

DISEÑO DE UNA ALTERNATIVA PARA ESTABILIZAR LA ENERGÍA
ENTREGADA EN LOS PROCESOS DE COMBUSTIÓN DE LA U2800, EN GRB,
MEDIANTE LA IMPLEMENTACION DE CONTROL ADAPTATIVO USANDO
REDES NEURONALES

HARBey ALEXI ESCOBAR SEPULVEDA

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISCOQUÍMICAS
ESCUELA DE INGENIERIA QUÍMICA
MAESTRIA EN INGENIERIA QUÍMICA
BUCARAMANGA
2016

DISEÑO DE UNA ALTERNATIVA PARA ESTABILIZAR LA ENERGÍA
ENTREGADA EN LOS PROCESOS DE COMBUSTIÓN DE LA U2800, EN GRB,
MEDIANTE LA IMPLEMENTACION DE CONTROL ADAPTATIVO USANDO
REDES NEURONALES

HARBHEY ALEXI ESCOBAR SEPULVEDA

Trabajo de grado para optar al título de Magister en Ingeniería Química

Director:
ING. JAQUELINE SAAVEDRA Ph. D

Co-director:
ING. JOHN JAIRO CASTILLO

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISCOQUÍMICAS
ESCUELA DE INGENIERIA QUÍMICA
MAESTRIA EN INGENIERIA QUÍMICA
BUCARAMANGA
2016

Este libro está dedicado a
Mi Padre Dios, mi Salvador Jesucristo, su Santo Espíritu,
Mi familia,
Destinatarios de mi amor y orgullo.

AGRADECIMIENTOS

A los HAKETALUSA, Kelly Johanna, Tania Alejandra, Luis Alejandro y Danna “Gracia” Salomé Alejandra, Son mi razón de ser.

A mis Padres Jorge Luis y Carmen Elisa, a quienes debo mi vida.

A mis Hermanos, Luis Fernando, Jorge Efrén, Victor Hugo, Eliana Alexandra, José Guillermo, Gladys Adriana, sin ellos no habría sido posible llegar hasta aquí.

A Jaqueline Saavedra, por su apoyo incondicional, su gran amistad, sus sugerencias, consejos y aportes.

A John Jairo Castillo por su amistad y su genial aporte en el área técnica.

A Dionisio Laverde y Orlando Diaz por su ingenio y audacia al concebir el programa de Postgrados en Barrancabermeja.

A mis cincuenta y uno colegas de sendero.

A Hugo Armando ¡Adelante!

A la UIS por acercarse a Barrancabermeja con el Postgrado.

A Ecopetrol, una gran empresa.

CONTENIDO

	Pág.
INTRODUCCIÓN.....	14
1. OBJETIVOS.....	15
1.1. OBJETIVO GENERAL.....	15
1.2. OBJETIVOS ESPECÍFICOS.....	15
2. PROBLEMÁTICA.....	16
2.1. LA ESTRATEGIA DE CONTROL ACTUAL.....	16
2.2. EL CABEZAL DE GAS COMBUSTIBLE.....	20
3. MARCO TEÓRICO Y ESTADO DEL ARTE.....	25
3.1. INTERCAMBIABILIDAD DE GASES.....	25
3.2. ÍNDICES DE INTERCAMBIABILIDAD.....	26
3.3. ÍNDICE DE WOBBE:.....	27
3.4. PREPARACIÓN DE GAS COMBUSTIBLE.....	28
3.5. CONTROL ADAPTATIVO CON REDES NEURONALES.....	29
3.6. CONTROL DE UNA PLANTA NO LINEAL CON REDES NEURONALES.....	32
4. METODOLOGÍA.....	37
4.1. VARIABLES A CORRELACIONAR.....	38
4.2. DISEÑO DEL NEUROCONTROLADOR.....	40
4.3. IDENTIFICACIÓN DEL SISTEMA.....	44

5. RESULTADOS.....	48
5.1. CREAR Y CONFIGURAR LA RED	48
5.2. EVALUACIÓN DE LOS CONTROLADORES	55
5.3. NUEVA ESTRATEGIA DE CONTROL.....	58
6. CONCLUSIONES.	61
REFERENCIAS	62
BIBLIOGRAFÍA.....	67

LISTA DE TABLAS.

	Pág.
Tabla 1. Cromatografía gas de suministro al H2801A	21
Tabla 2. Histórico cromatografía de gas U2800.....	22
Tabla 3. Problemas de Intercambiabilidad de gases.	26
Tabla 4. Variables a correlacionar	38
Tabla 5. Matrices de datos para entrenamiento.....	40
Tabla 6. Algoritmos evaluados.....	48
Tabla 7. Resultados de evaluación de algoritmos de entrenamiento.....	50
Tabla 8. Requerimientos de cómputo de los controladores.	57

LISTA DE FIGURAS.

	Pág.
Figura 1. Diagrama de fase de la Unidad Visorreductora II	14
Figura 2. La estrategia de control actual.....	16
Figura 3. Termografía interior del H2801A.....	17
Figura 4. Registro fotográfico tubos del H2801A	18
Figura 5. Curva de respuesta lazo de control actual.....	19
Figura 6. Inestabilidad del lazo de control actual.	20
Figura 7. Diagrama de Proceso de Mezcla de gas Industrial.....	28
Figura 8. Modelo de control predictivo basado redes neuronales artificiales.	30
Figura 9. Esquema simplificado de una red neuronal de tres niveles	32
Figura 10. Esquema modelamiento con redes neuronales.	33
Figura 11. Metodología del trabajo de aplicación.....	37
Figura 12. Variables Correlacionadas H2801	40
Figura 13. Diagrama de bloques NNPC.....	41
Figura 14. Diseño NNPC	42
Figura 15. Diseño NNNarma-L2.....	42
Figura 16. Diagrama de bloques NNRC.	43
Figura 17. Diseño NNRC.	43
Figura 18. Diagrama de bloques identificación del sistema.	44
Figura 19. Metodología identificación del sistema.	45
Figura 20. Diagrama de bloques procesamiento de datos.....	46
Figura 21. Funciones de transferencia evaluadas.	49
Figura 22. Grafica resultante función de entrenamiento traincgb.	51
Figura 23. Desempeño función de entrenamiento trainbr	52
Figura 24. Grafica resultante función de entrenamiento trainlm	53
Figura 25. Desempeño función de entrenamiento trainlm	54
Figura 26. Resultado de la RNA	54

Figura 27. Respuesta del neurocontrolador NNPC	55
Figura 28. Respuesta del neurocontrolador NNARMA-L2	56
Figura 29. Respuesta del neurocontrolador NNRC.....	56
Figura 30. Respuesta salida en el control de temperatura.....	58
Figura 31. Esquema de nueva estrategia de control H2801A.....	59
Figura 32. Protocolo de comunicación DCS – Matlab.....	60

RESUMEN

TITULO: DISEÑO DE UNA ALTERNATIVA PARA ESTABILIZAR LA ENERGÍA ENTREGADA EN LOS PROCESOS DE COMBUSTIÓN DE LA U2800, EN GRB, MEDIANTE LA IMPLEMENTACION DE CONTROL ADAPTATIVO USANDO REDES NEURONALES.*

AUTOR: Harbey Alexi Escobar Sepúlveda**

PALABRAS CLAVES: Gas Combustible, Índice de Wobbe, Eficiencia térmica, Redes Neuronales.

DESCRIPCIÓN:

El presente trabajo de aplicación propone una estrategia de control apoyada en redes neuronales aplicada en horno de craqueo térmico. El objetivo operacional del horno es proporcionar a la carga energía suficiente para la reacción; por consiguiente, la eficiencia de la operación resulta al maximizar la transferencia de calor hacia el fluido de proceso, es decir, al incrementar la temperatura para un consumo dado de combustible. La técnica de control adaptativo del control de gas combustible frente a las fuertes variaciones de las propiedades físico-químicas del cabezal de gas combustible de suministro generó un beneficio adicional con una mejor práctica operativa.

El problema a solucionar en el presente trabajo de aplicación radica que ante las degradaciones de gas de refinería se evidencia inestabilidad en la energía entregada en los procesos de combustión, a partir de la variabilidad las propiedades fisicoquímicas del cabezal de gas combustible de suministro, afectando la integridad de los activos y la operación de la unidad.

Al evaluar el sistema de combustión con la estrategia de control actual no cumple con todos los criterios de estabilidad, evidenciando altos valores de sobrepaso en el control de la temperatura de salida de los serpentines del H2801AB, ante las degradaciones de gas a la red de suministro y el presente trabajo de aplicación facilitará la implementación de iniciativas de control en sistemas dinámicos, como hornos de proceso, proporcionando ahorro de energía y mejoramiento de la integridad de los equipos de combustión, basado en las características de las mezclas de gas de refinería, utilizadas como combustible por los hornos y calderas.

*Trabajo e Grado

** Facultas Ingenierías Físico Químicas,. Escuela de Química. Director Jaqueline Saavedra. Director Jaqueline Saavedra

ABSTRACT

TITLE: DESIGN OF AN ALTERNATIVE TO STABILIZE ENERGY DELIVERED IN THE PROCESS OF BURNING OF THE U2800, IN GRB, BY IMPLEMENTING ADAPTIVE CONTROL USING NEURAL NETWORKS.*

AUTHOR: Harbey Alexi Escobar Sepúlveda**

KEYWORDS: Gas Fuel, Wobbe index, thermal efficiency, neural networks, control systems.

DESCRIPTION:

This paper proposes implementing a control strategy supported by neural networks applied in thermal cracking furnace furnace .The operational objective is to provide enough energy for the reaction charge; therefore, the operation efficiency is to maximize the heat transfer to the process fluid, that is, by increasing the temperature for a given fuel consumption. The technique of adaptive control of gas fuel control against strong variations of the physicochemical head supply fuel gas properties generated an additional benefit with better operational practice.

The problem to be solved in this application work lies that before degradations refinery gas instability is evident in the energy delivered in combustion processes, from the variability in the physicochemical properties of head combustible gas supply, affecting the asset integrity and operation of the unit

In evaluating the combustion system with the strategy of current control does not meet all the criteria of stability, showing high values override the temperature control output coils H2801AB before degradations gas supply network and this application work will facilitate the implementation of control initiatives in dynamic systems such as process furnaces, providing energy savings and improve the integrity of the combustion equipment, based on the characteristics of the blends of refinery gas, used as fuel for the furnaces and boilers.

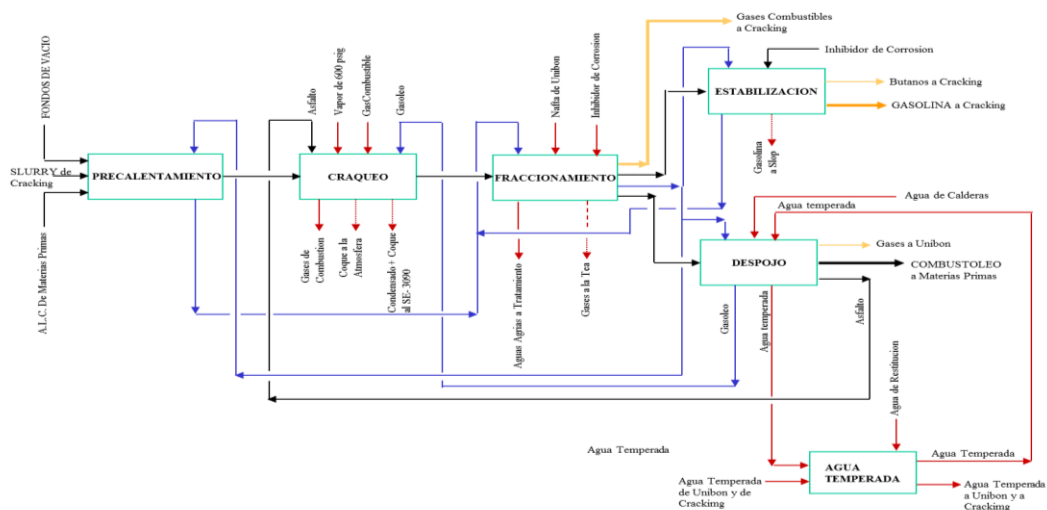
* Degree Work

** Engineering Faculty Physicochemical,. School of Chemistry. Director Jaqueline Saavedra

INTRODUCCIÓN.

En el contexto de la refinería de Ecopetrol en Barrancabermeja, la U2800 o planta Viscorreductora II, hace parte del esquema de recuperación de productos valiosos de los fondos del barril de hidrocarburo, la unidad procesa veinticinco mil barriles de fondos al día y tiene como objetivo reducir la viscosidad de la materia prima para la producción de un terminado llamado combustóleo, mediante la adición de diluyente llamado aceite liviano de ciclo ALC. La reducción de la viscosidad se realiza mediante un proceso endotérmico de craqueo a altas temperaturas, en dos hornos en paralelo, los cuales realizan la transferencia de la energía a partir de combustión de 3.500.000 pies cúbicos estándar por día de gas de suministro. En la figura 1 se presenta un diagrama de fase de Viscorreductora, precalentamiento, craqueo, fraccionamiento, estabilización, despojo y circuito de agua atemperada. En la sub-fase de craqueo se encuentran los hornos de craqueo térmico, los cuales son de tiro natural tipo cabina con pared radiante interna y una distribución de veinticuatro quemadores cada uno.

Figura 1. Diagrama de fase de la Unidad Viscorreductora II



Fuente: Ecopetrol. Información Técnica de la Refinería de Barrancabermeja. Barrancabermeja: Ecopetrol. 2014

1. OBJETIVOS

1.1. OBJETIVO GENERAL

Diseñar una alternativa para estabilizar la energía entregada en los procesos de combustión de la U2800 en GRB, mediante la implementación de control adaptativo usando redes neuronales.

1.2. OBJETIVOS ESPECÍFICOS

Analizar el sistema actual mediante la caracterización de las corrientes que componen la red de gas combustible desde el punto de vista físico-químico.

Evaluar el sistema de combustión con la estrategia de control actual de acuerdo a los criterios de estabilidad establecidos.

Diseñar la estrategia de control adaptativo a partir de las diferentes arquitecturas de redes neuronales, mediante el uso de la herramienta Matlab.


2. PROBLEMÁTICA.

El problema a solucionar en el presente trabajo de aplicación radica que ante las degradaciones de gas de refinería se evidencia inestabilidad en la energía entregada en los procesos de combustión, a partir de la variabilidad las propiedades fisicoquímicas del cabezal de gas combustible de suministro, afectando la integridad de los activos y la operación de la unidad.

2.1. LA ESTRATEGIA DE CONTROL ACTUAL

El lazo de control de temperatura actual consiste en una cascada de dos PID, el control de temperatura de salida de proceso como lazo maestro y el control de presión de gas a quemadores, como lazo esclavo o dependiente.

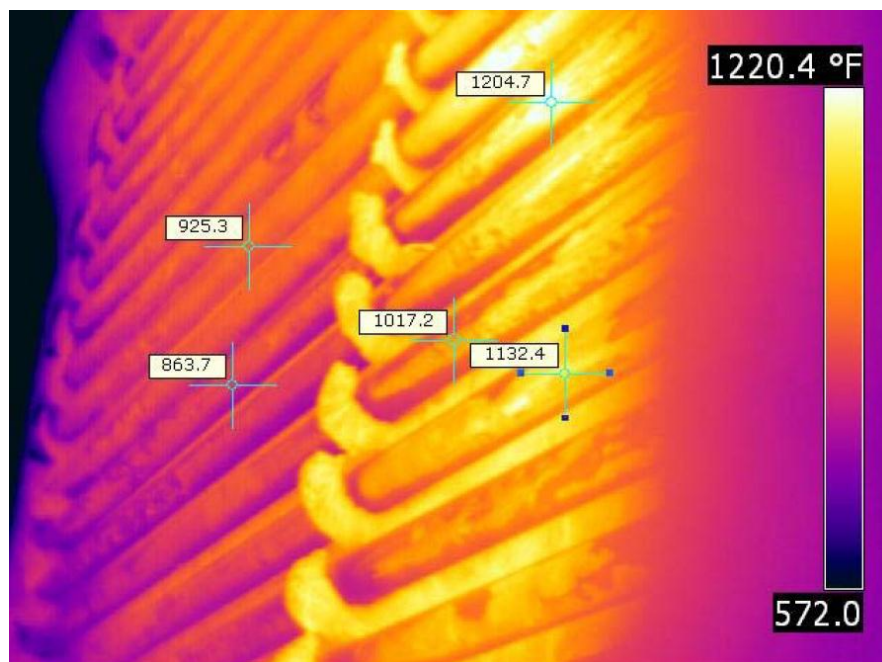
Figura 2. La estrategia de control actual



La evaluación del lazo de control actual evidencia valores de sobre paso de temperatura en la salida de proceso ante la inestabilidad de la composición de gas combustible de suministro.

El Impacto de la inestabilidad se evidencia en las altas temperaturas de piel de tubos, registrados en los sensores correspondientes. En la figura 3 se presenta una termografía donde se evidencian zonas de temperatura por encima de las guías de control y ventanas operativas; en el interior de los tubos que incrementan la velocidad de formación de coque, modificando el factor de transferencia de calor por conducción y disminuyen la eficiencia de los equipos de quema. En la figura 4 se presenta un registro fotográfico de los serpentines del H2801A durante una inspección de reparación y mantenimiento después de la corrida 57 de la unidad de proceso.

Figura 3. Termografía interior del H2801A



Fuente: Ecopetrol. Información Técnica de la Refinería de Barrancabermeja. 2014

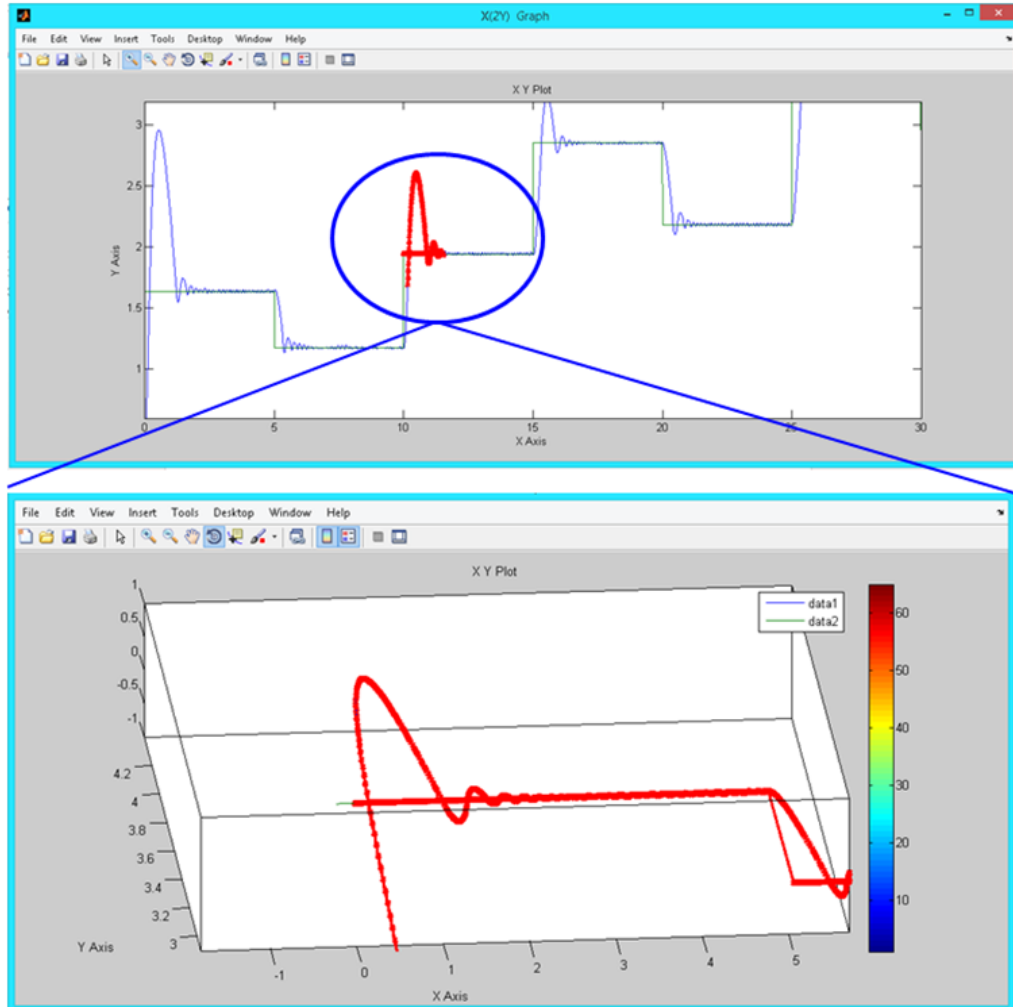
Figura 4. Registro fotográfico tubos del H2801A



Fuente: Ecopetrol. Información Técnica de la Refinería de Barrancabermeja. 2014


En la figura 5 se observa la curva de respuesta del lazo de control actual, bajo la estrategia de control de temperatura, en cascada con el control de presión de gas combustible a quemadores, se evidencia altos porcentajes de sobre paso de la señal de temperatura respecto al valor de referencia del lazo de control, parámetro responsable de la inestabilidad del sistema de combustión en el horno objeto del trabajo de aplicación.

Figura 5. Curva de respuesta lazo de control actual.



A partir del análisis del lazo de control de temperatura actual, se define como criterio de estabilidad el valor del sobrepaso de señal de temperatura de salida sobre el valor de referencia de dicho lazo. Adicional se define como criterio de adaptabilidad el desempeño del lazo de control a lo largo de la corrida de la U2800, en la figura 6 se observa el bajo nivel de adaptabilidad del lazo de control actual en el transcurso de la corrida de la unidad, dinámica que se afecta por la modificación de los coeficientes de transferencia de calor en el interior de los serpentines de los tubos por coquizamiento progresivo.

Figura 6. Inestabilidad del lazo de control actual.



2.2. EL CABEZAL DE GAS COMBUSTIBLE.

En la tabla 1, se presenta el resultado de una cromatografía típica de la red de suministro a la U2800 donde se evidencia como componentes principales el metano, hidrógeno, etano, propano, propileno y un poder calórico de 940 BTU por cada pie cúbico.

Tabla 1. Cromatografía gas de suministro al H2801A

Cromatografía típica de la red de suministro	Valor	Unidad
Hidrógeno	9,77	% mol
Oxígeno	0,02	% mol
Nitrógeno	1,8	% mol
Monóxido de Carbono	0,48	% mol
Dióxido de Carbono	0,82	% mol
Metano	77,9	% mol
Etano	3,46	% mol
Propano	1,26	% mol
Propileno	1,29	% mol
Iso-butano	0,6	% mol
N-butano	0,63	% mol
Iso-pentano	0,32	% mol
Total olefinas	1,23	% mol
Potencia Calorífica	940	BTU

Fuente: Ecopetrol. Información Técnica de la Refinería de Barrancabermeja. 2014

El gas combustible proviene de dos fuentes principales, una externa a la refinería consistente en gas natural, compuesto por metano el cual es suministrado por los campos de producción del país; esta primera fuente es de composición estable; la segunda fuente de suministro es interna de la refinería y consiste en una mezcla de varios gases de cola de las unidades de proceso, el cual es de composición variable, dependiendo de las condiciones operacionales de cada unidad. En la tabla 2 se presenta un resumen histórico en un periodo de un año, tiempo que dura la corrida

de la U2800, donde se muestran los resultados de cromatografías realizadas a la mezcla de gas combustible de suministro y se resaltan los valores máximos y mínimos en porcentaje molar, para el metano, como gas base de la mezcla y el etano, como el principal enriquecedor del poder calórico y el hidrógeno como principal empobrecedor de la mezcla.

Tabla 2. Histórico cromatografía de gas U2800.

GAS COMBUSTIBLE % MOL							
FECHA	METANO	CO2	ETANO	ETILENO	H2	PROPANO	PROPILENO
OCTUBRE	78.84	0.21	3.96	1.02	10.55	0.92	1.18
NOVIEMBRE	83.36	0.15	3.12	0.52	7.95	0.81	1.07
DICIEMBRE	73.35	1.18	7.17	1.43	10.56	1.49	0.98
ENERO	91.31	1.01	4.26	0.07	0.26	0.90	0.05
FEBRERO	78.70	0.16	4.84	0.75	10.49	0.78	1.00
MARZO	82.65	0.35	6.33	0.46	5.41	1.70	0.65
ABRIL	79.87	0.08	3.00	0.44	11.24	0.54	0.88
MAYO	77.05	1.24	5.63	0.44	8.96	1.70	1.05
JUNIO	83.67	0.18	2.14	1.26	8.25	0.60	0.90
JULIO	83.08	0.26	1.69	0.94	8.97	0.64	0.95
AGOSTO	87.83	0.18	2.15	0.72	5.95	0.37	0.56
SEPTIEMBRE	85.21	0.23	1.62	0.71	7.81	0.52	0.74
OCTUBRE	82.47	0.67	2.70	0.66	8.78	0.70	0.94
NOVIEMBRE	81.67	0.20	3.91	0.41	7.99	0.82	1.22
Límite Superior	95.55	1.66	9.79	1.79	16.53	2.18	1.76
Límite Inferior	68.59	0.79 (-)	1.14(-)	0.38(-)	0.36 (-)	0.39(-)	0.03(-)
Promedio	82.06	0.43	3.75	0.70	8.08	0.89	0.86

Desviación Estándar	4.49	0.40	1.74	0.36	2.81	0.43	0.29
Especificaciones	>=65; <= 85	<=0.40	<=10	<=4.00	<=20.00	<=3.00	

Fuente: Ecopetrol. Información Técnica de la Refinería de Barrancabermeja. 2014.

Se evidencia entre otros aspectos el rango de contenido de metano, el cual tiene un valor mínimo de 73.335 % mol, y un máximo de 91.31% mol; el rango de contenido de hidrogeno, el cual tiene un valor de 0.26% mol y alcanza un máximo de 11.24 % mol; por otro lado se aprecia el contenido de etano en valores de 1.62% mol y 7.17 %mol respectivamente.

Para la industria del petróleo han sido muchos los estudios sobre variabilidad de gas combustible y el intento por estabilizar la energía entregada a los procesos. A continuación se presentan algunos casos donde se presentan las bases conceptuales que permiten abordar el trabajo de aplicación, se realiza una descripción de la red de gas combustible, el proceso de combustión y sus parámetros, la intercambiabilidad de gases y sus implicaciones, así como el uso del gas de refinería y el efecto sobre otros equipos de combustión. Igualmente se presentan trabajos donde se diseñaron nuevas estrategias de control, mediante el uso de la inteligencia artificial y la incorporación de redes neuronales artificiales RNA, como complementos efectivos en la búsqueda de estabilizar los complejos sistemas de combustión.

Es así como la combustión es uno de los procesos más analizados a través de la historia de la ingeniería, por su gran impacto como mecanismo de reacción para el suministro de energía química. Dentro de los parámetros de operación que afectan el proceso de la combustión se resaltan: la intercambiabilidad de gases, la

composición, el poder calorífico, la temperatura adiabática de llama y la eficiencia del proceso.

3. MARCO TEÓRICO Y ESTADO DEL ARTE

3.1. INTERCAMBIABILIDAD DE GASES.

En el caso particular de la combustión de gases, se han realizado estudios sobre los efectos que generan en los quemadores el cambio de la fuente de suministro.

Debido a que el principal uso del gas natural es como combustible, la variación de las propiedades del gas, representa un enorme reto desde el punto de vista de poder asegurar su combustión segura, eficiente y con menor impacto ambiental.

Todos los equipos de combustión a gas están diseñados para operar con un intervalo particular de especificaciones de gas, en el caso de los hornos de tiro natural mediante la correlación de la presión a quemadores y la energía suministrada por unidad de volumen para determinado valor de poder calorífico. Si las propiedades del gas se salen de dicho intervalo se representan problemas de combustión incompleta, daños en los equipos y una operación riesgosa entre otros aspectos.

Los problemas con la intercambiabilidad se traducen en fenómenos de combustión que afectan el desempeño de los equipos de combustión y las emisiones que se generan como producto de la reacción; en la tabla 3 se presenta un listado de problemas asociados a la intercambiabilidad de gases, los cuales se relacionan por un lado con los fenómenos de combustión y por otro lado con la naturaleza de las emisiones.

Tabla 3. Problemas de Intercambiabilidad de gases.

PROBLEMAS DE INTERCAMBIABILIDAD	
Relacionado con fenómenos de combustión	Relacionados con la naturaleza de las emisiones
Puntas de Llama Amarilla – Inquemados	Monóxido de carbono (CO)
Desprendimiento de la llama del quemador	Óxidos de nitrógeno (Nox)
Apagado de la llama - Baja presión.	Hidrocarburos sin quemar (CxHy)
Auto ignición de gas	
Problema de dinámica de la llama	
Retroceso de la llama.	

Fuente: Ortiz (2014). Fundamentos de la intercambiabilidad del gas natural. *MET&FLU Ciencia Tecnología e Innovación*, 7-15.

3.2. ÍNDICES DE INTERCAMBIABILIDAD

En su trabajo Montaña, presenta los métodos para hallar la intercambiabilidad de gases, basado en el cálculo de magnitudes llamadas “índices de Intercambiabilidad” los cuales relacionan las propiedades físicas del gas y los fenómenos de combustión, permitiendo una mejor caracterización y en consecuencia un rango más ajustado y preciso de intercambiabilidad, así mismo determinan el comportamiento de la combustión del gas sustituto. (1). Se presenta el índice de Wobbe (IW) como ejemplo de índice simple, a los índices de Weaver como representantes de índices múltiples y el diagrama de Delbourg como método gráfico.

3.3. ÍNDICE DE WOBBE:

Desde el inicio del siglo pasado el físico italiano Goffredo Wobbe describe la intercambiabilidad de un amplio rango de gases mediante el Índice que lleva su nombre, dado por la siguiente expresión.

$$IW = \frac{PCI}{\sqrt{D_r}} \quad (1)$$

Donde IW es el Índice de Wobbe,
PCI el poder calorífico inferior del combustible
D_r la densidad relativa del gas.

De esta manera Wobbe estableció una proporcionalidad que combina las ecuaciones de flujo de entrada de energía al quemador y de la hidráulica asociada al flujo de gas. A partir de este planteamiento formuló las siguientes observaciones:

La energía que suministra un quemador es directamente proporcional al caudal volumétrico de gas que ingresa al quemador.

La velocidad del flujo a través de un orificio dado, a presión constante es inversamente proporcional a su gravedad específica.

Cuanto mayor sea el IW, mayor será la energía asociada al flujo de gas que pasa a través de un orificio o inyector de determinado tamaño para alimentar un quemador.


En un estudio realizado por el Dr. Campos Avella, recomienda controlar los desvíos de etano, propano y butano provenientes de la refinería, de tal forma que el

combustible alimentado al quemador pertenezca siempre a la familia 2 del índice de Wobbe. (2)

3.4. PREPARACIÓN DE GAS COMBUSTIBLE.

Muller et al. Determinaron que en la preparación del gas combustible, la composición debe ser controlada dentro de límites de especificación. Esto permite a los clientes la quema segura y transferencia de calor constante. Las variables a controlar son el poder calorífico alto, (HHV), El Índice de Wobbe (WI), El Índice de velocidad de llama (FSI) y la presión. (3), variables ilustradas en la figura 7.

Figura 7. Diagrama de Proceso de Mezcla de gas Industrial



Fuente: MULLER, E. A. Modelling, validation and control of an industrial fuel gas blending system. Journal Process Control 21, 852-860. 2011

En acuerdo con Muller, Ricker et al. determinaron que en mezcla de gases Industriales se propone un sistema de control donde las variables controladas son la presión del gas combustible y tres mediciones de la composición del gas. Y se propone que las velocidades de flujo de gas de seis alimentaciones pueden

manipular para lograr el objetivo. (RIKER. Fuel gas blending benchmark for economic performance evaluation of advanced control and state estimation. journal process Control, 968-974. 2012).

Por su parte Cala, (4) concluye después de un estudio realizado mediante la simulación de las mezclas combustibles que es viable realizar el proceso de combustión con gases de refinería con un índice de eficiencia energética mayor o igual a 6.5, pues para este valor encontró rangos de temperatura e índice de Wobbe que no generan perturbaciones y problemas en el horno. (4).

Finalmente, Montaña D. determinó que los principales efectos de la variación del poder calorífico y del Índice de Wobbe en los hornos de proceso, se evidencian en las temperaturas de piel de tubos de los hornos, existe una relación directa, al aumentar el poder calorífico, se incrementa la temperatura de piel de tubos, y realizó hallazgos sobre la compatibilidad química y determinó una relación por encima de la cual no es conveniente degradar corrientes. (5)

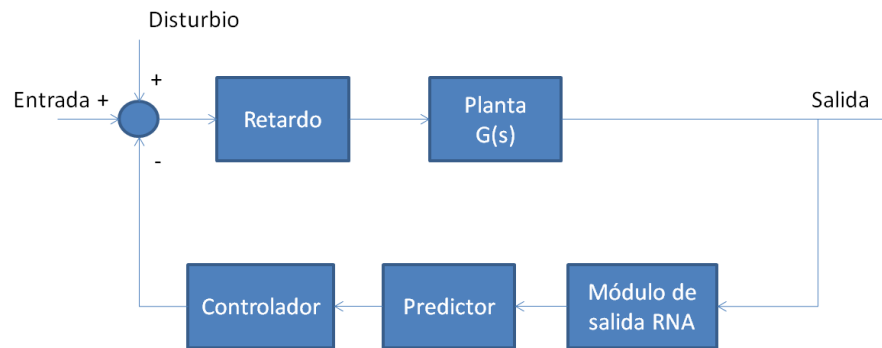
3.5. CONTROL ADAPTATIVO CON REDES NEURONALES.

En su trabajo de investigación, Ortiz et al, sobre control de temperatura de un planta no lineal con redes neuronales, presentan una comparación entre un control convencional y un control inteligente, los controladores desarrollados con un PID y un control con redes neuronales para un sistema térmico, mediante el planteamiento de un modelo matemático y el modelo mediante la identificación paramétrica de la planta con mínimos cuadrados. Para el control convencional, se diseña un control PID por medio del método del lugar geométrico de las raíces. El control neuronal se implementó con redes neuronales NARMA-L2, con cuatro neuronas, dos en la capa oculta, una en la capa de entrada y una en la capa de salida. La red neuronal es entrenada con seis algoritmos diferentes, una vez entrenada la red, se selecciona

el mejor método y se valida en el sistema con el control PID y el control neuronal. (Ortiz & Arias, 2009).

Por su parte, Liu et al. Presentan una nueva estrategia para la estabilización de un sistema de combustión. El algoritmo es diseñado en tres partes: un módulo de salida, un módulo de predicción y un controlador feedback. El módulo de salida se establece usando una red neuronal artificial la cual predice la salida para compensar el tiempo de retardo del sistema, el cual es suficientemente grande comparado con el periodo de muestreo. Se introduce en la estrategia un controlador feedback el cual se utiliza para suprimir la inestabilidad del proceso, en la figura 8 se presenta un diagrama simplificado de bloques propuesto en el diseño de Liu. (6).

Figura 8. Modelo de control predictivo basado redes neuronales artificiales.




Normey & Rico et al. En su trabajo de estudios de estrategias de control para sistemas con tiempo muerto concluye con algunas recomendaciones para el diseño de controladores de compensación compensador de tiempo muerto, a partir del análisis del Predictor SMITH.

En su trabajo Castillo J. concluye que los controladores industriales son configurados de tal manera que valiéndose de la robustez del algoritmo Proporcional Integral Derivativo PID, ignoran por completo la dinámica del sistema. La implementación de un Predictor Smith y el diseño del control en cascada en los sistemas de combustión de una refinería se traducen en estabilidad, confiabilidad y rentabilidad de los procesos.

NA Jing et al. Diseñaron el ATPFC, por sus siglas en inglés “adaptive time-delay positive feedback controller” para compensar tiempo muerto de sistemas no-lineales a partir del uso de redes neuronales artificiales RNA, el cual identifica el tiempo muerto y alimenta un controlador feedback que corrige dicho retardo. En el diseño utilizan dos “high-order neural networks” HONN, redes neuronales artificiales de orden superior empeladas para identificar el sistema no-lineal (7) y Hussain A. En su estudio sobre aplicaciones de redes neuronales artificiales RNA en procesos químicos, concluye que las RNA han sido utilizadas en una serie de aplicaciones de ingeniería química tales como sensores de análisis de datos, detección de fallas e identificación de sistemas no-lineales, como resultado de las capacidades de modelamiento de las mismas. Aunque hay muchos tipos de RNA, las aplicaciones en procesos químicos se centran en las redes multinivel tipo feedforward con funciones de transferencia del tipo sigmoidea. (8).

En la figura 9, se ilustra parte del diseño Bahman y Ali, de acuerdo al entrenamiento, validación y prueba de resultados de una red neuronal de tres niveles de cuatro neuronas cada uno como la mejor arquitectura de para la predicción de variables de proceso.

Figura 9. Esquema simplificado de una red neuronal de tres niveles



Proposed three layer feed forward neural network model.

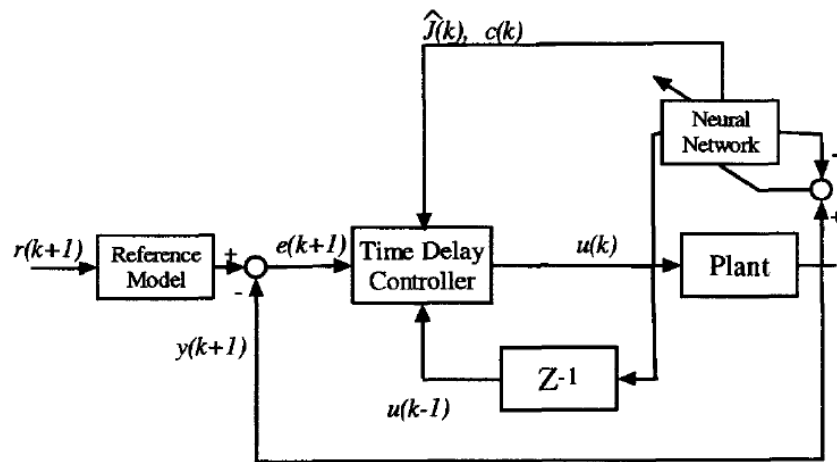
Fuente: BAHMAN, Z., & ALI, A. A multi-layer feed forward neural network model for accurate prediction of flue gas sulfuric acid dew point in process industries. Applied Thermal Engineering 30, 692-696. 2010.

3.6. CONTROL DE UNA PLANTA NO LINEAL CON REDES NEURONALES

En su investigación Jeong et al determinaron que el control de una planta no lineal, el cual es difícil de modelar por los métodos analíticos, es posible realizarlo mediante una red neuronal multinivel, la cual se adapta mediante el entrenamiento en línea, asimilando los cambios del sistema a controlar. En la figura 10 se presenta un esquema de modelamiento de sistemas no lineales mediante el uso de redes neuronales, dónde se presenta un esquema de la estructura propuesta para un controlador, $\hat{j}(k)$ denota la estimación Jacobiana de la red neuronal con respecto a $u(k)$. Si hay un error de modelado en la red neuronal, este puede ser corregido por bloque de retardo de tiempo en el algoritmo de control. La red neuronal se adapta

continuamente a la planta real, adicional se observa como el algoritmo de retardo de tiempo se adapta a los cambios rápidos del sistema y la red neuronal se adapta a los cambio lentos del sistema. Frente a otros algoritmos de control de redes neuronales, el algoritmo propuesto, en general, tiene las siguientes ventajas, la red neuronal puede ser utilizado antes de aprender a fondo del comportamiento de toda la planta, porque TDC puede tolerar un cierto grado de error de modelado de redes neuronales; el algoritmo propuesto sintetiza el control de realimentación de errores y control de alimentación directa.

Figura 10. Esquema modelamiento con redes neuronales.



Fuente: JEONG-WOO, L., & JUN-HO, O. Time delay control of nonlinear systems with neural network modeling. Pergamon - Mechatronics , 613-640. 1997.

El sistema propuesto por Xiucheng y Haibin, evidencia características de control excelentes, esto se debe al uso de un sistema adaptativo, y la rápida corrección de los parámetros del controlador neuronal.

Las RNA ofrecen algunas ventajas como no linealidad, gracias a la sinapsis el procesador neuronal biológico no es lineal, el procesador neuronal artificial también utiliza la sinapsis y sólo se activa si la señal supera el umbral de activación, lo que

también lo convierte en no lineal. Si la neurona es no lineal la red neuronal también lo es; transformación entrada-salida: El proceso de aprendizaje de la red consiste en mostrarle un ejemplo y modificar sus pesos sinápticos de acuerdo con su respuesta. De esta forma la red tiene la capacidad de aprender y adaptarse a la transformación entrada-salida; adaptabilidad, una red neuronal es capaz de adaptar sus parámetros incluso en tiempo real; tolerancia a fallas, al existir una conectividad masiva la falla de un procesador no altera seriamente la operación.

Para la industria del petróleo han sido muchos los estudios sobre variabilidad de gas combustible y el intento por estabilizar la energía entregada a los procesos. A continuación se presentan algunos casos donde se presentan las bases conceptuales que permiten abordar el trabajo de aplicación, se realiza una descripción de la red de gas combustible, el proceso de combustión y sus parámetros, la intercambiabilidad de gases y sus implicaciones, así como el uso del gas de refinería y el efecto sobre otros equipos de combustión. Igualmente se presentan trabajos donde se diseñaron nuevas estrategias de control, mediante el uso de la inteligencia artificial y la incorporación de redes neuronales artificiales RNA, como complementos efectivos en la búsqueda de estabilizar los complejos sistemas de combustión.

Es así como la combustión es uno de los procesos más analizados a través de la historia de la ingeniería, por su gran impacto como mecanismo de reacción para el suministro de energía química. Dentro de los parámetros de operación que afectan el proceso de la combustión se resaltan: la intercambiabilidad de gases, la composición, el poder calorífico, la temperatura adiabática de llama y la eficiencia del proceso

En su trabajo de investigación, Ortiz et al, sobre control de temperatura de un planta no lineal con redes neuronales, presentan una comparación entre un control convencional y un control inteligente, los controladores desarrollados con un PID y

un control con redes neuronales para un sistema térmico, mediante el planteamiento de un modelo matemático y el modelo mediante la identificación paramétrica de la planta con mínimos cuadrados. Para el control convencional, se diseña un control PID por medio del método del lugar geométrico de las raíces. El control neuronal se implementó con redes neuronales NARMA-L2, con cuatro neuronas, dos en la capa oculta, una en la capa de entrada y una en la capa de salida. La red neuronal es entrenada con seis algoritmos diferentes, una vez entrenada la red, se selecciona el mejor método y se valida en el sistema con el control PID y el control neuronal. (9)

Por su parte, Liu et al. Presentan una nueva estrategia para la estabilización de un sistema de combustión. El algoritmo es diseñado en tres partes: un módulo de salida, un módulo de predicción y un controlador feedback. El módulo de salida se establece usando una red neuronal artificial la cual predice la salida para compensar el tiempo de retardo del sistema, el cual es suficientemente grande comparado con el periodo de muestreo. Se introduce en la estrategia un controlador feedback el cual se utiliza para suprimir la inestabilidad del proceso, en la figura 8 se presenta un diagrama simplificado de bloques propuesto en el diseño de Liu. (6)

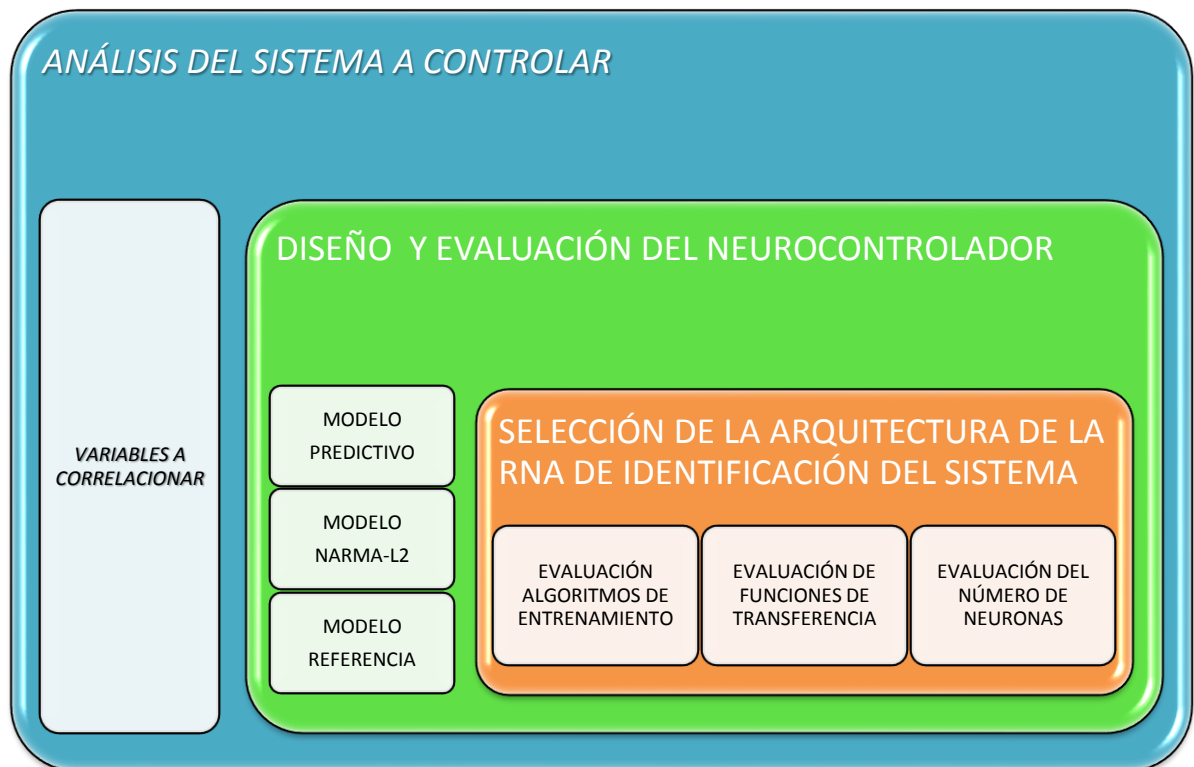
En su investigación Jeong et al determinaron que el control de una planta no lineal, el cual es difícil de modelar por los métodos analíticos, es posible realizarlo mediante una red neuronal multinivel, la cual se adapta mediante el entrenamiento en línea, asimilando los cambios del sistema a controlar. Si hay un error de modelado en la red neuronal, este puede ser corregido por bloque de retardo de tiempo en el algoritmo de control. La red neuronal se adapta continuamente a la planta real, adicional se observa como el algoritmo de retardo de tiempo se adapta a los cambios rápidos del sistema y la red neuronal se adapta a los cambio lentos del sistema (10)

En su trabajo Rairám et al implementan el algoritmo de aprendizaje backpropagation en línea para el entrenamiento de redes neuronales tipo feedforward, tres neurocontroladores para tres sistemas. La primera estrategia que se prueba para todos los sistemas es un PID clásico, el cual es utilizado para comparar el desempeño de los otros controladores. El primer neurocontrolador comparte la responsabilidad de comandar al sistema con un PID; el siguiente es entrenado en línea y trabaja solo; y por último se encuentra un controlador PID neuronal, el cual cambia las ganancias del PID para hacerlo adaptable a la dinámica de la planta (11) Finalmente Ortiz et al presentan los resultados de la comparación de respuesta de control convencional PID y redes neuronales, donde se evidencia al reducción del sobre paso y el cumplimiento de la robustez, y la adaptabilidad de estrategia, para analizar los resultados se valida el sistema ante la misma señal de entrada tanto para el control convencional como el diseñado con redes neuronales, aunque los resultados obtenidos por los dos controladores es buena, el control con redes presenta un mejor comportamiento, mejorando la estabilidad y disminuyendo el tiempo de respuesta del sistema. (9)

4. METODOLOGÍA

La figura 11 ilustra la metodología desarrollada para el logro de los objetivos propuestos, análisis del sistema a controlar donde se determinan las variables a correlacionar, el diseño y evaluación del neurocontrolador a partir de los modelos propuestos en la herramienta Matlab, y la selección de la arquitectura de la red neuronal de identificación de la planta a partir de la evaluación de los algoritmos y funciones de transferencia.

Figura 11. Metodología del trabajo de aplicación



4.1. VARIABLES A CORRELACIONAR

Las variables a correlacionar se seleccionaron mediante análisis estadístico de las variables instrumentadas en el sistema de control actual, y la validación mediante pruebas a partir de movimientos en la unidad de proceso y su correspondiente efecto en las variables asociadas, en la tabla 4 se muestra el resultado de la selección de las variables a correlacionar,

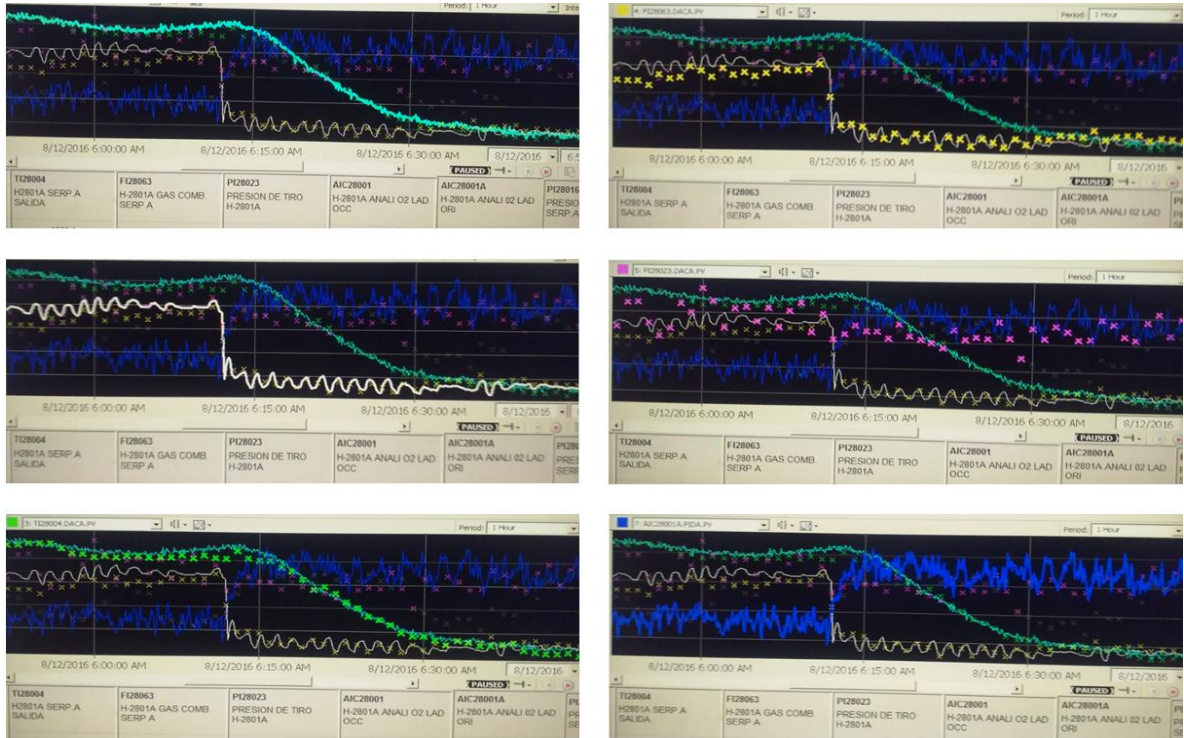
Tabla 4. Variables a correlacionar

Variable a correlacionar	Tag - PI	VALOR TIPICO	UI
Poder calorífico del gas combustible de suministro a H2801AB	U2800-DG28013	1130,108765	BTU / FT ³
Temperatura de salida de proceso serpentín A H2801A.	U2800-TIC28001	889,9050293	GRADOS F
Presión de gas combustible a quemadores serpentín A H2801A.	U2800-PIC28015	11,35817528	PSIG
Temperatura de salida de proceso serpentín B H2801A	U2800-TIC28002	880,2564087	GRADOS F
Presión de gas combustible a quemadores serpentín B H2801A	U2800-PIC28017	13,11139488	PSIG
Temperatura de salida de proceso serpentín A H2801B	U2800-TIC28003	888,9232788	GRADOS F

Presión de gas combustible a quemadores serpentín A H2801B	U2800-PIC28019	12,12262535	PSIG
Temperatura de salida de proceso serpentín B H2801B	U2800-TIC28004	881,220459	GRADOS F
Presión de gas combustible a quemadores serpentín B H2801B	U2800-PIC28021	10,17065144	PSIG

El DG28013 registra el valor del poder calorífico del cabezal de gas combustible en British Thermal Unit, BTU por pie cúbico, mediante un transductor de gravedad específica; el TIC28001, registra y controla como lazo maestro dentro de la cascada, la temperatura de salida del serpentín A del horno H2801A en grados Fahrenheit, y el PIC28015, registra y controla la presión de gas combustible de suministro al serpentín A del horno H2801A, como lazo esclavo de la cascada en Pound Square Inch Gauge PSIG.

Figura 12. Variables Correlacionadas H2801



Las matrices de datos generadas para la correlación del control, las cuales se alimentan en la herramienta para el diseño, entrenamiento y validación de la red neuronal artificial.

Tabla 5. Matrices de datos para entrenamiento.

Command Window		Workspace			
<pre>>> input=xlread('horno_data1',2); >> target=xlread('horno_data1',3); fx >> </pre>		Name	Value	Min	Max
		input	<2x1378 double>	721.9063	1.7030e
		target	<1x1378 double>	8.3774	13.4367

4.2. DISEÑO DEL NEUROCONTROLADOR

El diseño del neurocontrolador se realiza a partir de los modelos de control disponibles en la herramienta Matlab para sistemas no lineales:

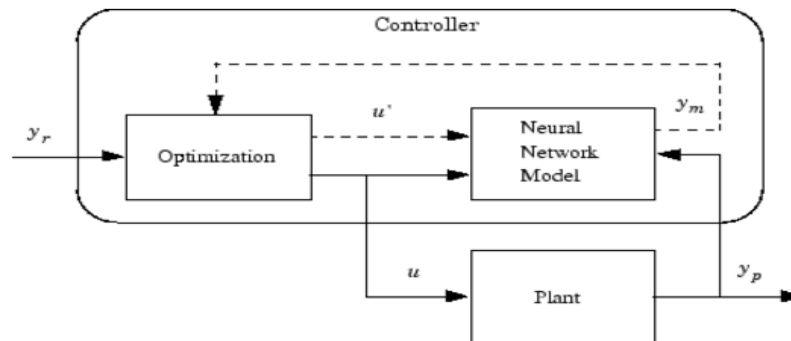
El Neural Network Predictive Controller, está basado en la técnica de retroceso de horizonte, dónde el modelo predice la respuesta de la planta sobre un horizonte de tiempo especificado. El control predictivo está basado en la predicción del

comportamiento futuro del proceso a controlar. Esta predicción es obtenida por un recurso de predicción de la red neuronal. Las predicciones son usadas por un programa de optimización numérica para determinar la señal de control que minimice el siguiente criterio de rendimiento sobre el horizonte de predicción, según la figura 13.

$$J = \sum_{j=N_1}^{N_2} (y_r(t+j) - y_m(t+j))^2 + \rho \sum_{j=1}^{N_u} (u'(t+j-1) - u'(t+j-2))^2$$

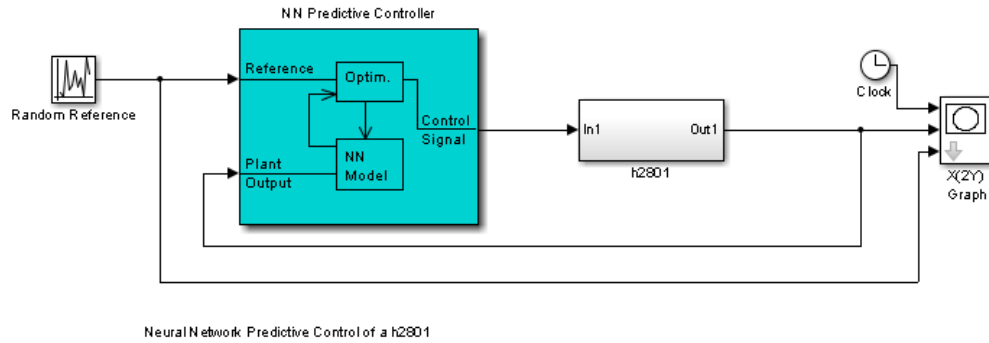
Donde N_1, N_2, N_u definen los horizontes sobre los cuales se realiza seguimiento y la evaluación de los incrementos de control, u' es la señal calculada, y_r es la respuesta deseada, y_m es la respuesta del modelo de la red, el valor ρ determina la contribución de la suma de los cuadrados sobre el rendimiento, en la figura 13 se presenta el diagrama de bloques del algoritmo del controlador predictivo neurona, NNPC y en la figura 14 se presenta diseño en la herramienta matlab para el controlador asociado a la planta h2801.

Figura 13. Diagrama de bloques NNPC



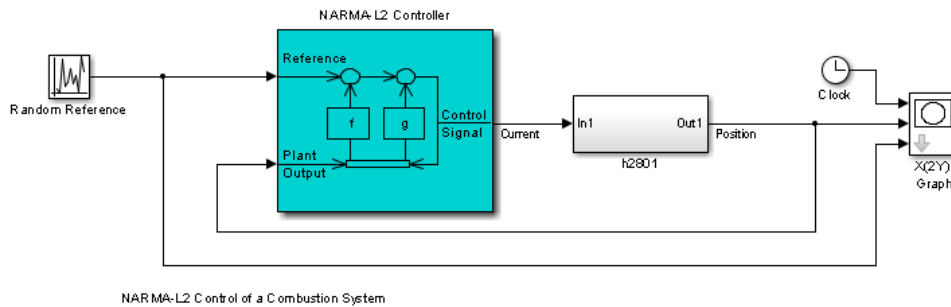
Fuente: MARK, H. B., MARTIN, T. H., & DEMUTH, H. B. (2012). Neural Network Toolbox. Natick, MA: MathWorks.

Figura 14. Diseño NNPC



El Nonlinear autoregressive-moving average (NARMA), La idea central de este tipo de control es la de transformar la dinámica de sistemas no lineales en dinámica lineal mediante la cancelación de las no linealidades, en la figura 15 se presenta diseño en la herramienta matlab para el controlador NNNArma-L2 asociado a la planta h2801.

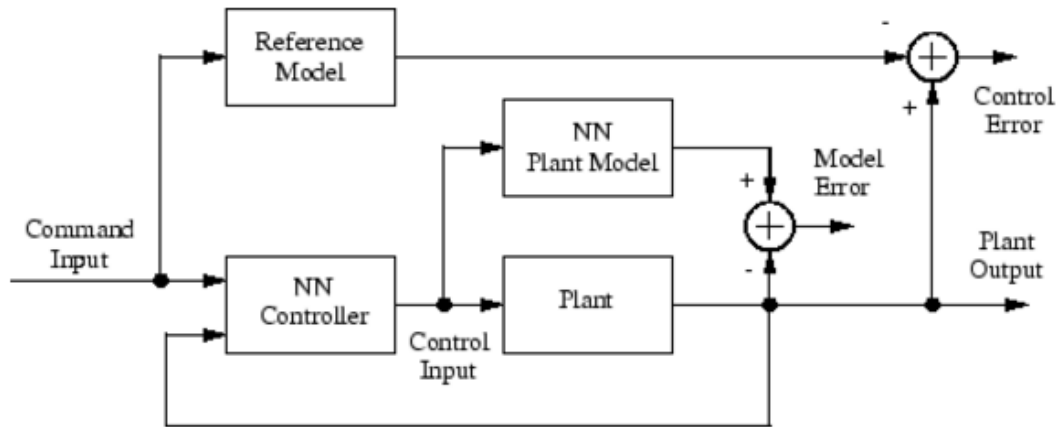
Figura 15. Diseño NNNArma-L2



El Model-Reference Neural Controller, utiliza dos redes neuronales, una red de control y una red de modelado de la planta. El modelo de la planta se identifica primero, y entonces el controlador se entrena para que la salida de planta siga la salida del modelo de referencia, en la figura 16 se presenta el diagrama de bloques

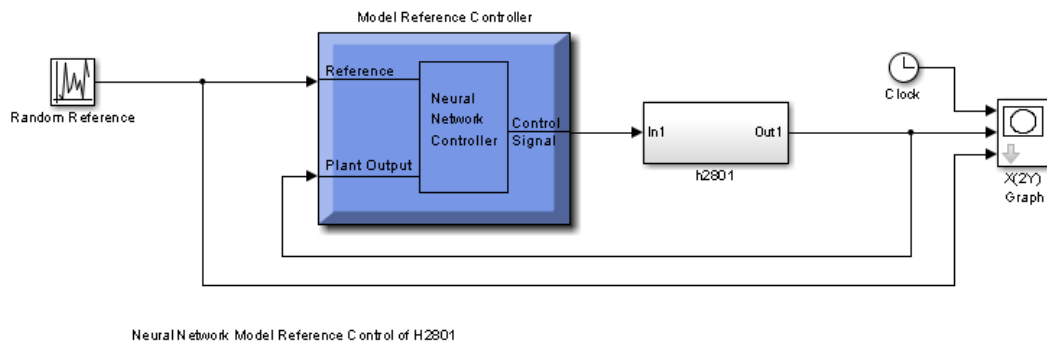
del algoritmo del controlador predictivo neurona, NNRC y en la figura 17 se presenta diseño en la herramienta matlab para el controlador asociado a la planta h2801..

Figura 16. Diagrama de bloques NNRC.



Fuente: MARK, H. B., MARTIN, T. H., & DEMUTH, H. B. (2012). Neural Network Toolbox. Natick, MA: MathWorks.


Figura 17. Diseño NNRC.



4.3. IDENTIFICACIÓN DEL SISTEMA

La primera etapa del modelo de control adaptativo es entrenar una red neuronal artificial para representar la dinámica de la planta. En la figura 18 se presenta el diagrama de bloques del algoritmo de identificación del sistema; donde se observa que la red es entrenada fuera de línea, usando los datos de operación de la planta.

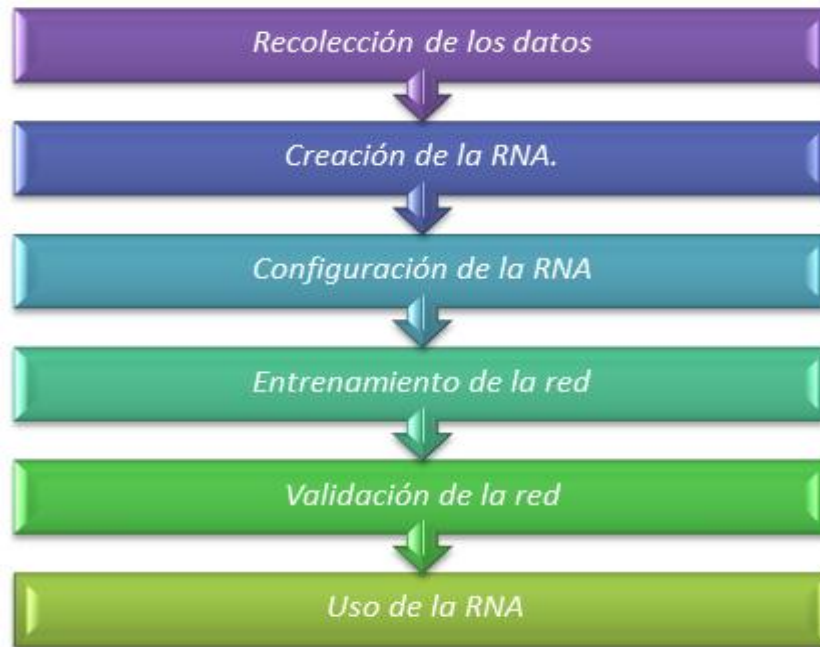
Figura 18. Diagrama de bloques identificación del sistema.



Fuente: MARK, H. B., MARTIN, T. H., & DEMUTH, H. B. (2012). Neural Network Toolbox. Natick, MA: MathWorks.

La identificación del sistema se realiza de acuerdo a la metodología sugerida en la figura 19, iniciando con la recolección de los datos de las variables seleccionadas a correlacionar.

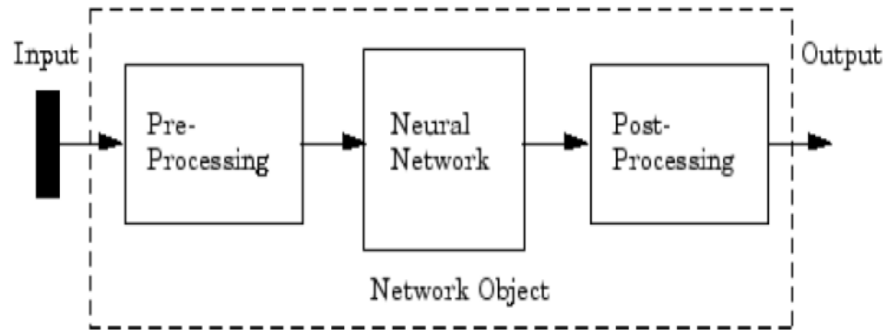
Figura 19. Metodología identificación del sistema.



El primer paso se realiza fuera del software de diseño de la RNA, los datos cubren un rango de entrada para los cuales se usará la red; la red generalizará dentro del rango seleccionado pero no tendrá la habilidad de extrapolar exactamente fuera del rango seleccionado.

Las rutinas de pre-procesamiento de los datos son provistas de manera automática por el software de diseño, mediante la normalización de los vectores de entradas y objetivos; la arquitectura de la red tendrá un bloque de pre-procesamiento, el cual estará entre la entrada a la red y el primer nivel de la red neuronal y un bloque de post-procesamiento el cual aparecerá entre el último nivel de neuronas y la salida de la red.

Figura 20. Diagrama de bloques procesamiento de datos



Fuente: MARK, H. B., MARTIN, T. H., & DEMUTH, H. B. (2012). Neural Network Toolbox. Natick, MA: MathWorks.

Después de recolectar los datos, el próximo paso fue crear la red, se selecciona dentro de las arquitecturas disponibles en la herramienta, las funciones de transferencia y los algoritmos de entrenamiento, los cuales son evaluados a continuación.

La función típica de desempeño para la validación de las redes neuronales es el promedio de la suma de los errores al cuadrado (MSE, de sus iniciales en inglés), el cual se busca minimizar para obtener el mejor desempeño posible de la red.

$$F = mse = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2$$

El error se calcula como la diferencia entre los valores correspondientes obtenidos por el modelo de la red y los valores obtenidos a través de la base de datos de la planta.

$$e_i = \hat{y} - y_{plan,i} \quad i = 1,2,3, \dots n$$

La función de desempeño comúnmente usada es el coeficiente de correlación Pearson (R) definido por la siguiente ecuación:

$$R = \frac{n (\sum_{i=1}^n y_{exp,i} * \hat{y}_i) - (\sum_{i=1}^n y_{exp,i}) * (\sum_{i=1}^n \hat{y}_i)}{\sqrt{[n \sum_{i=1}^n y_{exp,i}^2 - (\sum_{i=1}^n y_{exp,i})^2] * [n \sum_{i=1}^n \hat{y}_i^2 - (\sum_{i=1}^n \hat{y}_i)^2]}}$$

Con la función R se crea un gráfico de regresión, el cual muestra la relación entre los valores de salida del modelo (outputs) y los valores reales de las variables a predecir obtenidos de las bases de datos (targets). Si el modelo es perfecto los valores de los outputs y targets serian exactamente iguales mostrando un valor del coeficiente de correlación R igual a 1

En la tabla se listan las funciones de la herramienta de diseño y el nombre del algoritmo de entrenamiento correspondiente.

5. RESULTADOS.

5.1. CREAR Y CONFIGURAR LA RED

Como se mencionó previamente en el marco teórico y el estado del arte, los criterios de diseño y selección de la arquitectura de la red neuronal son la función de transferencia y el algoritmo de entrenamiento; en el contexto del desarrollo de la metodología del presente trabajo se evaluaron 16 funciones de transferencia y 15 algoritmos de entrenamiento en la red, en la tabla 6 se presenta un listado de los algoritmos evaluados y su correspondiente nombre. En la figura 21 aparece el bloque de identificación en la herramienta de diseño y el nombre encontrado en el ambiente de simulación; el resultado de la evaluación de las diferentes funciones coincide con la revisión de la literatura donde recomiendan ampliamente para cumplir con los objetivos propuestos de control el uso de la función logsig.

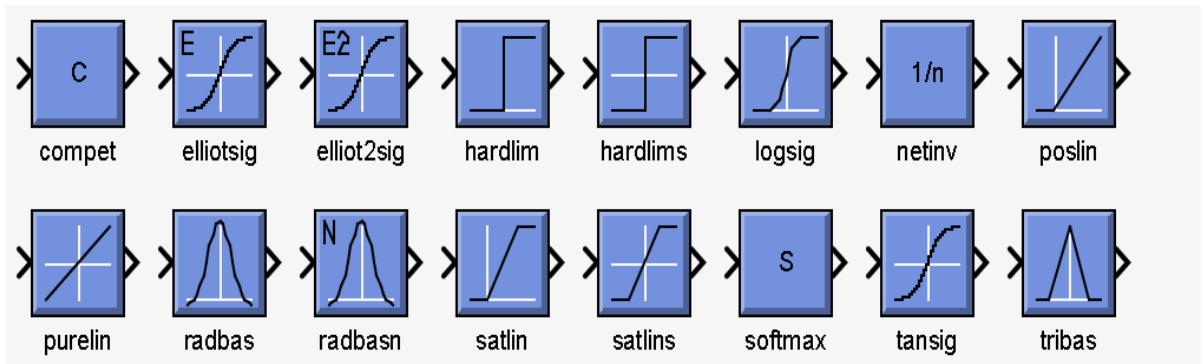
Tabla 6. Algoritmos evaluados.

Function	Algorithm
trainlm	Levenberg-Marquardt
trainbr	Bayesian Regularization
trainbfg	BFGS Quasi-Newton
trainrp	Resilient Backpropagation
trainscg	Scaled Conjugate Gradient
traincgb	Conjugate Gradient with Powell/Beale Restarts
traingcf	Fletcher-Powell Conjugate Gradient
traingcp	Polak-Ribière Conjugate Gradient
trainoss	One Step Secant
traingdx	Variable Learning Rate Gradient Descent
traingdm	Gradient Descent with Momentum
traingd	Gradient Descent

Fuente: MARK, H. B., MARTIN, T. H., & DEMUTH, H. B. (2012). Neural Network Toolbox. Natick, MA: MathWorks.

Se evalúan los algoritmos de entrenamiento y las funciones de transferencia disponibles.

Figura 21. Funciones de transferencia evaluadas.



Fuente: MARK, H. B., MARTIN, T. H., & DEMUTH, H. B. (2012). Neural Network Toolbox. Natick, MA: MathWorks.

Los resultados de la evaluación de los algoritmos de entrenamiento, las funciones de transferencia y el número de neuronas en la capa oculta se presentan en la tabla 7.

Tabla 7. Resultados de evaluación de algoritmos de entrenamiento.

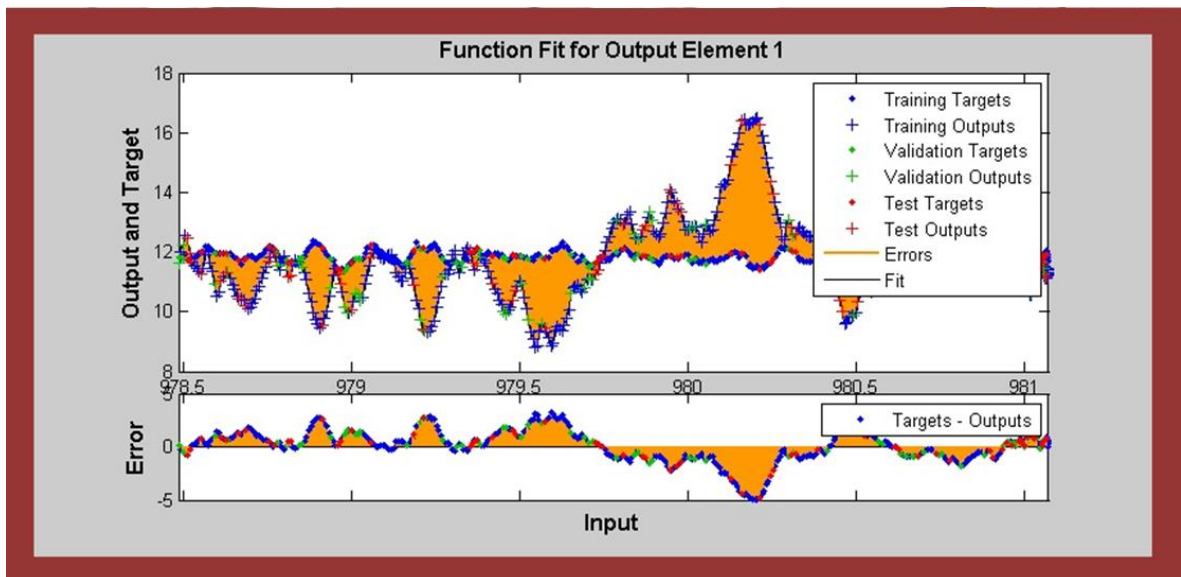
		ALGORITMOS DE ENTRENAMIENTO EVALUADOS EVALUADOS																							
FUNCIONES	N Neuronas	trainlm				trainbr				trainbfg				trainrp				trainscg				traincgb			
		3	7	10	13	3	7	10	13	3	7	10	13	3	7	10	13	3	7	10	13	3	7	10	13
elliotsig		< 0.9	< 0.9	< 0.9	< 0.9	> T	> T	> T	> T	< 0.9	< 0.9	< 0.9	< 0.9	< 0.7	< 0.7	< 0.7	< 0.7	< 0.8	< 0.8	< 0.8	< 0.8	< 0.7	< 0.7	< 0.7	< 0.7
elliotsig		< 0.9	< 0.9	< 0.9	< 0.9	> T	> T	> T	> T	< 0.9	< 0.9	< 0.9	< 0.9	< 0.7	< 0.7	< 0.7	< 0.7	< 0.8	< 0.8	< 0.8	< 0.8	< 0.7	< 0.7	< 0.7	< 0.7
hardlim		NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA
hardlims		NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA
logsig		0,9131	0,9572	0,9861	0,9959	0,86689	0,91021	0,95211	0,96659	0,78362	0,82154	0,86254	0,88362	0,53019	0,63019	0,71215	0,73019	0,55316	0,65214	0,82654	0,85316	0,69437	0,69437	0,69437	0,69437
netinv		< 0.9	< 0.9	< 0.9	< 0.9	> T	> T	> T	> T	< 0.9	< 0.9	< 0.9	< 0.9	< 0.7	< 0.7	< 0.7	< 0.7	< 0.8	< 0.8	< 0.8	< 0.8	< 0.7	< 0.7	< 0.7	< 0.7
poslin		NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA
purelin		NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA
radbas		< 0.9	< 0.9	< 0.9	< 0.9	> T	> T	> T	> T	< 0.9	< 0.9	< 0.9	< 0.9	< 0.7	< 0.7	< 0.7	< 0.7	< 0.8	< 0.8	< 0.8	< 0.8	< 0.7	< 0.7	< 0.7	< 0.7
radbasn		< 0.9	< 0.9	< 0.9	< 0.9	> T	> T	> T	> T	< 0.9	< 0.9	< 0.9	< 0.9	< 0.7	< 0.7	< 0.7	< 0.7	< 0.8	< 0.8	< 0.8	< 0.8	< 0.7	< 0.7	< 0.7	< 0.7
satlin		NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA
satlins		NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA
softmax		< 0.9	< 0.9	< 0.9	< 0.9	> T	> T	> T	> T	< 0.9	< 0.9	< 0.9	< 0.9	< 0.7	< 0.7	< 0.7	< 0.7	< 0.8	< 0.8	< 0.8	< 0.8	< 0.7	< 0.7	< 0.7	< 0.7
tagsin		0,9134	0,9545	0,9871	0,9959	0,86689	0,91021	0,95211	0,96659	0,78362	0,82154	0,86254	0,88362	0,53019	0,63019	0,71215	0,73019	0,55316	0,65214	0,82654	0,85316	0,69437	0,69437	0,69437	0,69437
tribas		< 0.9	< 0.9	< 0.9	< 0.9	> T	> T	> T	> T	< 0.9	< 0.9	< 0.9	< 0.9	< 0.7	< 0.7	< 0.7	< 0.7	< 0.8	< 0.8	< 0.8	< 0.8	< 0.7	< 0.7	< 0.7	< 0.7

		traincgf				traincgp				trainoss				traingdx				traingdm				traingd			
FUNCIONES	N Neuronas	3	7	10	13	3	7	10	13	3	7	10	13	3	7	10	13	3	7	10	13	3	7	10	13
		elliotsig		< 0.7	< 0.7	< 0.7	< 0.7	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.1	< 0.1
elliotsig		< 0.7	< 0.7	< 0.7	< 0.7	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.1	< 0.1	< 0.1	< 0.1
hardlim		NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA
hardlims		NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA
logsig		0,73374	0,73374	0,73374	0,73374	0,58828	0,58828	0,58828	0,58828	0,50666	0,50666	0,50666	0,50666	0,16436	0,16436	0,16436	0,16436	0,1425	0,1954	0,2124	0,23066	0,01245	0,01952	0,02814	0,0289
netinv		< 0.7	< 0.7	< 0.7	< 0.7	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.1	< 0.1	< 0.1	< 0.1
poslin		NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA
purelin		NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA
radbas		< 0.7	< 0.7	< 0.7	< 0.7	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.1	< 0.1	< 0.1	< 0.1
radbasn		< 0.7	< 0.7	< 0.7	< 0.7	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.1	< 0.1	< 0.1	< 0.1
satlin		NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA
satlins		NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA	NA
softmax		< 0.7	< 0.7	< 0.7	< 0.7	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.1	< 0.1	< 0.1	< 0.1
tagsin		0,73374	0,73374	0,73374	0,73374	0,58828	0,58828	0,58828	0,58828	0,50666	0,50666	0,50666	0,50666	0,16436	0,16436	0,16436	0,16436	0,1425	0,1954	0,2124	0,23066	0,01245	0,01952	0,02814	0,0289
tribas		< 0.7	< 0.7	< 0.7	< 0.7	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.6	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.2	< 0.1	< 0.1	< 0.1	< 0.1

Los resultados de la evaluación dónde el valor de R es inferior a 0.1, correspondientes al algoritmo de gradiente descendente, `traingd`, valor de R cercano a 0.95, sin embargo con tiempo de cálculo final después de realizadas todas las iteraciones del orden de cinco minutos, tiempo muy alto para la estrategia de control, correspondiente al algoritmo regularización Bayesiana, `trainbr` y finalmente algoritmo Levenberg-Marquardt, con tiempos de iteración alrededor de un segundo.

En la figura 22 se presentan los resultados del entrenamiento de la red neuronal utilizando el algoritmo `traingd`, se evidencia que el valor de R es menos a 0.1, lo cual indica que el porcentaje de error es inadmisiblemente alto para usar en el entrenamiento de la red neuronal.

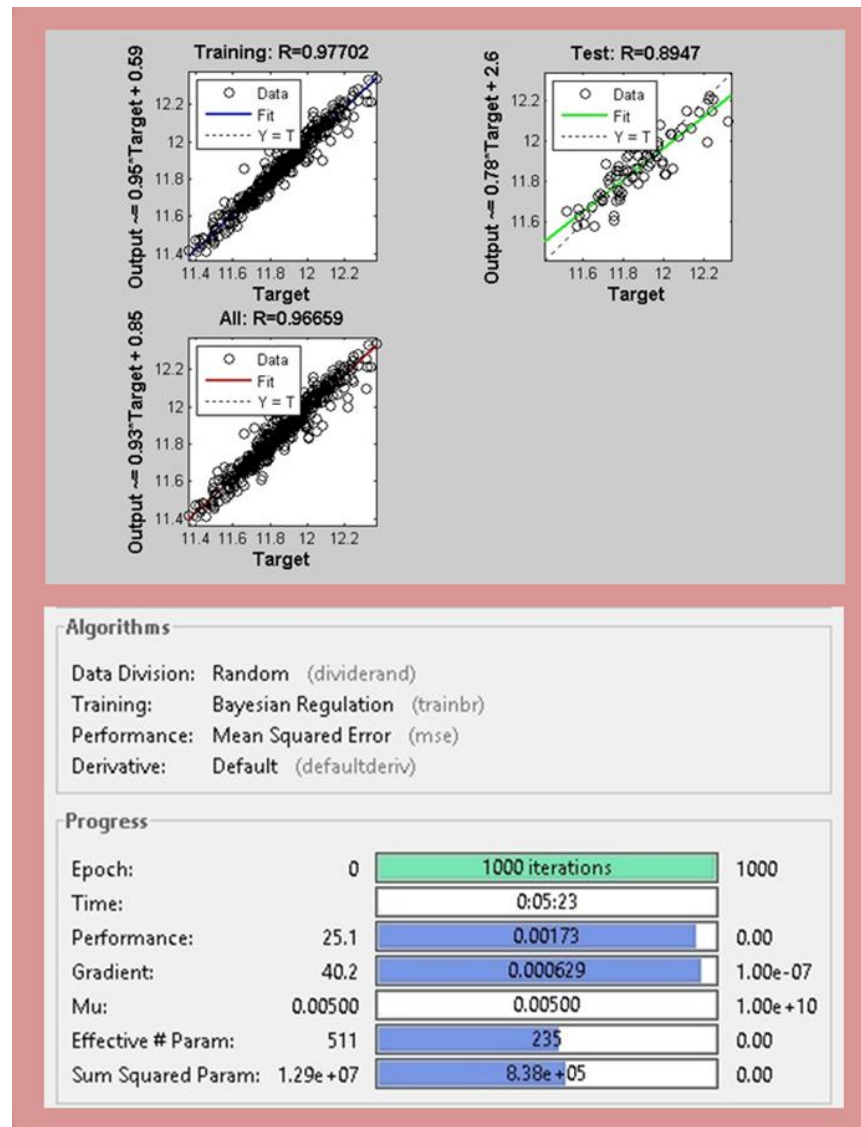
Figura 22. Grafica resultante función de entrenamiento `traincgb`.



En la figura 23 se presentan los resultados del entrenamiento de la red neuronal utilizando el algoritmo `trainbr`, se evidencia que el valor de R es mayor a 0.9, lo cual indica que el porcentaje de error es admisible para usar en el entrenamiento de la

red neuronal, sin embargo el tiempo de procesamiento es del orden de 5 minutos, lo cual es inadmisibles para la estrategia de control.

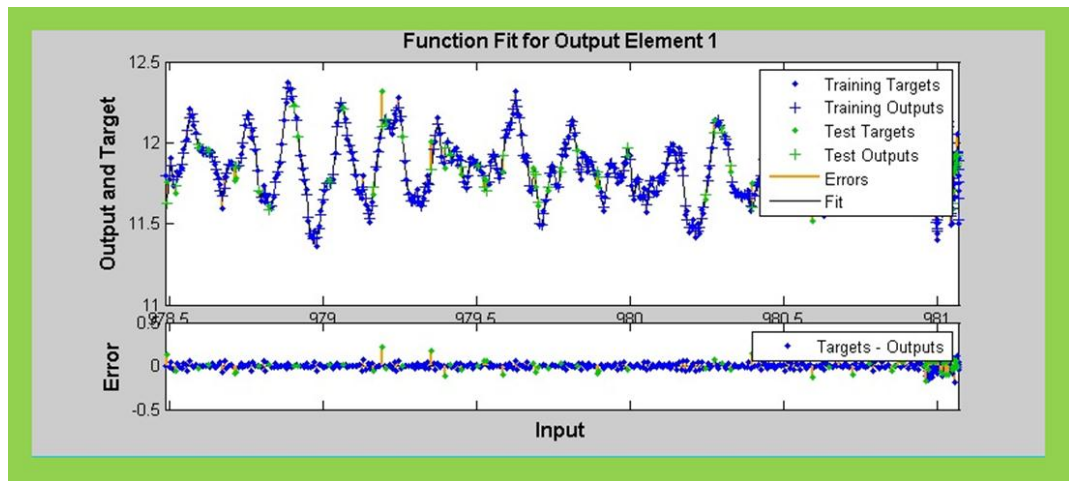
Figura 23. Desempeño función de entrenamiento trainbr



En la figura 24 se presentan los resultados del entrenamiento de la red neuronal utilizando el algoritmo trainlm, se evidencia que el valor de R es mayor a 0.99, lo cual indica que el porcentaje de error es admisible para usar en el entrenamiento de

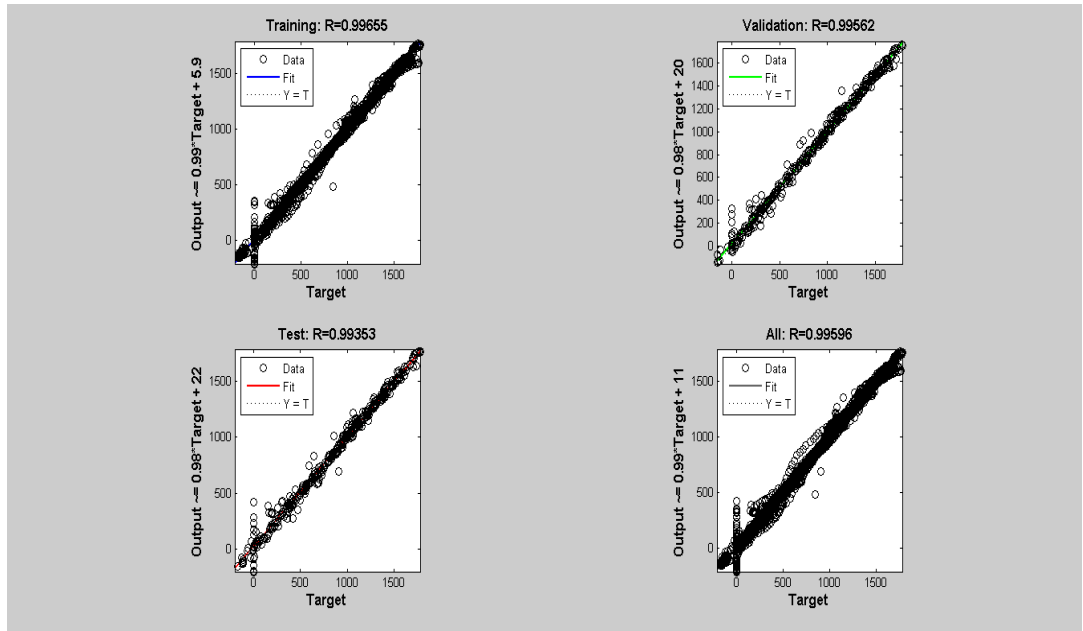
la red neuronal, y el tiempo de procesamiento es del orden de 1 segundo, lo cual es admisible para la estrategia de control.

Figura 24. Grafica resultante función de entrenamiento trainlm




En la figura 25 se presenta el resultado del desempeño de la función logsig y el algoritmo de entrenamiento trainlm, con 13 neuronas en la capa oculta, donde se observan valores de R en entrenamiento de 0.99665, valores de R en prueba de 0.9935 y valores de R en validación de 0.99562, los resultados son satisfactorios para la implementación de la estrategia de control.

Figura 25. Desempeño función de entrenamiento trainlm



Se evalúan los diferentes escenarios de correlación de variables y se selecciona la correlación de tres variables principales en el control de la combustión, la temperatura de salida por serpentín, el valor de presión de gas combustible y el valor del poder calorífico del cabezal de gas combustible, esta última como variable disturbio. Sin embargo se contemplaron correlaciones que incluían las temperaturas de piel del tubo, el flujo de gas combustible, el flujo de carga al horno, el exceso de oxígeno y el tiro del horno.

Figura 26. Resultado de la RNA




Teniendo en cuenta la literatura reciente y los análisis del comportamiento de las variables de combustión de los hornos se definen criterios de estabilidad, el valor de sobre paso de la variable temperatura de salida del serpentín y el tiempo de estabilización de la variable.

5.2. EVALUACIÓN DE LOS CONTROLADORES

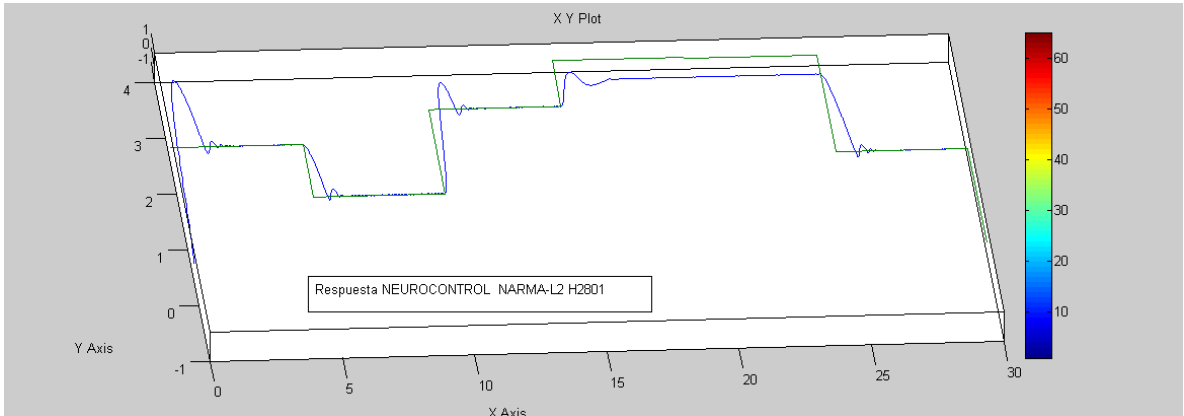
En la figura 27 se presenta la respuesta del neurocontrolador NNPC, donde se observa la corrección del sobrepaso de la señal de temperatura sobre la señal de referencia del lazo de control, sin embargo se observa inestabilidad en el tiempo de respuesta hacia un nuevo valor de referencia.

Figura 27. Respuesta del neurocontrolador NNPC




En la figura 28 se presenta la respuesta del neurocontrolador NNARMA-L2, donde no se observa mejora considerable en el valor del sobrepaso de la señal de temperatura sobre la señal de referencia del lazo de control, y se observa que se mantiene la inestabilidad en el tiempo de respuesta hacia un nuevo valor de referencia.

Figura 28. Respuesta del neurocontrolador NNARMA-L2



En la figura se presenta la respuesta del neurocontrolador NNRC, donde se observa la corrección del sobrepaso de la señal de temperatura sobre la señal de referencia del lazo de control, y se observa corrección de la inestabilidad en el tiempo de respuesta hacia un nuevo valor de referencia.

Figura 29. Respuesta del neurocontrolador NNRC



Adicional al criterio antes mencionado se analizan los requerimientos de procesamiento y computo on-line, off-line y el rango de aplicación, en la tabla se observa que los controladores NARMA-L2 y NNRC necesitan bajos requerimientos de computo en línea, el controlador NNPC, solicita bajos requerimientos de computo

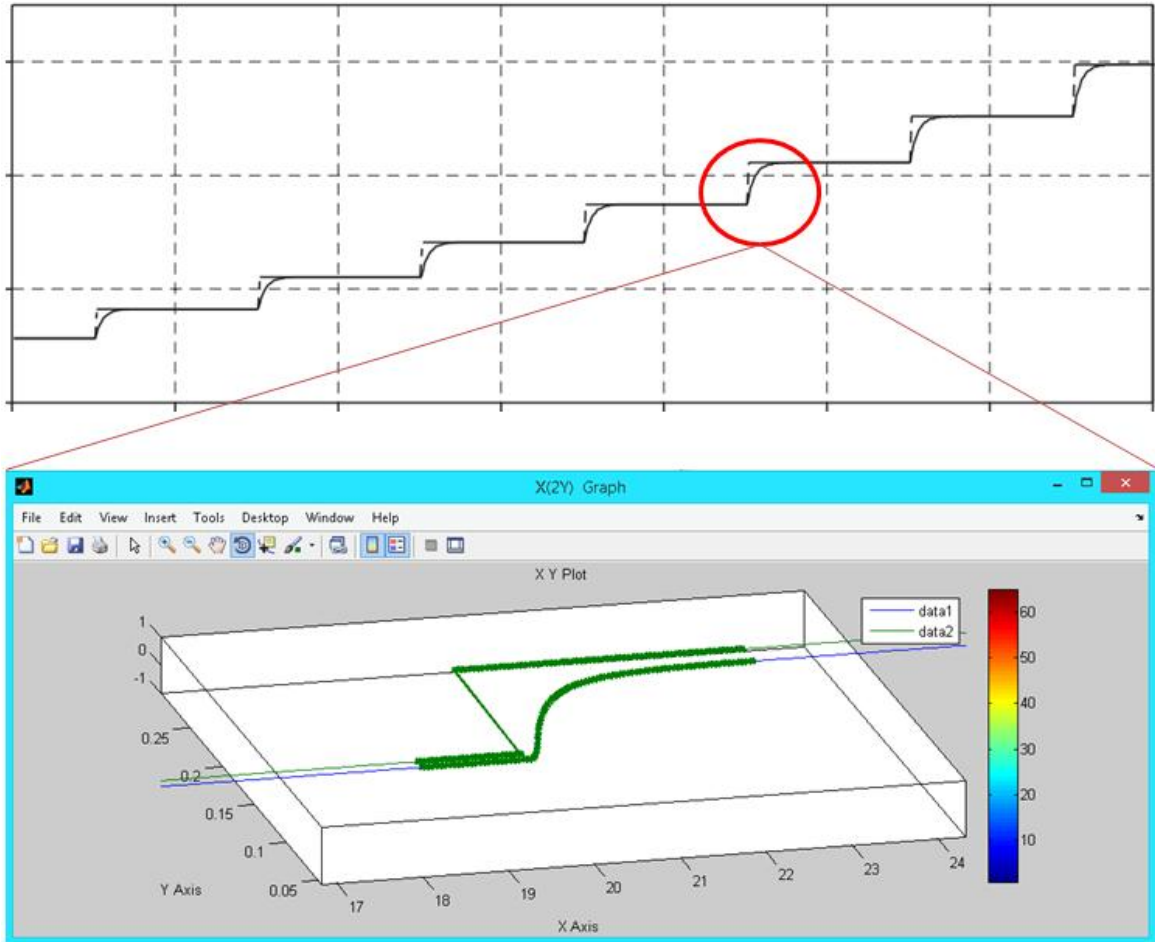
fuera de línea, y el controlador NNRC, es de los tres controladores el que mayor rango de aplicación ofrece.

Tabla 8. Requerimientos de cómputo de los controladores.

CARACTERISTICAS	NNPC	NARMA-L3	NNRC
REQUERIMIENTOS DE COMPUTO ON-LINE	ALTO	BAJO	BAJO
REQUERIMIENTOS DE COMPUTO OFF-LINE	BAJO	MEDIO	ALTO
RANGO DE APLICACIÓN	BAJO	MEDIO	ALTO

En la figura 30 se presenta la respuesta de salida en el control de temperatura en diferentes escenarios, los cuales representan las diferentes condiciones a lo largo de una corrida de la unidad de proceso; el valor del sobrepaso de señal de temperatura de salida sobre el valor de referencia de dicho lazo y se observa el cumplimiento del criterio de adaptabilidad de desempeño del lazo de control a lo largo de la corrida , en la figura 30 se observa el alto nivel de adaptabilidad del nuevo lazo de control el transcurso de la corrida de la unidad.

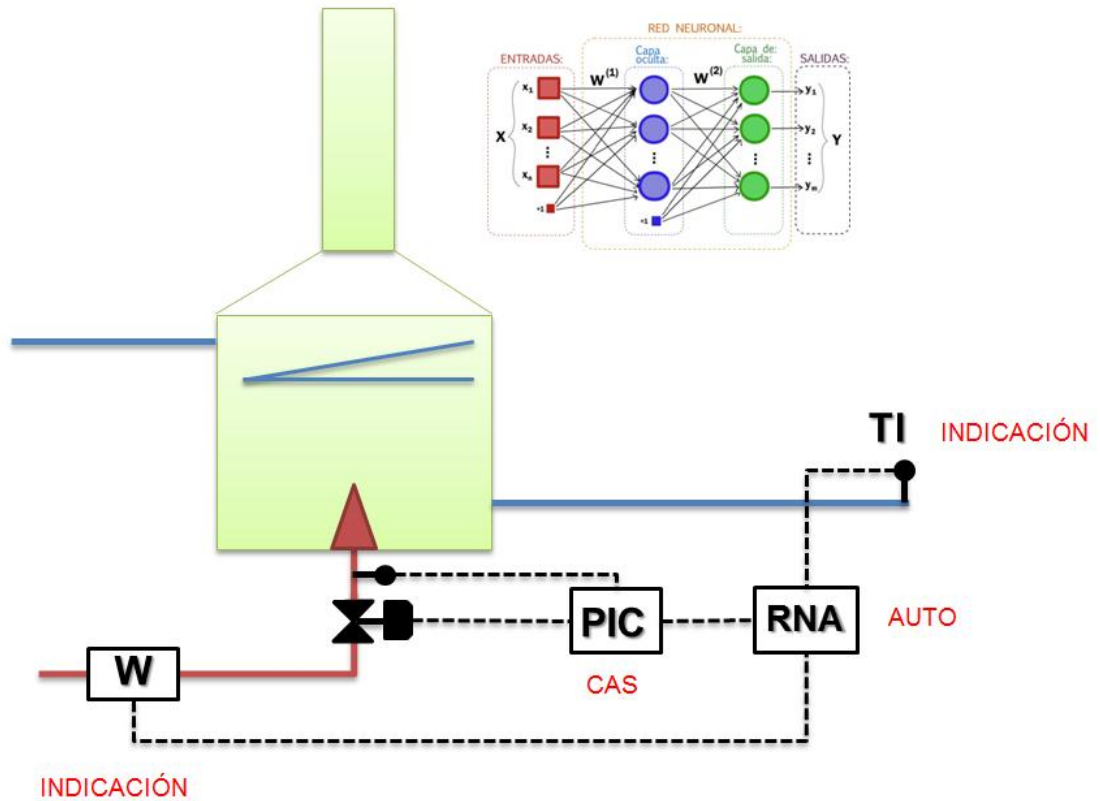
Figura 30. Respuesta salida en el control de temperatura.



5.3. NUEVA ESTRATEGIA DE CONTROL

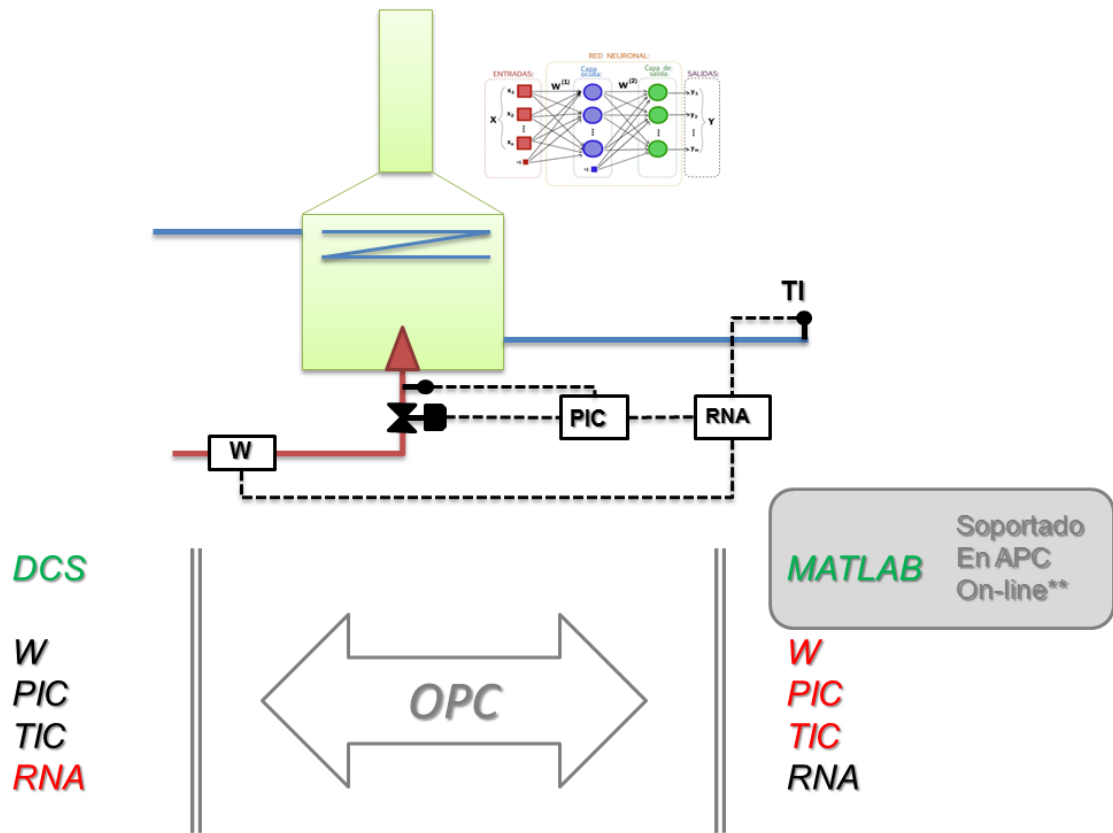
El nuevo lazo de control de temperatura consiste en una cascada, la indicación de temperatura de salida de proceso y un bloque de red neuronal artificial como lazo maestro, el cual incorpora la señal de temperatura y la señal de poder calorífico del cabezal de gas combustible y el control de presión de gas a quemadores, como lazo esclavo o dependiente

Figura 31. Esquema de nueva estrategia de control H2801A



La comunicación entre la herramienta Matlab y el sistema de control distribuido de la U2800 se realizará mediante el protocolo OPC, OLE for Process Control el cual es un estándar de comunicación en el campo del control y supervisión de procesos industriales, basado en una tecnología Microsoft, que ofrece una interfaz común para comunicación que permite que componentes software individuales interactúen y compartan datos, mediante la creación de las variables cliente – servidor correspondientes, para lo anterior se instala en software Matlab en el servidor de control avanzado de la U2500, el cual es común para la U2800.

Figura 32. Protocolo de comunicación DCS – Matlab.



** El servidor de control avanzado de la U2500 se encuentra en la misma red DCS [Experion Honeywell](#) de la U2800.

6. CONCLUSIONES.

Al analizar el sistema actual mediante la caracterización de las corrientes que componen la red de gas combustible desde el punto de vista físico-químico, se evidencia inestabilidad en el gas de suministro, a partir de las degradaciones de gases de cola de las unidades de proceso, así: U2500 degradación intermitente de Iso-butano, Normal-butano y propano provenientes de la operación de control de presión del sistema de recirculación de alta presión D2505 (230 a 70 PSIG), en rangos de 3000 PCEH, aportando alto poder calorífico a la red de gas y U2650 degradación intermitente de hidrógeno de la operación de purga del sistema de hidro-craqueo en D2653, (1500 a 70 PSIG), en rangos de 100 mil a 800 mil PCED, aportando bajo poder calorífico a la red de gas de suministro.

Al evaluar el sistema de combustión con la estrategia de control actual no cumple con todos los criterios de estabilidad, evidenciando altos valores de sobrepaso en el control de la temperatura de salida de los serpentines del H2801AB, ante las degradaciones de gas a la red de suministro.

Al diseñar la estrategia de control adaptativo, la mejor opción es el controlador MODELO DE REFERENCIA, NNMRC el cual tiene incorporada una RNA con las siguientes características evaluadas: Algoritmo de entrenamiento: LM, Función de transferencia: LOGSIG, Numero de neuronas en la capa oculta: 13

REFERENCIAS

1. Montaña, Daniel Dario. *Determinación de la propiedades de combustión e identificación de problemas de intercambiabilidad de las mezclas de gas natural con otros combustibles de refinería*. Bucaramanga : UIS, 2011.
2. Campos, Avella Juan Carlos. *Ahorro de energía en la Industria del Refino*. Medellin : Universidad Nacional, 2008.
3. *Modelling, validation and control of an industrial fuel gas blending system*. Muller, Et al. 2011, Journal Process Control 21, págs. 852-860.
4. Cala, P. *Determinación de los índices para la gestión de los procesos de combustion de los gases de refinería*. Bucaramanga : Universidad Industrial de Santander, 2013.
5. Montaña, Daniel. *Determinación de las propiedades de combustión e identificación de problemas de intercambiabilidad de las mezclas de gas natural con otros combustibles de refinería*. Bucaramanga : Universidad Industrial de Santander, 2011.
6. *Adaptative predictive control of combustor NOx emissions*. GP, Liu y Daley, S. 2001, Control Engineering Practice 9, págs. 631-638.
7. *Time-delay Positive Feedback Control for Nonlinear Time-delay Systems with Neural Network Compensation*. NA, Jing, REN, Xue Mei y HUANG, Hong. 2008, Acta Automatica Sinica, págs. 1196 - 2003.
8. *Review of the applications of neural networks in chemical process control simulation and online implementation*. Hussain, Mohamed Azlan. 1999, Artificial Intelligence in Engineering, págs. 55-68.
9. *Output-model-based predictive control of unstable combustion systems using neural networks*. Liu, G.P. y Duley, S. 1999, Control Engineering Practice, págs. 591-600.
10. *Unified approach for robust dead-time compensator desing*. Normey-Rico, Julio E y Camacho, Eduardo F. 2009, Journal of Process Control, págs. 38-47.

11. Technology, Aspen. Transformation of process Engineering. [En línea] 15 de Agosto de 2014. [Citado el: 6 de Diciembre de 2015.]
[Http://www.aspentech.com/Transformation of Process Engineering.pdf](http://www.aspentech.com/Transformation of Process Engineering.pdf).
12. America Petroleum Institute. *Standar 560 Fired heather for general refinery service*. Washington DC, USA : America Petroleum Institute, 2001.
13. —. *Standar 530 Calculation of Heater-tube Thickness in petroleum Refineries*. Washington, DC USA : America Petroleum Institute, 2008.
14. *Efectos del cambio de composición química del gas natural sobre el comportamiento de turbinas a gas: Una aproximación al caso colombiano*. A., Amell. 2006, Revista energética 35, págs. 23-31.
15. *Analisis comparativo de las propiedades de combustion de las mezclas metano-hidrógeno con respecto al metano*. Amell, A. 2006, Ingeniería y desarrollo Universidad del norte 20, págs. 19-34.
16. Ecopetrol. *Información Técnica de la Refinería de Barrancabermeja*. Barrancabermeja : Ecopetrol, 2014.
17. *Time delay control of nonlinear systems with neural network modeling*. Jeong-Woo, Lee y Jun-Ho, Oh. 1997, Pergamon - Mechatronics , págs. 613-640.
18. *A multi-layer feed forward neural network model for accurate prediction of flue gas sulfuric acid dew point in process industries*. Bahman, ZareNezhad y Ali, Aminian. 2010, Applied Thermal Engineering 30, págs. 692-696.
19. *Artificial Neural Networks (ANNs): A new paradigm for thermanl science and engineering*. Kwang-Tzu y Yang. 2008, vol 130, Journal of heat transfer, págs. 1-19.
20. *A state-of-the-art review of pulse combustion: Principles, modeling, applications and R&D issues*. Xiangmei, Meng, Wiebren, de Jong y Tadeusz, Kudra. 2016, Renewable and Sustainable Energy Reviews, págs. 73-114.
21. *Efecto de la Composición del gas de refinería sobre las características del proceso de combustión*. Saavedra, Jaqueline y Kafarov, V. 2013, Revista Ingenierías Universidad de medellín, págs. 101-112.

22. *Fuel gas blending benchmark for economic performance evaluation of advanced control and state estimation*. Riker. 2012, journal process Control, págs. 968-974.
23. Renjifo, Jose Raul. *Sistema experto de hornos*. Barrancabermeja : Ecopetrol, 2001.
24. *Combustion of hydrogen-enriched methane in a lean premixed swirl burner*. Schefer, W. s.l. : C, 2001, Combustion research, pág. 570.
25. *Análisis teorico de la combustión en quemadores de gas natural*. Serrano, J. 2005, Scientia et Technica, págs. 139-143.
26. *Variables significativas del proceso de combustión de gas natural*. Villafior. 2008, Información Tecnológica, págs. 57-62.
27. *Feedback control and optimization for the production of commercial fuels by blending*. Chebre. 2010, Journal Process Control, págs. 441-451.
28. *Mathamatical model for refinery furnaces simulation*. Diaz, F y Castro, J. 2010, C&T-Ciencia tecnología y futuro, págs. 89-99.
29. Wildy, F. *Fifed heater optimization*. Pittsburgh : Ametek, 2012.
30. Castillo, John Jairo. *Implementación de un Predictor Smith*. Bucaramanga : Universidad Pontificia Boliviana, 2012.
31. Mark, Hudson Beale, Martin, T. Hagan y Demuth, Howard B. *Neural Network Toolbox*. Natick, MA : MathWorks, 2012.
32. Institute, American Petroleum. *API RECOMMENDED PRACTICE 535*. Washington DC, USA : American Petroleum Institute, 2006.
33. Institute, America Petroleum. *Burners for Fired Heaters in General Refinery Services*. Washington DC : API, 2006.
34. Duque, Andres Felipe. *SINTONIZACIÓN DE CONTROLADORES PID EN AMBIENTES INDUSTRIALES*. cali : UNIVERSIDAD AUTÓNOMA DE OCCIDENTE, 2012.
35. *Research on fuzzy self-ada Pi-Smith control in long time-dalay system*. WEI, Qiu-yue y WANG, Wen-qing. 2011, The Journal of China Universities of Post and Telecommunications, págs. 114-117.

36. *Artificial intelligence for the modeling and control of combustion processes a review.* Soteris, Kalogirous. 2003, Progress in Energy and Combustion Science, págs. 515-566.
37. *Comparision of intelligent control schemes for real-time presure control.* Babusca, R, Braake, H y Van Can, H. 1996, Control eng. Practice, págs. 1585-1592.
38. *Fundamentos dela intercambiabilidad del gas natural.* Ortiz, Juan Manuel. 2014, MET&FLU Ciencia Tecnología e Innovación, págs. 7-15.
39. *A modified Smith predictive scheme based back-propagation neural network approach for FOPDT processes control.* Hao, Chen y Zoubir, Zouaoui. 2013, Journal of Process Control, págs. 1261-1269.
40. Baukal, Charles. *Tha John Zink Hamworthy Combustion Handbook.* New York : CRC press, 2013.
41. *Control de una planta no lineal de temperatura con redes neuronales.* Ortiz, Paula y Arias, Alexander. 2009, Avances en sistemas e informatica, págs. 127-141.
42. *Study on new control method for boiler combustion system.* Xiucheng, Dong y Haibin, Wang. Dalian : China, 2006. Proceeding of the 6th congress on intelligent control and automation. págs. 2943 - 2947.
43. *Neural prediction of combustion instability.* Cammarata, L, Fichera, A y Pagano, A. 2002, Dipartimento di Ingegneria Industrial e meccanica, Universita di Catania, págs. 513 - 528.
44. *Selection of best Neural Network for Estimating properties of Diesel - biodiesel blends.* Jatinder, Kumar y Ajay, Bansal. Greece : Corfu Island, 2007. Artificial Intelligece, Knowledge Engineering and data base. págs. 136 - 142.
45. *Implementación de neurocontroladores en linea.* Rairám, Jose D, Chiquiza, Diego y Parra, Miguel. 2011, Ing Univ. Bogotá, págs. 163-182.
46. *Contrtoller implementation in MATLAB and PLC with OPC communication applied to industrial plants.* Manyari, Manuel. 2008, Invest Apl Innov TECSUP, págs. 103-108.

47. Dennis, J.E., and R.B. Schnabel. *Numerical Methods for Unconstrained Optimization and Nonlinear Equations*. Englewood Cliffs, NJ : Prentice-Hall, 1983.

BIBLIOGRAFÍA

AMELL, A., Efectos del cambio de composición química del gas natural sobre el comportamiento de turbinas a gas: Una aproximación al caso colombiano. *Revista energética* 35, 23-31. 2006.

AMELL, A. Análisis comparativo de las propiedades de combustión de las mezclas metano-hidrógeno con respecto al metano. *Ingeniería y desarrollo Universidad del norte* 20, 19-34. 2006

AMERICA PETROLEUM INSTITUTE. Standar 560 Fired heater for general refinery service. Washington DC, USA: America Petroleum Institute. 2001.

AMERICA PETROLEUM INSTITUTE. Standar 530 Calculation of Heater-tube Thickness in petroleum Refineries. Washington, DC USA: America Petroleum Institute. 2008.

BABUSCA, R., BRAAKE, H., & VAN CAN, H. Comparison of intelligent control schemes for real-time pressure control. *Control eng. Practice*, 1585-1592. 1996.

BAHMAN, Z., & ALI, A. A multi-layer feed forward neural network model for accurate prediction of flue gas sulfuric acid dew point in process industries. *Applied Thermal Engineering* 30, 692-696. 2010.

BAUKAL, C. The John Zink Hamworthy Combustion Handbook. New York: CRC press. 2013.

CALA, P. Determinación de los índices para la gestión de los procesos de combustión de los gases de refinería. Bucaramanga: Universidad Industrial de Santander. 2013

CAMMARATA, L., FICHERA, A., & PAGANO, A. Neural prediction of combustion instability. Dipartimento di Ingegneria Industriale e meccanica, Università di Catania, 513 - 528. 2002.

CAMPOS, A. J. Ahorro de energía en la Industria del Refino. Medellín: Universidad Nacional. 2008.

CASTILLO, J. J. Implementación de un Predictor Smith. Bucaramanga: Universidad Pontificia Boliviana. 2012.

CHEBRE. Feedback control and optimization for the production of commercial fuels by blending. Journal Process Control, 441-451. 2010.

DENNIS, J. A. Numerical Methods for Unconstrained Optimization and Nonlinear Equations. Englewood Cliffs, NJ: Prentice-Hall. 1983.

DIAZ, F., & CASTRO, J. Mathematical model for refinery furnaces simulation. C&T- Ciencia tecnología y futuro, 89-99. 2010.

DUQUE, A. F. Sintonización de Controladores PID en Ambientes Industriales. Cali: Universidad Autónoma de Occidente. 2012.

ECOPETROL.. Información Técnica de la Refinería de Barrancabermeja. Barrancabermeja: Ecopetrol. 2014

GP, L., & DALEY, S. Adaptive predictive control of combustor NOx emissions. Control Engineering Practice 9, 631-638. 2001.

HAO, C., & ZOUBIR, Z. A modified Smith predictive scheme based back-propagation neural network approach for FOPDT processes control. Journal of Process Control, 1261-1269. 2013.

HUSSAIN, M. A. Review of the applications of neural networks in chemical process control simulation and online implementation. Artificial Intelligence in Engineering, 55-68. 1999.

INSTITUTE, A. P. API RECOMMENDED PRACTICE 535. Washington DC, USA: American Petroleum Institute. 2006.

INSTITUTE, A. P. Burners for Fired Heaters in General Refinery Services. Washington DC: API. 2006.

JATINDER, K., & AJAY, B. Selection of best Neural Network for Estimating properties of Diesel - biodiesel blends. Artificial Intelligence, Knowledge Engineering and data base (págs. 136 - 142). Greece: Corfu Island. 2007.

JEONG-WOO, L., & JUN-HO, O. Time delay control of nonlinear systems with neural network modeling. Pergamon - Mechatronics , 613-640. 1997.

KWANG-TZU, & YANG. Artificial Neural Networks (ANNs): A new paradigm for thermal science and engineering. Journal of heat transfer vol 130., 1-19. 2008

LIU, G., & DULEY, S. Output-model-based predictive control of unstable combustion systems using neural networks. Control Engineering Practice, 591-600. 1999.

MANYARI, M. Contrtoller implementation in MATLAB and PLC with OPC communication applied to industrial plants. Invest Apl Innov TECSUP, 103-108. 2008.

MARK, H. B., MARTIN, T. H., & DEMUTH, H. B. (2012). Neural Network Toolbox. Natick, MA: MathWorks.

MONTAÑA, D. Determinación de las propieddades de combustión e identificación de problemas de intercambiabilidad de las mezclas de gas natural con otros combustibles de refinería. Bucaramanga: Universidad Industrial de Santander.2011.

MONTAÑA, D. D. .Determinación de la propiedades de combustión e identificación de problemas de intercambiabilidad de las mezclas de gas natural con otros combustibles de refinería. Bucaramanga: UIS. 2011.

MULLER, E. A. Modelling, validation and control of an industrial fuel gas blending system. Journal Process Control 21, 852-860. 2011.

NA, J., REN, X. M., & HUANG, H. Time-delay Positive Feedback Control for Nonlinear Time-delay Systems with Neural Network Compensation. Acta Automatica Sinica, 1196 - 2003. 2008.

NORMEY-RICO, J. E., & CAMACHO, E. F. Unified approach for robust dead-time compensator desing. Journal of Process Control, 38-47. 2009.

ORTIZ, J. M. Fundamentos dela intercambiabilidad del gas natural. MET&FLU Ciencia Tecnología e Innovación, 7-15. 2014.

ORTIZ, P., & ARIAS, A. Control de una planta no lineal de temperatura con redes neuronales. Avances en sistemas e informatica, 127-141. 2009.

RAIRÁM, J. D., CHIQUIZA, D., & PARRA, M. Implementación de neurocontroladores en línea. Ing Univ. Bogotá, 163-182. 2011.

RENJIFO, J. R. Sistema experto de hornos. Barrancabermeja: Ecopetrol.2001.

RIKER. Fuel gas blending benchmark for economic performance evaluation of advanced control and state estimation. journal process Control, 968-974. 2012.

SAAVEDRA, J., & KAFAROV, V. Efecto de la Composición del gas de refinera sobre las características del proceso de combustión. Revista Ingenierías Universidad de medellín, 101-112. 2013.

SCHEFER, W. Combustion of hydrogen-enriched methane in a lean premixed swirl burner. Combustion research, 570. 2001.

SERRANO, J. Análisis teórico de la combustión en quemadores de gas natural. Scientia et Technica, 139-143. 2005.

SOTERIS, K. Artificial intelligence for the modeling and control of combustion processes a review. Progress in Energy and Combustion Science, 515-566. 2003.

TECNOLOGY, A. Transformation of process Engineering. 15 de Agosto de 2014 [en línea] {citado el 6 de Diciembre de 2015} Disponible en; de <http://www.aspentech.com/Transformation of Process Engineering.pdf>

VILLAFLORES. Variables significativas del proceso de combustión de gas natural. Información Tecnológica, 57-62. 2008.

WEI, Q.-Y., & WANG, W.-Q. Research on fuzzy self-ada Pi-Smith control in long time-dalay system. The Journal of China Universities of Post and Telecommunications, 114-117. 2011.

WILDY, F. Fified heater optimization. Pittsburgh: Ametek.2012.

XIANGMEI, M., WIEBREN, D. J., & TADEUSZ, K. A state-of-the-art review of pulse combustion: Principles, modeling, applications and R&D issues. Renewable and Sustainable Energy Reviews, 73-114..2016.

XIUCHENG, D., & HAIBIN, W. Study on new control method for boiler combustion system. Proceeding of the 6th congress on intelligent control and automation (págs. 2943 - 2947). Dalian: China. 2006.