestion of tomato solid wastes. Agricultural wastes., 10:285-295.
- Holland, John H, Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence, University of Michigan Press, 1975.
- Instituto para la Diversificación y Ahorro de la Energía (IDAE). (2007). Biomasa: Digestores anaerobios. Madrid, España.

- Iza, J. 1995. Control del proceso anaerobio. I curs d'enginyeria ambiental. Universitat de Lleida. Lleida.
- Izquierdo, I. G. (Ed.). (2005). El género textual y la traducción: Reflexiones teóricas y aplicaciones pedagógicas. Peter Lang.
- Jih-Gaw, L., Cheng-Nan, Ch. y Shou-Chung, Ch. 1997. Enhancement of anaerobic digestion of waste activate sludge by alkaline solubilization. *Bioresurce Technology*., 62:85-90.
- J. Flores, B. Arcay, J. Arias. 2000. An intelligent system for distributed control of an anaerobic wastewater treatment process. *Engineering Applications of Artificial Intelligence*. Pages 485-494.
- Jean-Philippe Steyer, Pierre Buffière, Damien Rolland, René Moletta. 1999. Advanced control of anaerobic digestion processes through disturbances monitoring. *Water Research*, Volume 33. Pages 2059-2068.
- Jiménez B., Castrejón A., Barrios J. A., Maya C., Rodríguez A. y González A. 2002. Evaluación de la calidad de lodos residuales de México. Instituto de Ingeniería. Grupo de Tratamiento y Reúso. Universidad Nacional Autónoma de México.
- Jinquan Wan, Mingzhi Huang, Yongwen Ma, Wenjie Guo, Yan Wang, Huiping Zhang, Weijiang Li, Xiaofei Sun. 2011. Prediction of effluent quality of a paper mill wastewater treatment using an adaptive network-based fuzzy inference system. *Applied Soft Computing*, Volume 11. Pages 3238-3246.
- Kim J.; Park C.; Kim T.-H.; Lee M.; Kim S.; Kim S.-W.; Lee J. 2003. Effects of various pretreatments for enhanced anaerobic digestion with waste activated sludge. *J. Bioscience & Bioengineering*, 95(3), 271- 275.
- Kosko, B., & Satoru, I. (1993). *Lógica borrosa. Investigación y cienica*.
- Wyman, C. E. 1999. Biomass ethanol: technical progress, opportunities, and comercial challenges. *Annual Review of Energy and the Environment*, 24(1), 189-226.
- Joost Lauwers, Lise Appels, Ian P. Thompson, Jan Degrève, Jan F. Van Impe, Raf Dewil. 2013. Mathematical modelling of anaerobic digestion of biomass and waste: Power and limitations. *Progress in Energy and Combustion Science*, Volume 39. Pages 383-402.

- Joo-Hwa Tay, Xiyue Zhang. 2000. A fast predicting neural fuzzy model for high-rate anaerobic wastewater treatment systems. *Water Research*, Volume 34. Pages 2849-2860.
- Katarzyna Golkowska, Manfred Greger. 2013. Anaerobic digestion of maize and cellulose under thermophilic and mesophilic conditions – A comparative study. *Biomass and Bioenergy*, Volume 56. Pages 545-554.
- L. Neumann, P. Scherer. 2011. Impact of bioaugmentation by compost on the performance and ecology of an anaerobic digester fed with energy crops. *Bioresource Technology*, Volume 10. Pages 2931-2935.
- L. Pastor, N. Marti, A. Bouzas, A. Seco. 2008. Sewage sludge management for phosphorus recovery as struvite in EBPR wastewater treatment plants. *Bioresource Technology*, Volume 99. Pages 4817-4824.
- Laurent Lardon, Ana Punal, Jean-Philippe Steyer. 2004. On-line diagnosis and uncertainty management using evidence theory—experimental illustration to anaerobic digestion processes. *Journal of Process Control*, Volume 14. Pages 747-763.
- Lise Appels, Jan Baeyens, Jan Degève, Raf Dewil. 2008 Principles and potential of the anaerobic digestion of waste-activated sludge. *Progress in Energy and Combustion Science*, Volume 34, Pages 755-781.
- Lin-Feng Zhai, Min Sun, Wei Song, Gan Wang. 2012. An integrated approach to optimize the conditioning chemicals for enhanced sludge conditioning in a pilot-scale sludge dewatering process. *Bioresource Technology*, Volume 121. Pages 161-168.
- Luna, H. R. G. y Guyot, P. J. 1990. Arranque de un reactor anaerobio con lodos adaptados como inóculo y un influente industrial de la industria agroalimenticia (ingenio azucarero). Reporte técnico realizado en el laboratorio de microbiología ambiental Depto. Biotecnología, UAM-I.
- Lee, M. J.; Song, J. H.; Hwang, S.-J. Effects of acid pre-treatment on bio-hydrogen production and microbial communities during dark fermentation. *Bioresour. Technol.* **2009**, *100*(3), 1491–3.
- Ilangoan K., Noyola A. 1993. Tratamiento anaerobio de aguas residuales micronutrientes y metales pesados en digestión anaerobia. Curso internacional México-Centroamérica, Instituto de Ingeniería. UNAM. México.

- Mandigan, M. T., Martinko, J. M. y Parker, J. 1998. Brock. Biología de los microorganismos. Edit. Prentice Hall International (UK) Ltd. 8ª ed.
- Mata-Alvarez, J.; Macé, S.; Llabrés, P. Anaerobic digestion of organic solid wastes. An overview of research achievements and perspectives. *Bioresour. Technol.* **2000**, 74(1), 3–16.
- Mejía Sánchez, G. M. (1987). Digestión anaerobia. Universidad Autónoma de Yucatán, Yucatán, México.
- Menert, A.; Vaalu, T.; Michelis, M.; Blonskaja, V.; Rikmanasn, E.; Mets, A.; Vilu, R. Influence of thermal pre-treatment on mesophilic anaerobic digestion of sludges. Proceedings of The 7th International Conference. Environmental. Engineering, Faculty of Environmental Engineering, Vilnius Gediminas Technical University, May 22-23, 2008, Vilnius, Lithuania, 625–635.
- Méndez-Contreras, J.M.; Atenodoro, J.; Champi3n, F.A.; Vallejo-Cantú, N.A.; Alvarado-Lassman, A. Inactivation of high concentration of pathogens in land-applied food industry sludge. *Water SA* **2009**, 35(4), 371–378.
- Mendoza Roca, J. A., Montañés Sanjuan, M. T., & Palomares Gimeno, A. E. (1998). Ciencia y tecnología del medio ambiente. Valencia: Servicio de publicaciones Reproval, S.L.
- Myung-Yeol Lee, Chang-Won Suh, Yong-Tae Ahn, Hang-Sik Shin. 2009. Variation of ADM1 by using temperature-phased anaerobic digestion (TPAD) operation. *Bioresource Technology*, Volume 100, Pages 2816-2822.
- Nava-Valente, N.; Alvarado-Lassman, A.; Nativitas-Sandoval, L.S.; Mendez-Contreras, J.M. Improved anaerobic digestion of a thermally pretreated mixture of physicochemical sludge; broiler excreta and sugar cane wastes (SCW): Effect on organic matter solubilization, biodegradability and bioenergy production. *J. Environ. Sci. Heal. Part A* **2016**, 51(5), 446–453.
- Nava Valente, N. (2011). Evaluaci3n de estrategias de alto desempe3o para la digesti3n anaerobia termofílica de lodos residuales (Tesis de maestría). Instituto Tecnol3gico de Orizaba. Orizaba Veracruz, México.

- Nava Valente, N. (2017) evaluación de mecanismos de transformación Bioquímica de residuos agroindustriales para la Obtención de bioenergéticos (Tesis doctoral). Instituto Tecnológico de Orizaba. Orizaba Veracruz, México
- Nelson DL, Cox MM. Principios de Bioquímica. 4ª ed. Barcelona:Omega; 2005.
- Nguyen, Hung T. Walker, Elebert A. A first course in Fuzzi Logic. Ed. CRC Press, New México 1996.
- Ortega, S. R. D., Castillo, C. J., Colín-Cruz, A., Salazar, M. S. A. 2003. Genotoxicidad del lixiviado de lodos residuales. VIII Congreso Nacional de Ciencias Ambientales y II Congreso Internacional de Ciencias Ambientales. Querétaro, México.
- Pavlostathis, S.G.; Giraldo-Gomez, E. Kinetics of anaerobic treatment – a critical review. *CRC Crit. Rev. Environ. Control* 1991, 21(5-6), 411–490.
- P. Mullai, S. Arulselvi, Huu-Hao Ngo, P.L. Sabarathinam. 2011. Experiments and ANFIS modelling for the biodegradation of penicillin-G wastewater using anaerobic hybrid reactor. *Bioresource Technology*, Volume 102. Pages 5492-5497
- Polit, M.; Estaben, M.; Labat, P. Fuzzy model for an anaerobic digester, comparison with experimental results. *Eng. Appl. Artif. Intell.* 2002, 15(5), 385–390.
- S. Carlos-Hernandez, E.N. Sanchez, J.F. Béteau. 2009. Fuzzy observers for anaerobic WWTP: Development and implementation. *Control Engineering Practice*, Volume 17. Pages 690-702.
- Rico-Contreras, J.O.; Aguilar-Lasserre, A.A.; Méndez-Contreras, J.J.; Cid-Chama, G.; Alor-Hernández, G. Predicción del contenido de humedad en la pollinaza para estimar la producción de bioenergía a través de una red neuronal artificial. *Revista Mexicana. Ingen. Quim.* 2012, 11(1), 23–43.
- Ruiz Espinoza, N. (2013). Desarrollo de estrategias para el desempeño de alta eficiencia y control del proceso de co-digestión anaerobia mesofílica de lodos residuales-residuos sólidos orgánicos municipales (Tesis doctoral). Universidad metropolitana de Azcapotzalco, Estado de México, México.
- Ruiz-Espinoza, J.E.; Méndez-Contreras, J.M.; Alvarado-Lassman, A.; Martinez-Delgadillo, S. A. Effect of low temperature thermal pre-treatment on the solubilization of organic matter, pathogen inactivation and mesophilic anaerobic digestion of poultry sludge. *J. Environ. Sci. Health. Pt. A* 2012, 47(12), 1795–1802.

- Siegrist, H., Renggli, D. y Gujer, W. 1993. Mathematical modelling of anaerobic mesophilic sewage sludge treatment. *Wat. Sci. Tech.*, 27(2):25-36.
- Sivanandam, S.N.; Sumathi, S.; Deepa S.N. *Introduction to Fuzzy Logic using MATLAB* Ed. Springer, Berlin, New York 2007.
- T.Y. Pai, T.J. Wan, S.T. Hsu, T.C. Chang, Y.P. Tsai, C.Y. Lin, H.C. Su, L.F. Yu. 2009. Using fuzzy inference system to improve neural network for predicting hospital wastewater treatment plant effluent. *Computers & Chemical Engineering*, Volume 33. Pages 1272-1278.
- Ting Yang, Lixian Zhang, Aijie Wang, Huijun Gao. 2013. Fuzzy modeling approach to predictions of chemical oxygen demand in activated sludge processes. *Information Sciences*, Volume 235. Pages 55-64.
- Yang, S.T.; Okos, M.R. Kinetic study and mathematical modeling of methanogenesis of acetate using pure cultures of methanogens. *Biotechnol. Bioeng.* **1987**, 30(5), 661–667.
- Y.G. Du, R.D. Tyagi, R. Bhamidimarri. 1999. Use of fuzzy neural-net model for rule generation of activated sludge process. *Process Biochemistry*, Volume 35. Pages 77-83.

ANEXOS

ANEXO 1.

EJEMPLO DE METODOLOGIA DE ECUACIONES Y FUNCIONES DE LOS MODELOS DE LÓGICA DIFUSA. (Ecuaciones para el modelo de lógica difusa de lodo prehidrolizado termicamente)

Ecuación 6.1 Tiempo de retención hidráulica, etiqueta “corta”.

$$\text{TRH}(s, \text{Corta}) = \begin{cases} 0 & ; \quad 4 \leq s \\ 1 - \left(\frac{10-s}{10-4} \right) & ; \quad 4 < s < 10 \\ 1 - \left(\frac{s-16}{16-10} \right) & ; \quad 10 < s < 16 \\ 0 & ; \quad s \geq 22 \end{cases}$$

Ecuación 6.2 Tiempo de retención hidráulica, etiqueta “convencional”.

$$\text{TRH}(s, \text{Convencional}) = \begin{cases} 0 & ; \quad 20 \leq s \\ 1 - \left(\frac{25-s}{25-20} \right) & ; \quad 20 < s < 25 \\ 1 - & \\ 0 & ; \quad s \geq 30 \end{cases}$$

Ecuación 6.3 Tiempo de retención hidráulica, etiqueta “larga”.

$$\text{TRH}(s, \text{Larga}) = \begin{cases} 0 & ; \quad 28 \leq s \\ 1 - \left(\frac{32-s}{32-28} \right) & ; \quad 28 < s < 32 \\ 1 - \left(\frac{s-36}{36-32} \right) & ; \quad 32 < s < 36 \\ 0 & ; \quad s \geq 40 \end{cases}$$

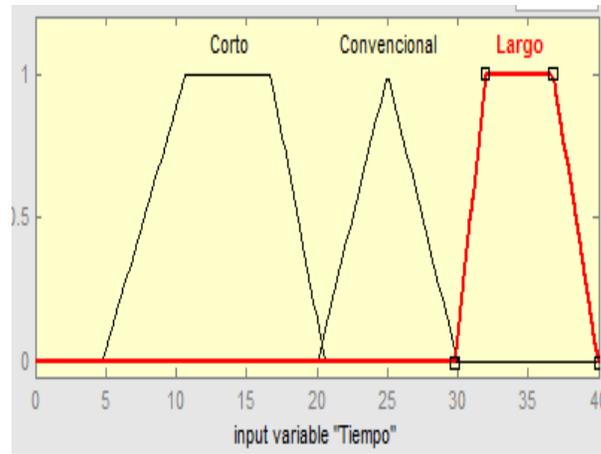


Figura 6.1 Funciones de pertenencia para la variable tiempo

Ecuación 6.4 pH, etiqueta “ácido”

$$\text{pH}(s, \text{Ácido}) = \begin{cases} 0 & ; \quad 4 \leq s \\ 1 - \left(\frac{5-s}{5-4}\right) & ; \quad 4 < s < 5 \\ 1 - \left(\frac{s-6}{6-5}\right) & ; \quad 5 < s < 6 \\ 0 & ; \quad s \geq 6.9 \end{cases}$$

Ecuación 6.5 pH, etiqueta “Recomendable”

$$\text{pH}(s, \text{Recomendable}) = \begin{cases} 0 & ; \quad 6.7 \leq s \\ 1 - \left(\frac{7.41-s}{7.41-6.7}\right) & ; \quad 6.7 < s < 7.41 \\ 1 - \left(\frac{s-7.66}{7.66-7.41}\right) & ; \quad 7.41 < s < 7.66 \\ 0 & ; \quad s \geq 8 \end{cases}$$

Ecuación 6.6. pH, etiqueta “alcalino”

$$\text{pH}(s, \text{Alcalino}) = \begin{cases} 0 & ; \quad 7.8 \leq s \\ 1 - \left(\frac{8.5-s}{8.5-7.8}\right) & ; \quad 7.8 < s < 8.5 \\ 1 - \left(\frac{s-9}{9-8.5}\right) & ; \quad 8.5 < s < 9 \\ 0 & ; \quad s \geq 9.5 \end{cases}$$

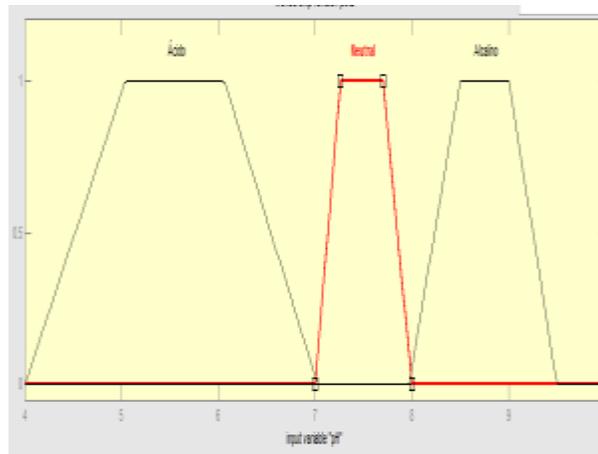


Figura 6.2. Funciones de pertenencia para la variable pH

Ecuación 6.7. Variable Carga, etiqueta “uno”

$$\text{Carga}(s, \text{uno}) = \begin{cases} 0 & ; \quad 0.9 \leq s \\ 1 - \left(\frac{1.02-s}{1.02-0.9} \right) & ; \quad 0.9 < s < 1.02 \\ 1 - \left(\frac{s-1.05}{1.05-1.02} \right) & ; \quad 1.02 < s < 1.05 \\ 0 & ; \quad s \geq 1.2 \end{cases}$$

Ecuación 6.8. Variable Carga, etiqueta “dos”

$$\text{Carga}(s, \text{dos}) = \begin{cases} 0 & ; \quad 1.1 \leq s \\ 1 - \left(\frac{1.4-s}{1.4-1.1} \right) & ; \quad 1.1 < s < 1.4 \\ 1 - \left(\frac{s-1.8}{1.8-1.4} \right) & ; \quad 1.4 < s < 1.8 \\ 0 & ; \quad s \geq 2 \end{cases}$$

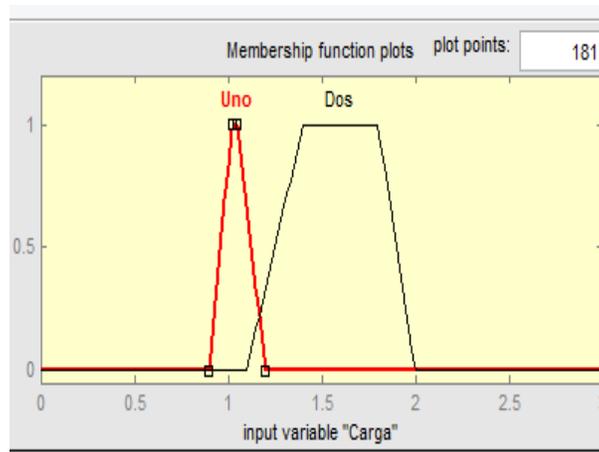


Figura 6.3 Funciones de pertenencia para la variable tiempo

Ecuación 6.9 Temperatura, etiqueta “baja”

$$Temperatura(s, Baja) = \begin{cases} 0 & ; \quad 20 \leq s \\ 1 - \left(\frac{25 - s}{25 - 20} \right) & ; \quad 20 < s < 25 \\ 0 & ; \quad s > 30 \end{cases}$$

Ecuación 6.10 Temperatura, etiqueta “estable”

$$Temperatura(s, estable) = \begin{cases} 0 & ; \quad 30 \leq s \\ 1 - \left(\frac{32 - s}{32 - 30} \right) & ; \quad 30 < s < 32 \\ 0 & ; \quad s \geq 35 \end{cases}$$

Ecuación 6.11 Temperatura, etiqueta "alta"

$$\text{Temperatura}(s, \text{Alta}) = \begin{cases} 0 & ; \quad 35 \leq s \\ 1 - \left(\frac{42-s}{42-35} \right) & ; \quad 35 < s < 42 \\ 0 & ; \quad s \geq 50 \end{cases}$$

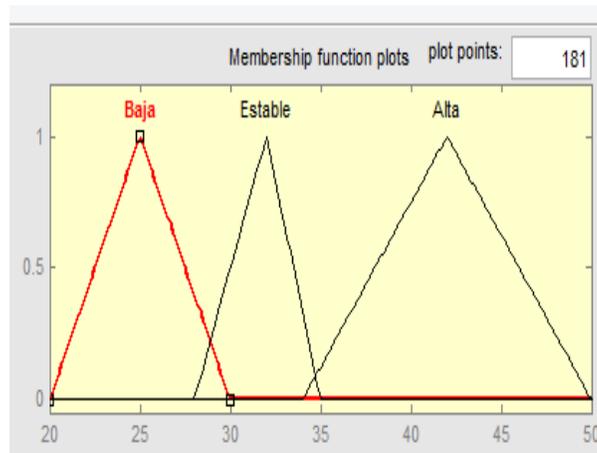


Figura 6.4 Funciones de pertenencia para la variable Temperatura

Ecuación 6.12. Sólidos totales, etiqueta "baja"

$$\text{Solidos totales}(s, \text{baja}) = \begin{cases} 0 & ; \quad 0 \leq s \\ 1 - \left(\frac{0.5-s}{0.5-0} \right) & ; \quad 0 < s < 0.5 \\ 1 - \left(\frac{s-1}{1-0.5} \right) & ; \quad 0.5 < s < 1 \\ 0 & ; \quad s \geq 1.5 \end{cases}$$

Ecuación 6.13 Sólidos totales, etiqueta “recomendable”

$$\text{Sólidos totales}(s, \text{recomendable}) = \begin{cases} 0 & ; \quad 1.5 \leq s \\ 1 - \left(\frac{2.9-s}{2.9-1.5} \right) & ; \quad 1.5 < s < 2.9 \\ 1 - \left(\frac{s-3.49}{3.49-2.9} \right) & ; \quad 2.9 < s < 3.49 \\ 0 & ; \quad s \geq 3.5 \end{cases}$$

Ecuación 6.14 Sólidos totales, etiqueta “elevado”

$$\text{Carga}(s, \text{elevado}) = \begin{cases} 0 & ; \quad 3.4 \leq s \\ 1 - \left(\frac{3.49-s}{3.49-3.4} \right) & ; \quad 3.4 < s < 3.49 \\ 1 - \left(\frac{s-3.64}{3.64-3.49} \right) & ; \quad 3.49 < s < 3.64 \\ 0 & ; \quad s \geq 4 \end{cases}$$

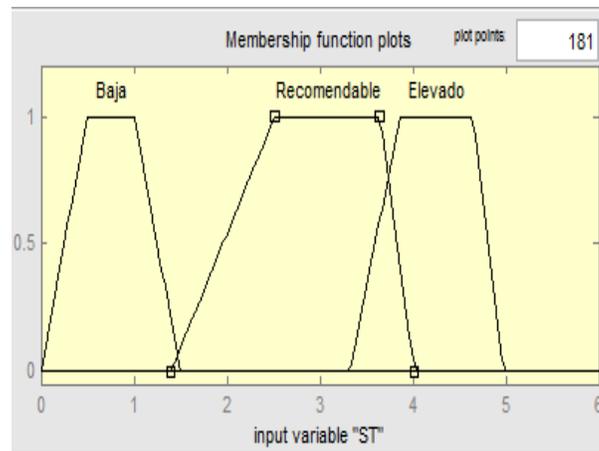


Figura 6.5 Funciones de pertenencia para la variable Sólidos totales

Ecuación 6.15 Sólidos volátiles, etiqueta “bajo”

$$\text{Solidos volátiles}(s, \text{bajo}) = \begin{cases} 0 & ; \quad 40 \leq s \\ 1 - \left(\frac{50-s}{50-40} \right) & ; \quad 40 < s < 50 \\ 1 - \left(\frac{s-60}{60-50} \right) & ; \quad 50 < s < 60 \\ 0 & ; \quad s \geq 70 \end{cases}$$

Ecuación 6.16 Sólidos volátiles, etiqueta “óptimo”

$$\text{Solidos volátiles}(s, \text{óptimo}) = \begin{cases} 0 & ; \quad 68 \leq s \\ 1 - \left(\frac{85.63-s}{85.63-68} \right) & ; \quad 68 < s < 85.63 \\ 1 - \left(\frac{s-87.3}{87.3-85.63} \right) & ; \quad 85.63 < s < 87.3 \\ 0 & ; \quad s \geq 90 \end{cases}$$

Ecuación 6.17 Sólidos volátiles, etiqueta “alto”

$$\text{Solidos volátiles}(s, \text{Alto}) = \begin{cases} 0 & ; \quad 88 \leq s \\ 1 - \left(\frac{90-s}{90-88} \right) & ; \quad 88 < s < 90 \\ 1 - \left(\frac{s-95}{95-90} \right) & ; \quad 90 < s < 95 \\ 0 & ; \quad s \geq 100 \end{cases}$$

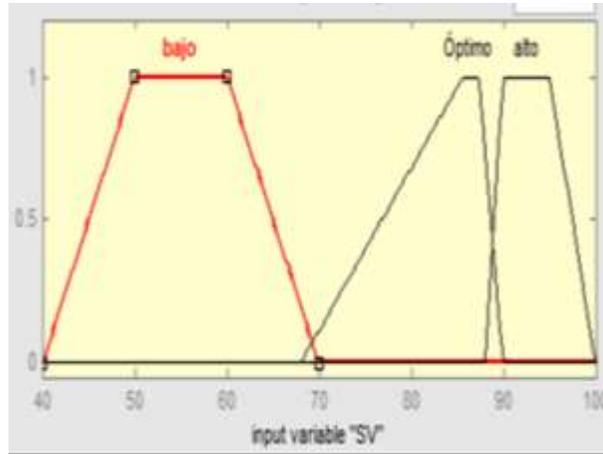


Figura 6.6 Funciones de pertenencia para la variable Sólidos volátiles

Ecuación 6.18 Biogás, etiqueta “Poco”

$$\text{Biogás}(s, \text{Poco}) = \begin{cases} 0 & ; \quad 0 \leq s \\ 1 - \left(\frac{0.1-s}{0.1-0} \right) & ; \quad 0 < s < 0.1 \\ 1 - \left(\frac{s-0.3}{0.3-0.1} \right) & ; \quad 0.1 < s < 0.3 \\ 0 & ; \quad s \geq 0.5 \end{cases}$$

Ecuación 6.19 Biogás, etiqueta “Promedio”

$$\text{Biogás}(s, \text{Promedio}) = \begin{cases} 0 & ; \quad 0.4 \leq s \\ 1 - \left(\frac{0.73-s}{0.73-0.4} \right) & ; \quad 0.4 < s < 0.73 \\ 1 - \left(\frac{s-0.77}{0.77-0.73} \right) & ; \quad 0.73 < s < 0.77 \\ 0 & ; \quad s \geq 1 \end{cases}$$

Ecuación 6.20 Biogás, etiqueta “Mucho”

$$\text{Biogás}(s, \text{Mucho}) = \begin{cases} 0 & ; \quad 0.9 \leq s \\ 1 - \left(\frac{1.3-s}{1.3-0.9} \right) & ; \quad 0.9 < s < 1.3 \\ 1 - \left(\frac{s-1.6}{1.6-1.3} \right) & ; \quad 1.3 < s < 1.6 \\ 0 & ; \quad s \geq 2 \end{cases}$$

Los valores de los conjuntos difusos de la variable biogás se observan en la tabla 18, dichos conjuntos corresponden a los datos que se ingresaron al modelo de lógica difusa desarrollado en Matlab.

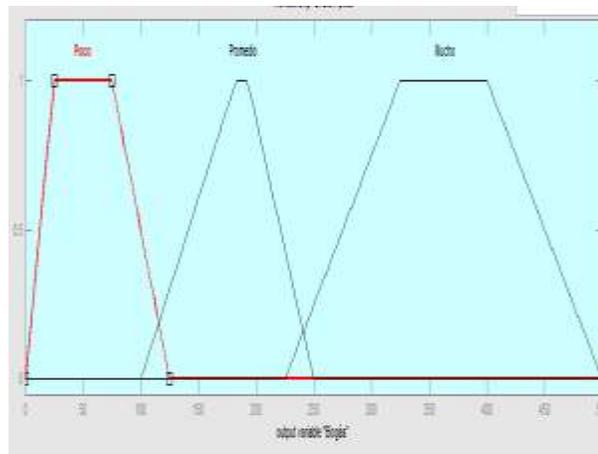


Figura 6.7 Funciones de pertenencia para la variable biogás

ANEXO 2

METODOLOGÍA PARA LA CREACIÓN DEL MODELO DE MATEMÁTICO OPTIMIZADO CON ALGORITMOS GENTICOS.

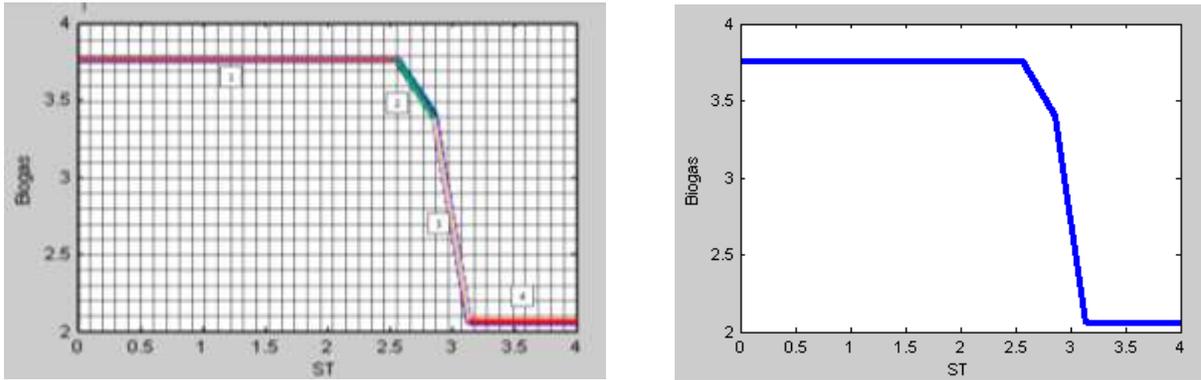


Figura 6.8 Comportamiento de la variable ST con respecto a la variable de salida biogás

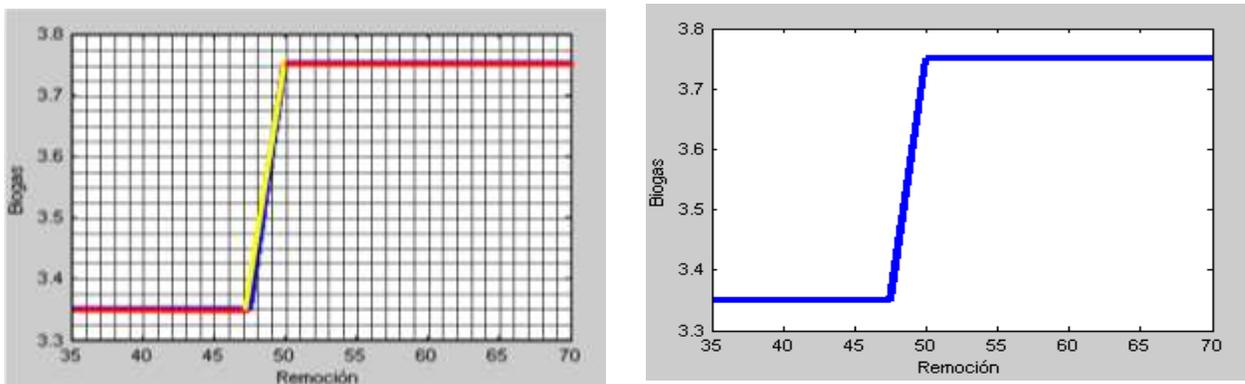


Figura 6.9 Superficies de respuesta de remoción con respecto a la variable de salida biogás del modelo de lógica difusa, para observar su comportamiento.

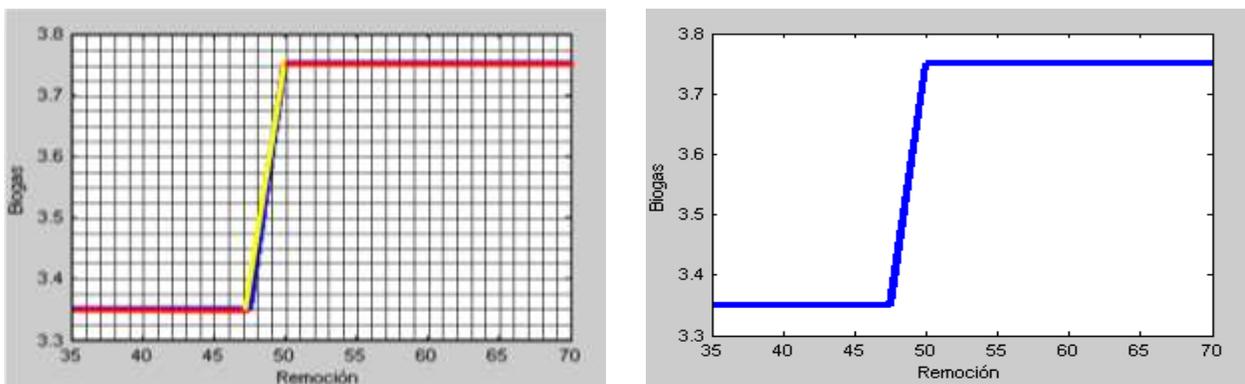


Figura 6.10 Superficies de respuesta de remoción con respecto a la variable de salida biogás del modelo de lógica difusa, para observar su comportamiento.

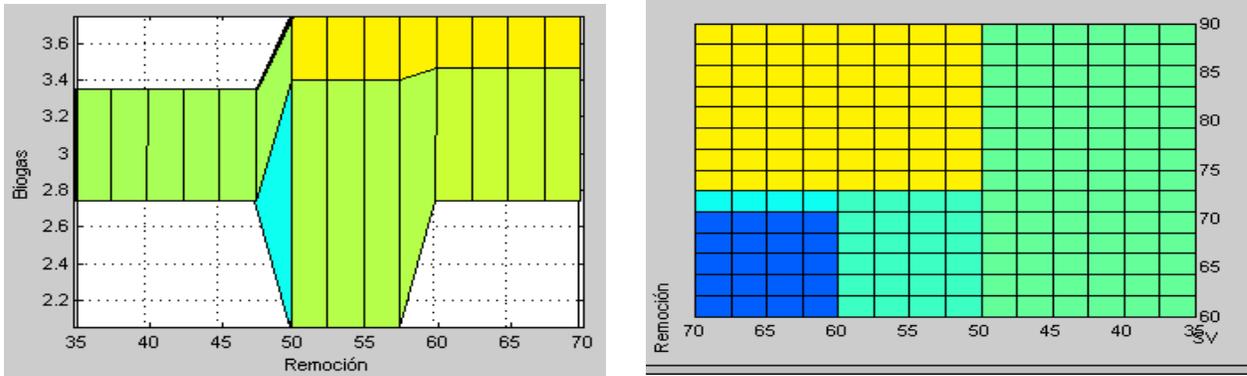


Figura 6.11 Superficies de respuesta de región óptima para la interacción de las variables solidos volátiles y tiempo de operación en la variable de salida biogás.

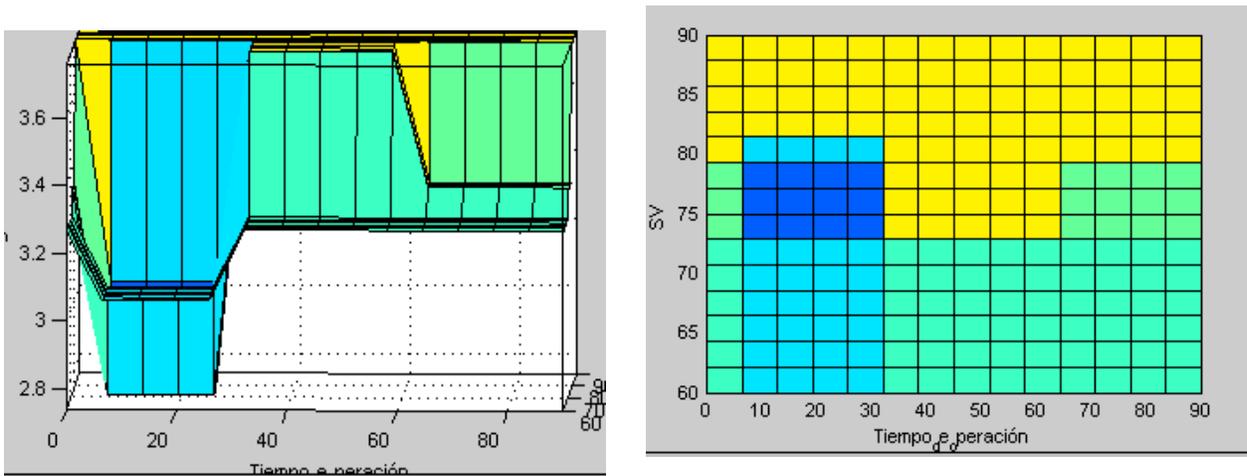


Figura 6.12 Ecuaciones de la región óptima para la interacción de las variables solidos volátiles y tiempo de operación en la variable de salida biogás.