



RED NEURONAL PARA CONTROL DE COMBUSTI N EN UNIDADES GENERADORAS DE VAPOR

NEURAL NETWORK FOR COMBUSTION CONTROL IN STEAM GENERATING UNITS

Fernando Mel an

fermelean90@gmail.com

B rbara A. Ordo ez S.

baordonez@urbe.edu.ve

Universidad Privada Dr. Rafael Belloso Chac n.

RESUMEN

Esta investigaci n tiene como objetivo proponer una red neuronal para control de combusti n en unidades generadoras de vapor. Sustentada por Lammers, H., Lammers, T. y Woodruff, E. (2004) en referencia a los sistemas de control de combusti n, y por Aggarwal, C. (2018), Jurado, F. et al. (2012) y Berzal, F. (2018) en relaci n con las redes neuronales. La investigaci n se considera proyectiva, documental y descriptiva, con un dise o no experimental, de campo y transeccional. La unidad de an lisis se compone de unidades generadoras de vapor empleadas para la estimulaci n t rmica de pozos de crudo extrapesado, pertenecientes a una empresa de servicios petroleros que se desempe a en los campos Lagunillas y Bachaquero de la regi n zuliana. Como t cnicas de recolecci n de informaci n se emplearon la revisi n documental, la entrevista no estructurada y las matrices de an lisis. El desarrollo estuvo comprendido en cinco (05) fases de dise o con una metodolog a mixta fundamentada en (1) las unidades objetivo planteadas para la investigaci n y (2) la metodolog a para el desarrollo de modelos de redes neuronales artificiales propuesta por Mari o, S. y Primorac, C. (2016). Se propuso un nuevo diagrama de proceso con control basado en redes neuronales artificiales. Como resultado de un an lisis comparativo, fue posible presentar un modelo de red neural artificial multicapa, con una (01) capa de entrada, conformada por 3 neuronas; cinco (05) capas ocultas de 10 neuronas cada una con funci n de activaci n ReLU, y dos (02) capas de salida con funci n de activaci n lineal. El entrenamiento de la red se llev  a cabo a trav s del algoritmo de backpropagation por el m todo del optimizador de Adam. Las pruebas de implementaci n realizadas a la red neuronal modelada validaron su capacidad de predecir los par metros de salida de inter s para el control de combusti n con muy buena precisi n.

Palabras clave: Red neuronal, control de combusti n, generadores de vapor, sistemas inteligentes.

ABSTRACT

The objective of this investigation is to propose a neural network for combustion control in steam generating units. The research is supported by Lammers, H.,



Lammers, T. and Woodruff, E. (2004) in reference to combustion control systems, and by Aggarwal, C. (2018), Jurado, F. et al. (2012) and Berzal, F. (2018) when related to artificial neural networks. Type of research was considered projective, documentary and descriptive, with a non-experimental, field and transactional design. The analysis unit is made up of steam generating units used for thermal stimulation of extra-heavy crude oil wells, belonging to an oil services company that operates in the Lagunillas and Bachaquero fields in the Zulia region. Documentary reviews, unstructured interviews and analysis matrices were used as data collecting techniques. Development was comprised of five (05) design phases with a mixed methodology based on: (1) the objectives proposed for the investigation and (2) the methodology for the development of artificial neural network models proposed by Mariño, S. and Primorac, C. (2016). A new process diagram with control based on artificial neural networks was proposed. As a result of a comparative analysis, it was possible to present a multilayer artificial neural network model, with one (01) input layer, made up of 3 neurons; five (05) hidden layers of 10 neurons each implementing ReLU activation functions, and two (02) output layers with linear activation functions. Network training was carried out through the backpropagation algorithm implementing the Adam optimizer. The implementation tests performed on the modeled neural network validated its ability to predict the output parameters of interest for combustion control with very good precision.

Keywords: Neural network, combustion control, steam generating units, intelligent systems.

INTRODUCCIÓN

La automatización es reconocida como elemento clave en el crecimiento y desarrollo de las industrias, garantizando el control efectivo de los procesos, de tal forma que éstos se lleven a cabo de un modo automático, reduciendo en todo lo posible la intervención humana, en un entorno de producción eficiente, tendente a satisfacer la creciente demanda de bienes y servicios, en intervalos de tiempo cada vez más reducidos. De allí la importancia de los sistemas inteligentes y redes neuronales, con capacidad de resolver problemas complejos y multidisciplinarios de una forma automática dando soporte a las decisiones.

Desde esta perspectiva, el presente artículo comprende la propuesta de una red neuronal para control de combustión en unidades generadoras de vapor, con lo que se describe el funcionamiento del control de combustión en unidades generadoras de vapor, selección de los parámetros operativos de la red neuronal y del tipo de red neuronal más apropiada, desarrollo de la arquitectura de la red neuronal y su validación mediante simulaciones del comportamiento de la red neuronal diseñada. Para llegar al cumplimiento del objetivo, el artículo comprende:

La presentación inicial del problema, que contiene el planteamiento del mismo, los objetivos, tanto general como específicos, la justificación y delimitación. Seguidamente se muestran los antecedentes de la investigación, se exponen las bases teóricas que fundamentaron el estudio, y se presenta el sistema de variables, con el cuadro de operacionalización.



Posteriormente se constituye el marco metodol gico, que refleja diversas estrategias empleadas para desarrollar el estudio, presentando el tipo y dise o de investigaci n, as  como las unidades de an lisis objeto de estudio, las t cnicas e instrumentos de recolecci n de datos y las fases de la investigaci n.

En este punto, se presentan los resultados en funci n del an lisis de los datos y discusi n de los resultados obtenidos luego de la aplicaci n de los instrumentos de recolecci n de informaci n. Se desarrollan las cinco (05) fases de dise o: Fase I, descripci n del funcionamiento del control de combusti n en unidades generadoras de vapor; Fase II, selecci n de los par metros operativos de la red neuronal; Fase III, dise o del modelo de red neuronal artificial; Fase IV, desarrollo del modelo de red neuronal artificial y Fase V, implementaci n del control por red neuronal artificial. Por  ltimo, conclusiones y recomendaciones.

METODOLOG A DE LA INVESTIGACI N

En funci n de la metodolog a aplicada, y seg n lo define Hurtado, J. (2012), la investigaci n proyectiva es aquella que consiste en la elaboraci n de una propuesta, un plan o un programa, como soluci n a un problema o necesidad de tipo pr ctico, a partir de un diagn stico preciso de las necesidades del momento, de los procesos explicativos involucrados y de las tendencias futuras, centr ndose en aplicaciones concretas y en dar respuesta al c mo hacer las cosas.

En este sentido, la presente investigaci n queda enmarcada como tipo proyectiva, puesto que se propone hallar la soluci n a un problema pr ctico, que consiste en la automatizaci n del control de combusti n en unidades generadoras de vapor, planteando un m todo para perfeccionar el funcionamiento de los componentes que se desempe an en el proceso de transferencia de calor intr nseco del sistema, por medio de la generaci n de un nuevo instrumento aplicable a esta realidad de estudio y basado en una estrategia de control como lo son las redes neuronales artificiales.

Al respecto de las fuentes de informaci n, Arias, F. (2012) define la investigaci n documental como un proceso basado en la b squeda, recuperaci n, an lisis, cr tica e interpretaci n de datos secundarios, obtenidos por otros investigadores en fuentes documentales, con el prop sito de aportar nuevos conocimientos. En este aspecto, la presente investigaci n se plantea adem s como tipo documental, debido a que emplea literatura y registros hist ricos referentes a los componentes, procesos, par metros operativos, metodolog as de control, entre otras caracter sticas que describen el comportamiento de generadores de vapor y el perfeccionamiento de redes neuronales artificiales.

Sobre estas mismas bases, Pimienta, J. y De la Orden, A. (2017) expresan que la investigaci n descriptiva busca identificar y describir los elementos, propiedades o caracter sticas principales que componen o explican determinados fen menos o problem ticas, bas ndose en el m todo anal tico. En referencia a esto, la presente investigaci n queda definida igualmente como de tipo descriptiva puesto que se basa en identificar y analizar los principales actores que intervienen en el funcionamiento del control de combusti n en unidades generadoras de vapor,



lo que en fases posteriores permitirá el desarrollo de un sistema de control para estos equipos basado en redes neuronales.

En conjunto con el tipo de investigación, se presenta también el diseño de la misma que, según los autores Palella, S. y Martins, F. (2012), se refiere a la estrategia que adopta el investigador para responder al problema planteado en el estudio. En este sentido, para dichos autores el diseño no experimental es el que se realiza sin manipular o sustituir en forma deliberada ninguna variable, observando los hechos tal y como se presentan en su contexto real. A partir de esta definición, es posible enmarcar el diseño de la presente investigación como tipo no experimental, dado que se plantea la observación del fenómeno objeto de estudio, esto es el proceso de control de combustión en generadores de vapor, tal como se da en su contexto natural y sin modificarlo intencionadamente, para posteriormente poder analizarlo en las fases subsecuentes de la investigación.

En este mismo contexto y acorde con la temporalidad de la investigación, Palella, S. y Martins, F. (2012) explican que las investigaciones con diseño transversal o transeccional se ocupan de recolectar datos en un tiempo único, describiendo las variables y analizando su incidencia e interacción en un momento dado. En base a lo expuesto, la presente investigación queda englobada en la categoría transeccional o transversal, puesto que la recolección de información referente a controles/componentes de los generadores y entrenamiento e implementación de redes neuronales, se lleva a cabo en un sólo momento, es decir, en un marco de tiempo único dentro del cual estos registros y documentación a utilizar son preservados.

Tratando ahora desde la perspectiva de la población y muestra, Pimienta, J. y De la Orden, A. (2017) definen que cuando se realiza cualquier investigación científica, esta se centra en analizar y comprender una determinada situación o problemática sobre la cual se desea responder diversas interrogantes. Para llevar a cabo este análisis, se debe tener en consideración el conjunto de elementos que son parte del fenómeno o problemática a estudiar, y que poseen características similares, pues éstos serán la base del estudio. A este conjunto, compuesto por la totalidad de los elementos, individuos o factores que forman parte del objeto de estudio, en un lugar y tiempo determinados, se le denomina población.

Aplicado a estas definiciones de población en los casos en que la población de un determinado estudio es muy amplia como para estar en posibilidades de hacer observaciones o entrevistar a todos sus integrantes, resulta necesario determinar una muestra que, según lo define Pimienta, J. y De la Orden, A. (2017), constituye una parte del total de la población, cuyas características resulten similares y, por tanto, representativas de la totalidad de la población.

Adentrándose aún más en este concepto de muestra representativa, Hurtado, J. (2012) define la unidad de estudio o unidad de análisis como el contexto, el ser o entidad poseedores de la característica, evento, cualidad o variable, que se desea estudiar. Una unidad de análisis puede ser una persona, un objeto, un grupo, una extensión geográfica, una institución, entre otros; y se debe definir de tal modo que a través de ella se pueda dar una respuesta completa, y no parcial o desviada, a la interrogante de la investigación.



Tomando como referencia los aportes de los autores antes mencionados, para efectos de la presente investigación, la unidad de análisis se compone de unidades generadoras de vapor empleadas para la estimulación térmica de pozos de crudo extrapesado, pertenecientes a una empresa de servicios petroleros que se desempeña en los campos Lagunillas y Bachaquero de la región zuliana.

Finalmente, en relación con las técnicas e instrumentos de recolección de datos, Pimienta, J. y De la Orden, A. (2017) expresan que estos son procedimientos diversos por medio de los cuales es posible recabar y organizar la información, para llevar a cabo el método que orientará el estudio, constituyendo herramientas o artefactos con los que apoyarse para la realización de las operaciones de una investigación. En este sentido, de acuerdo con la naturaleza de la presente investigación, los eventos que comprende y de las unidades/datos analizados, con la finalidad de poder cumplir con los objetivos planteados se aplicaron como técnicas e instrumentos de recolección de información la revisión documental, la entrevista no estructurada y las matrices de análisis.

ANALISIS DE LOS RESULTADOS

El desarrollo del presente estudio estuvo comprendido en cinco (05) fases de diseño por medio de una metodología mixta fundamentada en (1) las unidades objetivo planteadas para la investigación y (2) la metodología para el desarrollo de modelos de redes neuronales artificiales propuesta por Mariño, S. y Primorac, C. (2016), de esta manera se hizo posible cubrir el espectro de estudio completo, para la generación del conocimiento y productos trazados. A continuación, se presenta una descripción de dichas fases:

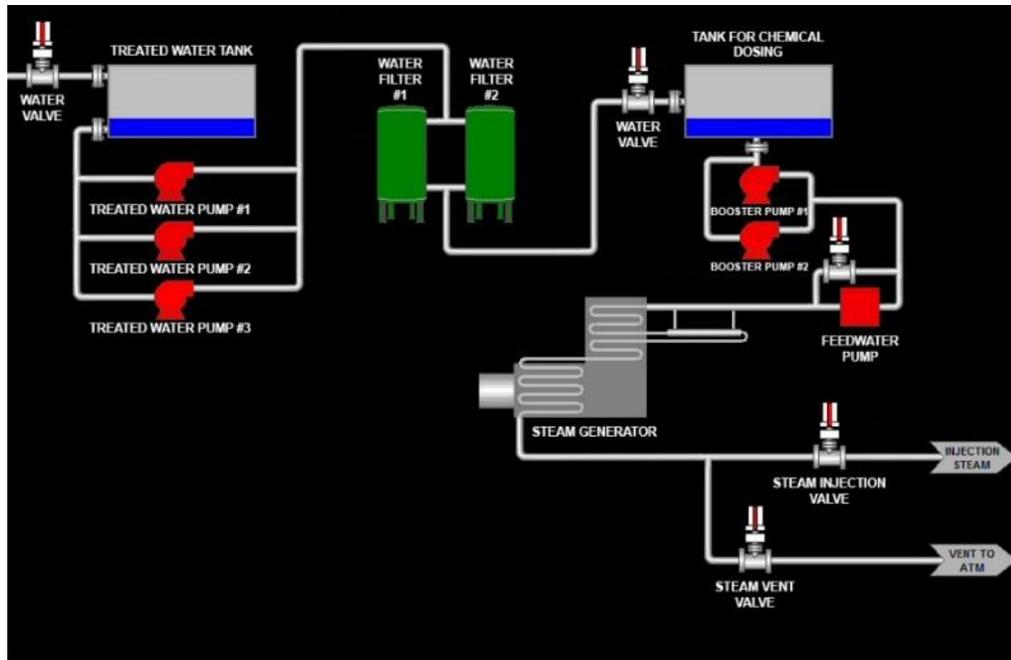
FASE I. Descripción del funcionamiento del control de combustión en unidades generadoras de vapor

Esta fase inicial de la investigación consistió en la definición de los elementos que componen el control de combustión de las unidades generadoras de vapor objeto de estudio y el rol de los mismos en el funcionamiento integral del sistema. Para esto se tomó en consideración la información de fuentes documentales tales como libros, manuales técnicos e investigaciones de terceros, en conjunto con la información recabada por medio de encuestas dirigidas a expertos en unidades generadoras de vapor. A continuación, se describen los principales elementos que conforman los sistemas de control de combustión de las unidades mencionadas y su posicionamiento dentro del proceso:

En su descripción más simple, el generador de vapor calienta el agua tratada de alimentación entrante a la calidad de vapor operativa requerida. Si se observa el diagrama de proceso mostrado en la figura 1, el proceso de generación de vapor inicia desde el sistema de tratamiento de agua, donde se bombea agua proveniente de un tanque de almacenamiento principal hasta el sistema de filtros de resina catiónica ácida fuerte diseñados para eliminar la dureza del agua de alimentación para prevenir la formación de incrustaciones dentro del sistema de tuberías de la caldera. Posteriormente el agua pasa de los filtros a un segundo tanque donde es

sometida a un tratamiento químico, añadiéndole secuestrante de oxígeno (generalmente bisulfito de sodio), para prevenir daños por picadura dentro de las tuberías del generador de vapor.

Figura 1 – Diagrama de proceso de planta de generación de vapor.



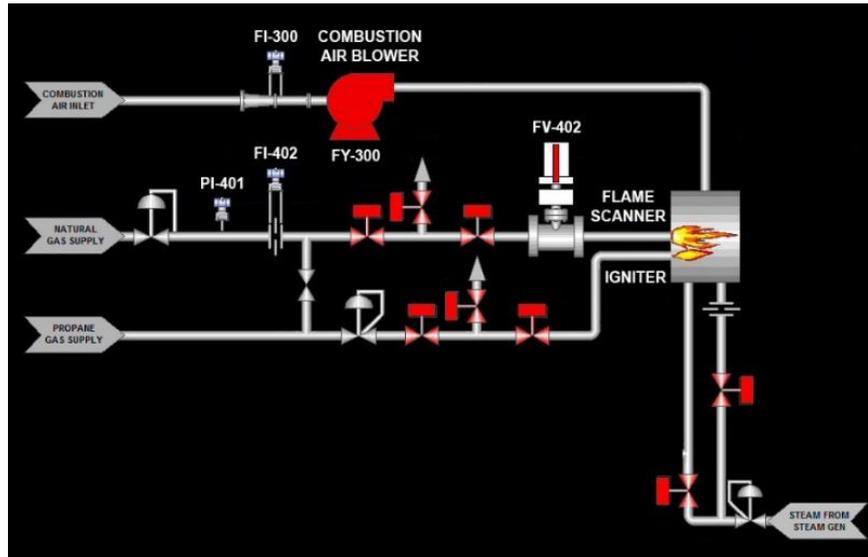
Fuente: Premier Energy (2015).

Una vez culminadas las labores de tratamiento de agua, el fluido ingresa al sistema de tuberías del sistema generador de vapor donde es calentado a presión y temperatura específicas, siendo este último parámetro controlado a través de la velocidad de disparo del quemador. Para el caso de los generadores de vapor empleados en los campos petroleros de la región zuliana, el PLC realiza un balance de calor del generador de vapor utilizando el caudal de agua de funcionamiento y la presión de vapor, el punto de ajuste de calidad de vapor deseado y la eficiencia de la caldera para determinar el flujo de combustible del quemador (gas natural) requerido.

La velocidad de disparo (flujo de combustible) luego se conecta en cascada a dos circuitos secundarios que controlan el gas combustible y el flujo de aire de combustión al quemador. Los dos bucles secundarios se limitan entre sí para mantener una relación segura de aire-combustible. En este módulo, el funcionamiento general de los equipos y parámetros del proceso críticos para el funcionamiento del quemador se dedican a un PLC del sistema de gestión del quemador (BMS) independiente. Por su parte, el aire de combustión al quemador es suministrado por el soplador (K-141), accionado por medio de un variador de frecuencia que rige la velocidad de giro del soplador. De esta manera, la velocidad

del soplador de aire de combustión (FY-300) se modula para controlar el flujo de aire al quemador (FI-300), tal y como se observa en la figura 2.

Figura 2 – Diagrama de proceso de sistema de quemador.



Fuente: Premier Energy (2015).

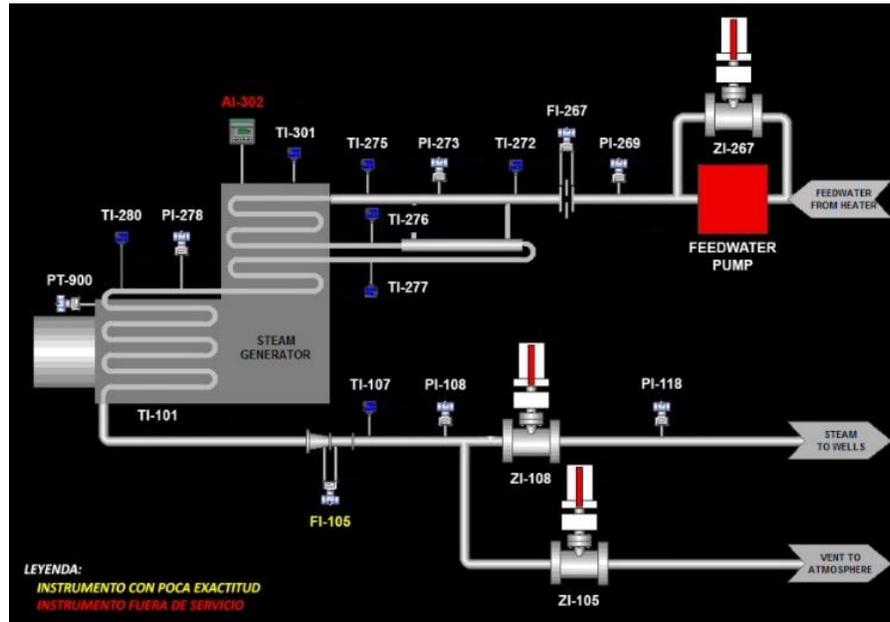
Dicho soplador también ejerce las labores del sistema de extracción de humos al proveer el tiro forzado que impulsará a los gases de combustión a través del horno y hasta la chimenea de salida del generador. En este punto de la chimenea, como se puede apreciar en la figura 3, se encuentra un sensor para monitoreo de la temperatura de salida de los gases de combustión (TI-301), así como un analizador de oxígeno de los gases de combustión (AI-302), ambos en la salida de gas de la sección de convección.

Generalmente, esta señal AI-302 se utiliza para ajustar el flujo de aire del quemador durante el funcionamiento con el fin de optimizar el exceso de aire para todas las cargas del quemador. Sin embargo, para el caso de los generadores de vapor que conforman la unidad de análisis de esta investigación, la señal AI-302 fue desconectada y puesta fuera de servicio por el personal de planta, debido a la falta de equipos para su mantenimiento/reemplazo. Naturalmente, esta decisión tiene consecuencias sobre las labores de cómputo del BMS, afectando negativamente su capacidad para determinar la demanda óptima de aire-combustible requerida por el sistema.

Para detallar sobre cómo afecta la omisión de esta variable a los cálculos que realiza el BMS, una curva de ajuste está preprogramada en la lógica de control para proporcionar un punto de ajuste flotante basado en la demanda de carga del quemador y el controlador de ajuste de oxígeno de los gases de combustión (AIC-302), buscando este último garantizar el exceso de aire de combustión aludido anteriormente para propiciar la quema óptima de todo el combustible que entra al

sistema. Dicha curva de combustión especifica los valores porcentuales de aire y gas combustible a la entrada del quemador para diferentes cargas.

Figura 3 – Diagrama de proceso de generador de vapor.



Fuente: Premier Energy (2015).

En este sentido, si el sistema trabajara con todos sus sensores operativos, el BMS ejecutaría el balance de energía del quemador en base a la curva de combustión programada en el equipo, y posteriormente se apoyaría con el controlador de ajuste de oxígeno de los gases de combustión (AIC-302) para optimizar la relación aire-combustible en base al análisis de la calidad de combustión que se obtiene del monitoreo de los gases de combustión a la salida de la chimenea. Sin embargo, debido a que el sensor AI-302 se encuentra fuera de servicio, esto genera imprecisiones en la determinación del punto de ajuste óptimo para adaptarse a las demandas del sistema cuando se encuentra en servicio, lo que se ve directamente reflejado en una menor calidad de la combustión y calidades finales de vapor fuera del rango óptimo de operación.

En esta misma línea de deficiencias por instrumentos del generador, y volviendo a la sección de tubería de agua que pasa por el proceso de transferencia de calor, la calidad del vapor a la salida del generador se controla continuamente mediante una boquilla de flujo (FE-105) que pasa a través de la tubería de vapor a la salida del generador, tal y como se muestra en la figura 3. Sin embargo, en la práctica este método de medición de calidad no ofrece una buena precisión debido a la naturaleza bifásica del fluido, por lo que también es necesario un monitoreo



regular de la calidad mediante ensayos químicos (titulación) para determinar el componente de agua en el vapor y garantizar que el generador de vapor esté funcionando correctamente.

Debido a esta poca fiabilidad del sistema de cálculo de calidad de vapor instalado en los generadores, esta medición en tiempo real no puede ser empleada para los cálculos del BMS de regulación de quema de combustible, por lo tanto, no existe realmente un circuito de control de retroalimentación de la calidad del vapor en los generadores de vapor. En cambio, el HMI tiene un factor de ajuste/corrección (bias) que debe ser ingresado manualmente por el operador para aumentar o disminuir la velocidad de disparo (quema de combustible), permitiendo corregir la relación de quema de combustible en los casos donde la calidad del vapor real medida por medio de ensayo químico sea diferente del punto de ajuste deseado/objetivo.

Por supuesto, todo esto tiene como consecuencia la necesidad de una constante interacción humana para: (1) realizar periódicamente pruebas químicas de calidad de vapor a la salida de los generadores, y (2) para ingresar manualmente al sistema de control el valor de corrección (bias) requerido para ajustar la velocidad de disparo del quemador y mantener a las unidades generadoras trabajando en un rango de calidad de vapor apropiado (alrededor de 75-85%); por supuesto, la efectividad de dicho ajuste manual solo puede ser validada por medio de una segunda prueba química de calidad, con lo que este ciclo de corrección y verificación puede llevarse a cabo más de una vez según lo requiera la unidad generadora de vapor.

Debido a estas carencias presentadas, los generadores de vapor a menudo sufren de varios inconvenientes asociados al funcionamiento de sus quemadores, como lo son: variaciones de la combustión, oscilaciones en la demanda de la caldera, ineficiencias operativas, estrés térmico, dificultades para alcanzar las calidades de vapor objetivo, necesidad de constante interacción humana y monitoreo, ineficiente estimulación térmica del crudo pesado de los pozos y menores tasas de producción de crudo.

Es este aspecto, y a final de cuentas, es posible adjudicar la presencia de dichas insuficiencias en la operación de los generadores de vapor a la incapacidad del control convencional de tomar decisiones ante la falta de realimentación de variables clave necesarias para: (1) garantizar una buena calidad de combustión durante la quema de combustible y (2) comprobar la calidad de vapor real exportada a los pozos de crudo extrapesados.

Todos estos factores justifican la necesidad de perfeccionamiento del sistema de control de combustión instalado en estas unidades generadoras de vapor, aplicando un modelo de control basado en redes neuronales artificiales que, apoyándose en los registros históricos del sistema mientras trabaja bajo condiciones óptimas, permita aumentar la autonomía de los equipos y su capacidad de respuesta ante variaciones en el sistema, garantizando el desempeño seguro y eficiente de las unidades.

FASE II. Selección de los parámetros operativos de la red neuronal

Con el objeto de garantizar el correcto funcionamiento del nuevo control de combustión a proponer, se realizó un análisis sobre todos los parámetros y variables que influyen dentro del proceso de generación de vapor, con la finalidad de definir cuáles son los más influyentes o son representativos para un desempeño óptimo de la combustión en las calderas. Para esta selección, se tomó como base la información recabada por medio de la revisión documental de diferentes libros, manuales de operación, artículos científicos y demás fuentes documentales disponibles al respecto de esta temática, y apoyándose en entrevistas no estructuradas a expertos en unidades generadoras de vapor generando un aporte en base a su experiencia.

En este contexto, la tabla 1 mostrada a continuación muestra el compendio de variables de entrada y salida que definirán la operación del control de combustión y serán determinantes para el entrenamiento de la red neuronal a implementar en el sistema:

Tabla 1 – Variables de proceso del control de combustión en generadores de vapor.

SISTEMA	PROCESO	
	VARIABLES DE ENTRADA	VARIABLES DE SALIDA
Generador de vapor	<ul style="list-style-type: none"> ▪ Presión de agua a la salida de la bomba de alimentación. ▪ Flujo de agua a la salida de la bomba de alimentación. ▪ Temperatura de agua a la entrada al economizador. 	
Quemador		<ul style="list-style-type: none"> ▪ Caudal de entrada de aire al quemador. ▪ Consumo de gas del quemador.

Fuente: Melean, F. (2022).

Del compendio de variables de proceso mostrado en la tabla 5, las variables de entrada seleccionadas fueron presión y flujo de agua a la salida de la bomba de alimentación, así como también la temperatura del agua a la entrada del economizador. Se escogieron deliberadamente estos parámetros de presión y flujo a la salida de la bomba de alimentación debido a que son los establecidos por el operador de planta a través del HMI de la unidad generadora de vapor para indicar la carga de trabajo, es decir, las toneladas de vapor (previamente agua) que serán inyectadas dentro de los pozos de crudo.

Es en base a esta cantidad de agua que deberá manejar la caldera, en conjunto con la temperatura inicial del fluido que se recibe por tubería desde fuera de la planta, que se determinarán más adelante del proceso el desempeño que



deber  tener el quemador, esto es, la cantidad de calor que deber  aportar el combustible quemado en el horno al fluido para que este alcance las temperaturas y presiones deseadas.

Como resultado de estos par metros iniciales, las variables de salida del proceso (y subsecuentemente de la red) se componen del caudal de entrada de aire al quemador y el consumo de gas del quemador, haciendo una clara paralela a los valores presentados en las curvas de combusti n de los generadores. Es decir, estos son los valores clave para la relaci n aire-combustible que deber  mantener el sistema de control de combusti n de la caldera para asegurar el  ptimo aprovechamiento del poder calor fico aportado por el combustible al ser quemado dentro del generador de vapor.

Adicionalmente, y debido a la naturaleza imprecisa del control de combusti n actualmente instalado en los generadores de vapor a partir de los cuales se realiz  el levantamiento de la data en campo para cada uno de los par metros mencionados y que ser n empleados en el desarrollo del nuevo modelo de control propuesto en este estudio, resulta imperante establecer los rangos operativos ideales para cada uno de estos par metros con el objeto de evitar alimentar al nuevo modelo de control con valores no optimizados o fuera del est ndar.

Para esto, se tom  como referencia los rangos de operaci n utilizados por una empresa de servicios de estimulaci n t rmica de pozos de crudo pesado de la regi n zuliana, la cual se tomar  como modelo de referencia a nivel datos operativos, dise o y simulaci n del comportamiento del sistema. En este contexto, la tabla 2 mostrada a continuaci n muestra los par metros y rangos de operaci n propuestos para el  ptimo desempe o del proceso de combusti n para la generaci n de vapor por calderas:

Tabla 2 – Rangos operativos para el filtrado de variables de proceso del control de combusti n en generadores de vapor.

PAR�METRO	UNIDAD	RANGO	
		M�NIMO	M�XIMO
Presi�n de agua a la salida de la bomba de alimentaci�n	psig	1300	1700
Flujo de agua a la salida de la bomba de alimentaci�n	t/h	9	11
Temperatura de agua a la entrada del economizador	�F	100	600
Temperatura de gases en la chimenea	�F	300	500
Temperatura de entrada a la zona radiante	�F	250	600
Temperatura a piel de tubo en zona radiante	�F	640	720
Presi�n de entrada en la zona radiante	psig	1350	1500



PAR��METRO	UNIDAD	RANGO	
		M��NIMO	M��XIMO
Temperatura del cabezal principal de vapor	��F	570	580
Presi��n del cabezal principal de vapor	psig	1200	1400
Presi��n de gas entrada al quemador	psig	12	16
Caudal de entrada de aire al quemador	m ³ /h	0	20000
Consumo de gas del quemador	kcf/h	10	30

Leyenda:

- **psig:** Libras por pulgada cuadrada.
- **t/h:** Toneladas por hora.
- **  F:** Grados Fahrenheit.
- **m³/h:** Metros c  bicos por hora.
- **kcf/h:** Kilopie cubico por hora.

Fuente: Melean, F. (2022).

A partir de los par  metros y rangos definidos en la tabla 2 mostrada anteriormente, se lleva a cabo un filtrado de la data de entrenamiento para el nuevo modelo de control de combusti  n a proponer. Como se puede observar, la tabla 2 contiene un mayor n  mero de par  metros que los listados previamente en la tabla 1 (resaltados en gris), esto de se debe a que, para poder emular el an  lisis termodin  mico realizado a la caldera por el control de combusti  n actualmente empleado en campo, es necesario tener conocimiento de la temperatura y presi  n del fluido mientras cambia de fase al recorrer el sistema de tuber  as del generador.

Los rangos de estos par  metros adicionales solo se aplican al filtrado de la data, mas no propiamente como data de entrenamiento para el nuevo sistema de control propuesto en esta investigaci  n, puesto que dichas presiones y temperaturas son funci  n/resultado del correcto desempe  o de la combusti  n definida por las variables de salida de la tabla 5, siendo meramente condiciones medidas que se presentan en la caldera una vez la relaci  n aire-combustible seleccionada es la apropiada para la cantidad de vapor a producir y no antes, por tanto, no pueden ser utilizadas como variables de entrada para el nuevo control propuesto y tampoco como variables de salida pues solo son controlables indirectamente.

Este filtrado permite que los datos recolectados en campo por medio del monitoreo de las unidades generadoras de vapor en servicio, sean refinados para dar cabida solo a aquellos par  metros que cumplan con las especificaciones de proceso recomendadas para el correcto desempe  o de estos equipos de caldera. En el contexto de estos datos, el compendio de par  metros operativos fue

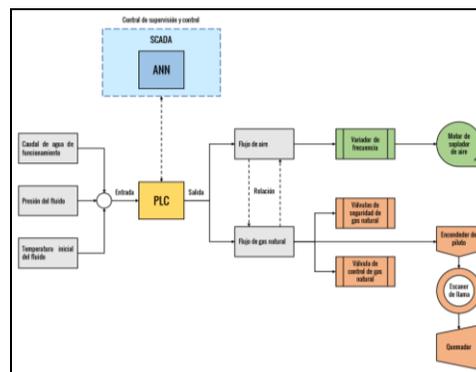
recolectado manualmente en campo por los operadores de generadores de vapor de la empresa de servicios de estimulación de pozos mencionada. Dicha data corresponde al periodo de agosto 2019 a junio del 2020, recolectada diariamente a lo largo de catorce (14) unidades de generación de vapor que se encontraban en servicio.

FASE III. Diseño del modelo de red neuronal artificial

En esta tercera fase se estructura la propuesta para el modelo de red neuronal artificial a desarrollar. Para esto es necesario en primera instancia llevar a cabo un análisis del ámbito de acción de la red neuronal, definiendo en que capas del proceso estará trabajando y sobre que gobernará. En este sentido, en el ámbito del nuevo modelo de control a proponer, la red neuronal artificial, entrenada con los datos de comportamiento de estos equipos generadores, emulará remotamente estos cálculos de balance de calor llevados a cabo dentro de la programación del PLC para determinar la relación aire-combustible requerida para conseguir una combustión óptima a partir del caudal de agua que se desea manejar, la presión del fluido y su temperatura de entrada al generador.

Para ello es necesaria la implementación de un sistema SCADA para la supervisión y control remoto de las unidades generadoras de vapor distribuidas en los campos de producción petrolera. En este sentido, la red neuronal artificial ejecutará sus operaciones de cómputo desde la infraestructura de ordenadores disponible en la central de control principal, que posteriormente enviará estas instrucciones de control al PLC del generador de vapor en campo, consiguiendo que este ejecute la configuración de aire y gas de combustión recomendada por el algoritmo de inteligencia artificial en base a la carga de vapor que se desee generar. De esta manera, el diagrama para control de combustión quedaría redefinido como se muestra en la figura 4.

Figura 4 – Diagrama de proceso de control de combustión con controlador por red neuronal artificial.



Fuente: Melean, F. (2022).

Adicionalmente, a razón de estos cambios en el control de combustión de los generadores de vapor, y para poder apreciar mejor el nivel de integración de la red neuronal propuesta, la tabla 3 mostrada a continuación contiene la pirámide de automatización del proceso, incluyendo las modificaciones específicas en su nivel 3 de supervisión para acomodar la implementación de la red neuronal artificial a través del sistema SCADA de control y supervisión de las unidades de generación de vapor.

Tabla 3 – Pirámide de automatización para proceso de control de combustión con controlador por red neuronal artificial.

5	GESTIÓN	N/A	
4	PLANIFICACIÓN	N/A	
3	SUPERVISIÓN	SCADA: Red neuronal artificial para control de combustión	
2	CONTROL	PLC: <ul style="list-style-type: none"> ▪ Rack 1: Controlador principal. ControlLogix 1756-L71 (Allen-Bradley). ▪ Rack 2: Remote I/O Rack. ControlLogix 1756-L71 (Allen-Bradley). BMS: <ul style="list-style-type: none"> ▪ Controlador CompactLogix 1768-L43S (Allen-Bradley). ▪ Módulos POINT I/O 1734 (Allen-Bradley). Terminal gráfica: PanelView Plus 1500 (Allen-Bradley). Conmutador: Switch ethernet (CISCO).	
1	CAMPO	Sensores de temperatura Sensores de presión Variador de frecuencia del soplador Soplador de aire Escáner de llama	Encendedor de piloto Quemador Válvulas de control Válvulas de seguridad

Fuente: Melean, F. (2022).

Con estas modificaciones al control planteado, se comienza a describir la arquitectura de red neuronal artificial que mejor se adapte a esta nueva estructura de control. Para esto, se hace uso de las matrices de análisis propuestas previamente en la metodología de la investigación, las cuales permiten realizar una comparativa directa entre los diversos algoritmos, diseños y estructuras para la constitución y el entrenamiento de la red neuronal a desarrollar, esto con el objeto de escoger y definir una arquitectura de red que cumpla con las necesidades del problema objeto de este estudio.



A partir de este análisis, se concluye que el tipo de red más conveniente para el problema objeto de estudio es la red de aprendizaje supervisado (backpropagation), puesto que se cuenta con un amplio compendio de data preclasificada que puede ser empleada para predecir el comportamiento del control de combustión en base a este histórico de atributos de los equipos generadores de vapor.

Seguidamente, se analiza la técnica de optimización que apoya al algoritmo de backpropagation para el proceso de entrenamiento de la red. De entre los algoritmos considerados, se selecciona el algoritmo de Adam (Adaptive Moment Estimation) puesto que puede soportar datasets y pesos más extensos a diferencia del algoritmo Levenberg-Marquardt, lo que lo vuelve el más adecuado puesto que se cuenta con una amplia cantidad de data de campo de los generadores de vapor. Al mismo tiempo, el algoritmo de Adam ofrece tiempos de entrenamiento mejores que el Scaled Conjugated Gradient y con un menor costo computacional, permitiendo trabajar con el desarrollo de arquitecturas de red en un menor tiempo.

Continuando con los tipos de arquitecturas a generar para la red neuronal, se determina que el modelo de red neuronal más conveniente son las redes multicapa puesto que el nivel de complejidad soportado y la data con la que pueden trabajar coinciden con los registros de variables recolectados para el comportamiento del control de los generadores de vapor que se busca emular por medio de red neuronal, permitiendo un entrenamiento de varios niveles de profundidad a partir de múltiples variables numéricas.

El último análisis consiste en comparar las funciones de activación disponibles para ser aplicadas sobre la estructura de la red neuronal artificial. Debido a la naturaleza del aprendizaje de redes neuronales artificiales, se opta por no seleccionar un único tipo de función de activación para el modelo de red desarrollado. En su lugar, se emplea una combinación de dos funciones de activación conformada en primer lugar por la función ReLU que es empleada en las neuronas de capa oculta de la red, previniendo de esta manera la aparición del problema de desvanecimiento de gradiente durante el entrenamiento, además de disminuir la carga computacional en estas capas las cuales contendrán la mayor cantidad de neuronas e iteraciones del proceso.

En segundo lugar, se hace uso de la función lineal en las neuronas de la capa de salida de la red, lo que facilita la regresión de dichas salidas al momento de aplicar el algoritmo de backpropagation para el entrenamiento de la arquitectura. Esta combinación de funciones de activación permite definir un modelo de aprendizaje más profundo, no tan demandante computacionalmente y que prevé la aparición el desvanecimiento de gradiente al ser entrenado.

FASE IV. Desarrollo del modelo de red neuronal artificial

Para la fase de desarrollo del modelo de red neuronal destinada al control de combustión de los generadores de vapor, se inicia con un tratamiento de la data histórica recolectada en campo por operadores de estas unidades generadoras en servicio. Como se mencionó anteriormente, esta data que servirá para el entrenamiento de la red neuronal fue reunida durante el periodo agosto 2019 a junio



de 2020, a través de monitoreo diario de 14 unidades de vapor ubicadas en la región zuliana. Estos monitoreos dieron como resultado un total de 2668 muestras de información que primero se pasan por un proceso de filtrado para garantizar que los parámetros operativos se encuentren dentro de los rangos de trabajo óptimos definidos previamente.

Aplicando este filtrado a la información de campo, la data de entrenamiento se reduce hasta un total de 426 muestras que cumplen con todos los rangos operativos para el funcionamiento óptimo de los generadores de vapor. Es decir, de las 2668 muestras tomadas entre agosto de 2019 y junio de 2020, los generadores de vapor solo se encontraron trabajando en el rango adecuado en un 16% de las instancias de muestreo, lo que denota el estado precario del control de combustión empleado actualmente en campo.

Habiendo refinado la data de entrenamiento para asegurar la calidad de la información con la que se entrenará la red neuronal artificial, seguidamente se hace uso del entorno de desarrollo Colaboratory, de la empresa Google, el cual provee un entorno de trabajo alojado en la nube para el desarrollo de código en Python, con librerías y utilidades específicas orientadas al modelado y entrenamiento de redes neuronales artificiales.

El primer paso para el modelado de la red neuronal consiste en importar todas aquellas librerías que serán utilizadas a lo largo del proceso de estructurado, entrenamiento y validación de la red. Para este proyecto se importan las librerías: Pandas, para análisis y manipulación de los datos; TensorFlow, para desarrollo y entrenamiento de modelos de redes neuronales artificiales; NumPy, para creación de vectores y matrices multidimensionales, y Matplotlib, para creación de gráficas y diagramado. Adicionalmente, se carga el dataset que incluye los valores de entrenamiento de la red en formato CSV compatible con Colaboratory y Python.

Seguidamente, buscando prevenir el sobreajuste de la red neuronal y garantizar la buena precisión de sus predicciones, se divide el dataset con los valores muestreados en tres categorías:

- Data de entrenamiento: Los valores que son presentados a la red durante su entrenamiento. Corresponde a aproximadamente el 65% de las muestras, o 272 muestras.
- Data de validación: Los valores usados para comprobar la capacidad de la red de generalizar. Corresponde a aproximadamente el 15% de las muestras, o 68 muestras.
- Data de prueba: Los valores que son usados para comprobar el desempeño de la red ya entrenada. Corresponde a aproximadamente el 20% de las muestras, u 86 muestras.

Posterior a este seccionamiento de la data, se procede a normalizar todos estos valores numéricos de la data de campo antes de ingresarla a la red neural; esto debido a que cada uno de los valores de entrada-salida de la red se presenta en una unidad diferente (psig, °F, t/h, m³/h, kcf/h, entre otros), por lo que es conveniente escalar las muestras para mejorar la estabilidad del proceso de aprendizaje y evitar que algún valor sesgue o afecte negativamente la predicción de otro.



Habiendo culminado con el normalizado, se describe la estructura de red neuronal a utilizar para el control de combusti n de las unidades generadas de vapor. En este sentido, tal y como fueron listadas en la tabla 1, la red contar  con tres (03) entradas y dos (02) salidas. Esto es, la capa de entrada estar  conformada por tres neuronas, correspondientes a la presi n, flujo y temperatura del agua de alimentaci n que se espera convertir en vapor; mientras que la capa de salida contar  con dos neuronas que corresponden al flujo de aire y flujo de gas que ingresan al quemador del generador de vapor. En este punto, la funci n de activaci n de ambas neuronas en la capa de salida corresponde a una funci n lineal, ideal para este tipo de entrenamiento de redes neuronales por regi n.

Por su parte, en el nivel de capa oculta, el dise o de dichas capas intermedias de la red se llev  a cabo mediante un proceso iterativo de prueba y error, en el que se experiment  con diferentes combinaciones de capas y n meros de neuronas hasta que se consigui  una estructura favorable que ofreciera un buen desempe o de la red. Esta combinaci n ganadora consiste en cinco (05) capas ocultas de diez (10) neuronas cada una, con una funci n de activaci n ReLU a la salida de dichas neuronas.

La figura 5 muestra el c digo de Python correspondiente a la definici n de este modelo de red neuronal dentro de la interfaz de Colaboratory, mientras que la figura 6 muestra una descripci n gr fica de la estructura de la red, sus neuronas y conexiones. Es importante se alar que, tal y como se aprecia en la imagen m s abajo, las dos neuronas de salida de la red reciben sus valores de entrada desde niveles diferentes de la capa oculta.

Espec ficamente hablando, la neurona encargada de la predicc n del flujo de gas recibe valores desde la cuarta (04) capa oculta de la red, mientras que la neurona responsable de predecir el flujo de aire toma sus valores de la quinta (05) capa oculta. La raz n detr s de esta decisi n de debe a que luego de agregar la cuarta capa oculta a la red, los valores predichos por la neurona de flujo de gas ya eran lo bastante buenos (como se evidenciar  m s adelante), por lo que agregar una quinta capa a esta neurona podr  hacerla propensa a sufrir de sobreajuste, lo que disminuir  sus capacidades para generalizar con nueva data. Por este motivo, la quinta capa fue agregada  nicamente para mejorar el desempe o de la neurona de flujo de aire.

Habiendo culminado con la definici n de la estructura de la red neuronal artificial, se ensambla el modelo de red propuesto dentro de Colaboratory. El algoritmo de optimizaci n utilizado para el entrenamiento de la red modelada es Adam, gracias a su eficiencia computacional y a los pocos requisitos de memoria, lo cual acelera su capacidad de ajuste de los pesos en la red neuronal artificial. En conjunto con este algoritmo, se selecciona una tasa de aprendizaje (η) de 0.001 y como l mite de iteraciones se considera un total de 300 pases/recorridos a trav s de la data de entrenamiento antes de dar por culminado dicho proceso de entrenamiento. Adicionalmente, se especifica un tama o de lote de 32 muestras por vez antes de actualizar los pesos del modelo, lo que garantiza una cantidad de muestras que sea lo suficientemente representativa del total de puntos en el dataset empleado.

Figura 5 – Modelado de red neuronal artificial en Python.

```
[ ] # Definiendo funcion para modelado de la red neuronal

def build_model():
    # Definiendo capa de entrada
    input_layer = Input(shape=(len(train.columns),))

    # Definiendo capas ocultas
    layer1 = Dense(units='10', activation='relu')(input_layer)
    layer2 = Dense(units='10', activation='relu')(layer1)
    layer3 = Dense(units='10', activation='relu')(layer2)
    layer4 = Dense(units='10', activation='relu')(layer3)
    layer5 = Dense(units='10', activation='relu')(layer4)

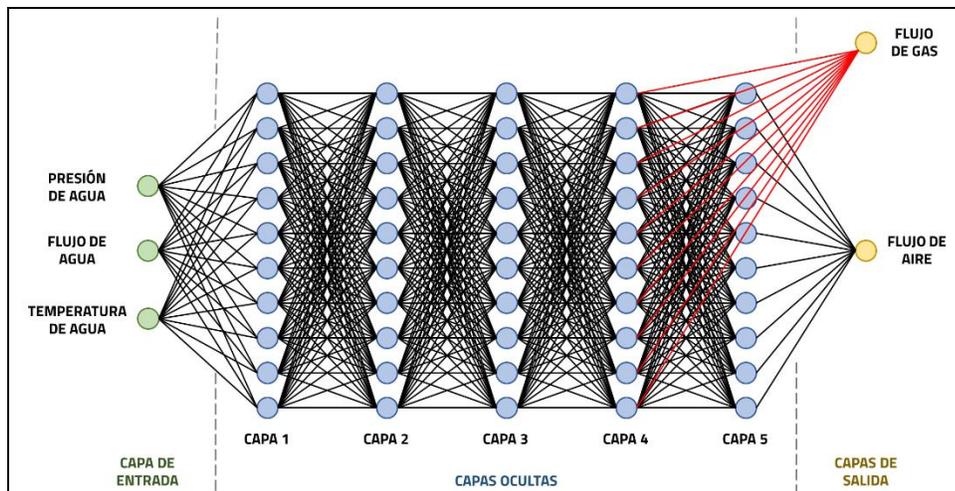
    # Definiendo capa de salida
    # Neuronas de salida Y1 corresponde a FLUJOGAS
    y1_output = Dense(units='1', name='flujogas_output')(layer4)
    # Neuronas de salida Y2 corresponde a FLUJOAIRE
    y2_output = Dense(units='1', name='flujoaire_output')(layer5)

    # Definiendo el modelo identificando su capa de entrada y capa(s) de salida
    model = Model(inputs=input_layer, outputs=[y1_output, y2_output])

    return model
```

Fuente: Melean, F. (2022).

Figura 6 – Diagrama de estructura para red neuronal artificial.



Fuente: Melean, F. (2022).

Terminado el entrenamiento, se obtienen los valores de pérdidas/desviaciones y el error cuadrático medio para las predicciones de ambos valores: flujo de aire y flujo de gas. Estos valores se pueden comprobar en la tabla 4 mostrada a continuación:

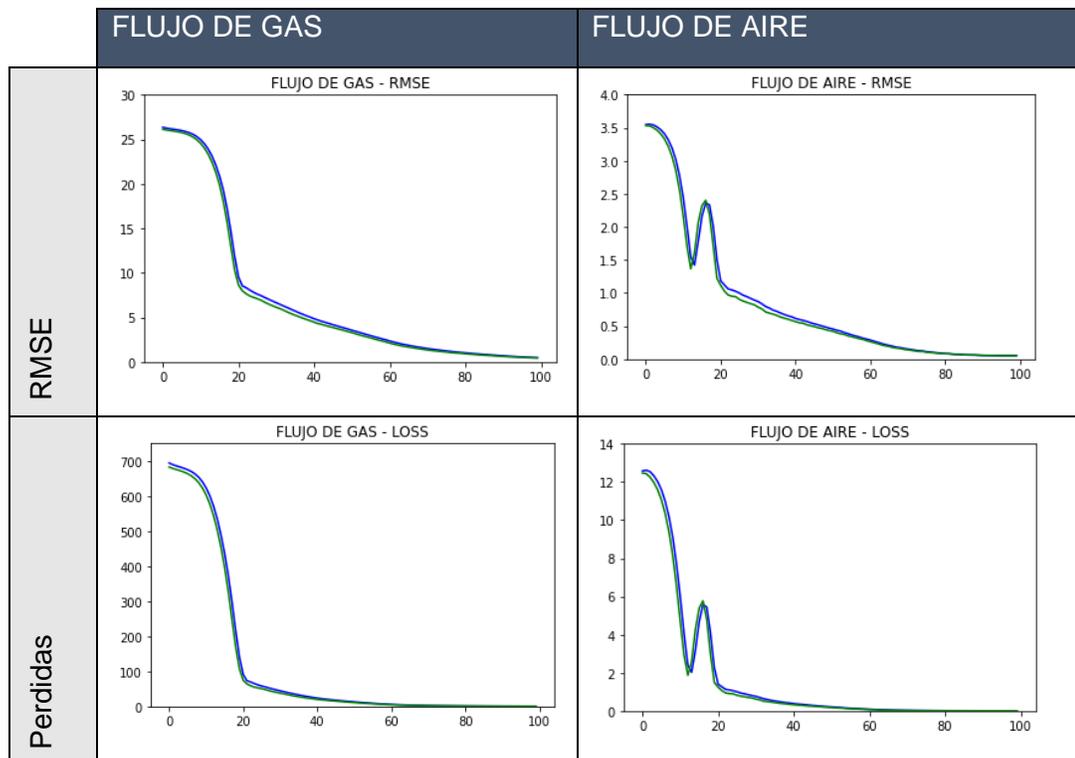
Tabla 4 – Valores de pérdidas y error cuadrático medio de predicciones de la red neuronal artificial entrenada.

	RMSE	Perdidas
Flujo de gas	0.4927	0.2428
Flujo de aire	0.0541	0.0029
		0.2427

Fuente: Melean, F. (2022).

Tal y como se observa en la tabla 4, los valores para error cuadrático medio (RMSE) de las predicciones son de apenas 0.4927 y 0.0541, para los valores de flujo de gas combustible y caudal de aire respectivamente arrojados por la red. Por su parte, las pérdidas/desviaciones totales de la red neuronal están en apenas 0.2427; esto significa que la red ha logrado aprender exitosamente de la data de entrenamiento y la diferencia entre los valores predichos por la red y la data de validación es muy baja, lo que denota una buena precisión para la red entrenada. Las gráficas mostradas a continuación, agrupadas en la tabla 5, muestran el proceso de aprendizaje de la red para cada iteración y como los valores de RMSE y pérdidas fueron disminuyendo con forme la red aprende y ajusta sus valores de pesos.

Tabla 5 – Graficas de progreso de aprendizaje de la red neuronal artificial.



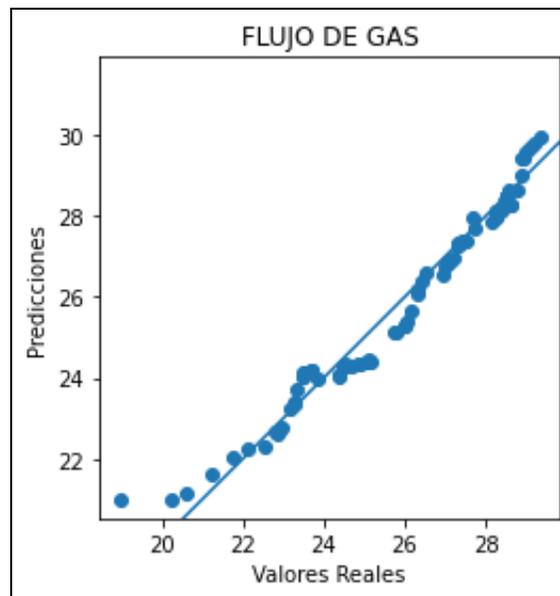
Leyenda:

- Azul: Desempeño a partir de la data de entrenamiento.
- Verde: Desempeño a partir de la data de validación.

Fuente: Melean, F. (2022).

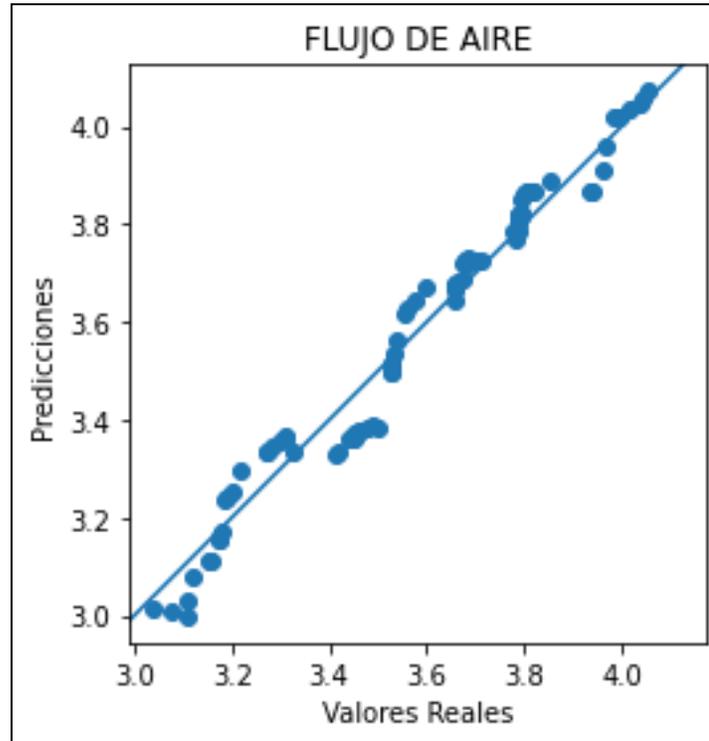
Para culminar, se evalúa la capacidad de generalización de la red al exponerla por primera vez a la data de prueba, esto con el objeto de garantizar que la red no sufra de sobreajuste que le impida trabajar con datos diferentes de los del conjunto de entrenamiento original. La figura 7 y figura 8 muestran la diferencia entre los valores reales y las predicciones realizadas por la red neuronal artificial entrenada para los parámetros de salida flujo de gas combustible y flujo de aire respectivamente.

Figura 7 – Gráfico de valores reales vs. predicciones de flujo de gas combustible de la red neuronal artificial entrenada.



Fuente: Melean, F. (2022).

Figura 8 – Gráfico de valores reales vs. predicciones de flujo de aire de combustión de la red neuronal artificial entrenada.



Fuente: Melean, F. (2022).

A manera de resumen, la tabla 6 mostrada a continuación lista las características principales de la red neuronal artificial propuesta anteriormente:

Tabla 6 – Resumen de características de la red neuronal artificial desarrollada.

ESTRUCTURA DE RED NEURONAL			
CAPAS		NUMERO DE NEURONAS	FUNCIÓN DE ACTIVACIÓN
Capa de entrada		3	N/A
Capa oculta	Capa 1	10	ReLU
	Capa 2	10	ReLU
	Capa 3	10	ReLU
	Capa 4	10	ReLU
	Capa 5	10	ReLU
Capa de salida		2	Lineal
ENTRENAMIENTO DE RED NEURONAL			
Algoritmo de entrenamiento		Adam	
Tasa de aprendizaje		0.001	
Límite de iteraciones (Epochs)		300	



Tama�o de lote	32	
DISTRIBUCI�N DE DATA		
TIPO DE DATA	CANTIDAD DE MUESTRAS	PORCENTAJE DE MUESTRAS
Entrenamiento	272	65%
Validaci�n	68	15%
Prueba	86	20%
	426	100%

Fuente: Melean, F. (2022).

FASE V. Implementaci n del control por red neuronal artificial

Para la implementaci n de la red neuronal artificial para el control de combusti n en unidades generadores de vapor, se guarda el modelo de red construido, entrenado y validado en un archivo formato TensorFlow, esto con el objeto de mantener a disposici n los nuevos pesos de la red optimizados durante el entrenamiento. El archivo en cuesti n puede ser ejecutado desde cualquier entorno Python, tomando en cuenta que las librer as correspondientes a TensorFlow deben de ser importadas previamente a dicho entorno.

Habiendo cargado el modelo, este es capaz de predecir los valores para caudal de aire de combusti n y consumo de gas del quemador a partir de los valores de presi n, caudal y temperatura de agua de alimentaci n que se requiere convertir en vapor. Es importante se alar adem s que, dichos valores de entrada deben de ser normalizados, siguiendo la misma funci n de escalamiento de la data que se llev  a cabo al momento de entrenar la red neuronal originalmente.

Con esto en mente, es posible llevar a cabo una comparaci n directa entre los m todos para la determinaci n de la relaci n aire-combustible requerida por el generador de vapor, y que fueron discutidos a lo largo de este proyecto de investigaci n; estos son: (a) curva de combusti n, (b) comportamiento real del quemador cuando este es manipulado por los operadores en campo, y (c) los nuevos valores proporcionados por la red neuronal artificial generada. Para ello, se ingresa a la red una serie de valores de entrada tomados directamente en campo con los equipos trabajando a diferentes cargas de generaci n de vapor.

Los resultados arrojados por el modelo de red neuronal para la relaci n aire-combustible pueden ser apreciados en la tabla 7, en donde se comparan directamente con los resultados reales de los equipos en campo, haciendo posible calcular el porcentaje de error entre los par metros de salida reales y los par metros predichos por la red neuronal artificial. Como se puede observar, para la predicci n del caudal de aire de combusti n, la red presenta un error m ximo de apenas 3.9% y un promedio global de 1.1%. Por su parte para la estimaci n del flujo de gas combustible, el error m ximo presentado fue de 2.6% y un promedio global 0.6% de desviaci n, lo que denota un muy buen ajuste de la red hacia los

parámetros reales descritos por el control de combustión con ajuste manual de los operadores en campo.

Tabla 7 – Porcentaje de error en predicciones aire-combustible.

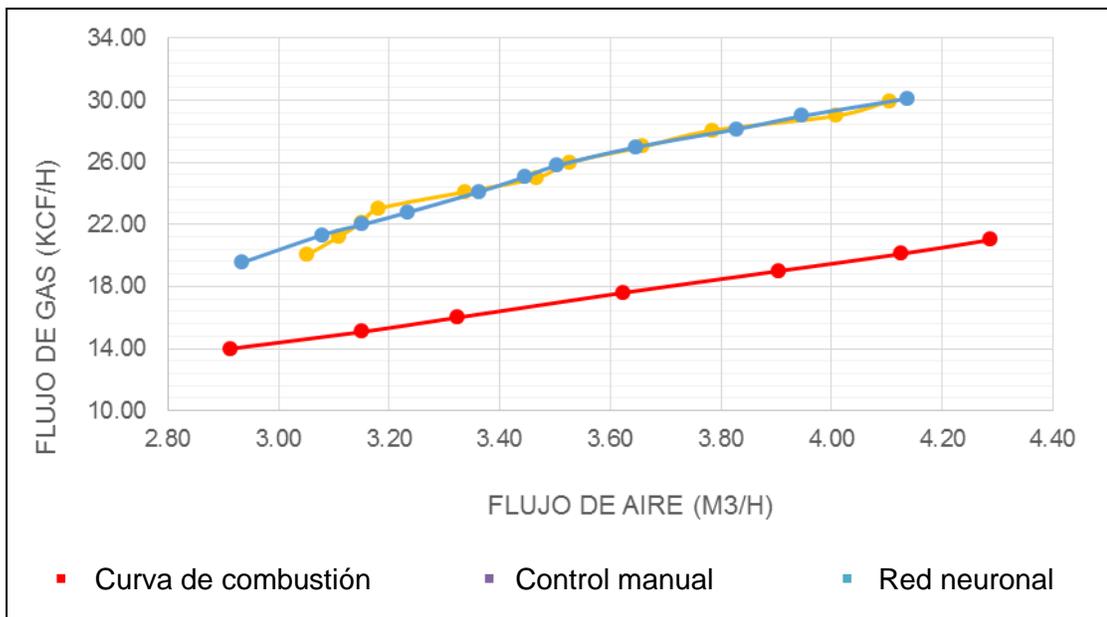
FLUJO DE AIRE (m ³ /h)			FLUJO DE GAS (kcf/h)		
Cam po	ANN	% Err or	Cam po	ANN	% Err or
3.0528	2.9332	3.9%	20.06	19.53	2.6%
3.1103	3.0792	1.0%	21.23	21.32	0.4%
3.1500	3.1508	0.0%	22.14	21.98	0.7%
3.1811	3.2346	1.7%	23.02	22.79	1.0%
3.3369	3.3622	0.8%	24.10	24.10	0.0%
3.4667	3.4467	0.6%	25.00	25.08	0.3%
3.5269	3.5024	0.7%	26.00	25.79	0.8%
3.6578	3.6461	0.3%	27.00	26.98	0.1%
3.7847	3.8280	1.1%	28.06	28.14	0.3%
4.0083	3.9461	1.6%	29.00	28.98	0.1%
4.1044	4.1377	0.8%	29.95	30.12	0.6%
% Error promedio		1.1%	% Error promedio		0.6%

Fuente: Melean, F. (2022).

En conjunto con esto, y para poder apreciar de una manera más intuitiva el nivel de aprendizaje del control propuesto, la figura 9 muestra un gráfico de comportamiento de la relación aire-combustible para ambos entornos, los valores reales de campo producto del control manual y los valores calculados por la red neuronal, que aparecen en la tabla 7. A la gráfica se ha adicionado además la conducta de la relación aire-combustible que provee la curva de combustión del control de combustión convencional de los generadores de vapor.

De esta última grafica es posible concluir como la red neuronal artificial es capaz de describir un comportamiento muy similar al del control manual realizado por los operadores en campo. Esto es el resultado deseado puesto que como se mencionó anteriormente en la fase I, el control convencional por medio de curva de combustión instalado originalmente en las unidades generadoras de vapor posee varias deficiencias que disminuyen significativamente su efectividad, afectando directamente el rendimiento de la combustión en los generadores de vapor, por lo que los operadores en campo se ven en la obligación de manipular manualmente el control de combustión de las unidades para garantizar las condiciones de vapor objetivo para la correcta estimulación de los pozos petroleros.

Figura 9 – Comportamiento de relación aire-combustible obtenida a partir de: a) curva de combustión, b) control manual en campo y c) control por red neuronal.



Fuente: Melean, F. (2022).

En este sentido, si anteriormente era necesario que los operadores en campo trasladaran de manera empírica el punto de ajuste de combustión desde aquel señalado por la curva de combustión del control convencional (línea roja) hasta el punto óptimo requerido en campo (línea amarilla), la red neuronal es ahora capaz de determinar de manera independiente estos puntos de ajuste de combustión optimizados (línea azul), ofreciendo al sistema la relación aire-combustible que satisfaga los requisitos de generación de vapor acorde con los estándares operativos y de seguridad de la organización, efectivamente emulando la acción de los operadores en campo, eliminando la dependencia de los mismos y mejorando la autonomía del sistema.



CONCLUSIONES

Considerando los resultados obtenidos del análisis de la información recolectada durante la investigación, se presentan las siguientes conclusiones:

Por medio de la definición del funcionamiento del control de combustión convencionalmente instalado en las unidades generadores de vapor, se logró definir aquellos factores operativos y de diseño que afectan negativamente al proceso de combustión de los equipos. En este sentido, se provee un análisis sobre la influencia de componentes como medidores de flujo para calidad de vapor y sensores de oxígeno para los gases de combustión, que no son lo suficientemente confiables o que simplemente se encuentran fuera de servicio, permitiendo definir limitantes y oportunidades de mejora en el sistema.

En adición a esto, del estudio del funcionamiento del control de combustión convencional también se deriva un diagrama del proceso de control, en base al cual se categorizó de manera visual e intuitiva los principales parámetros operativos, factores y componentes en interacción responsables del control del quemador de los generadores de vapor. Mas allá de esto, en base a las oportunidades de mejora mencionadas anteriormente, fue posible proponer un nuevo diagrama de proceso con control basado en redes neuronales artificiales, permitiendo solventar gran cantidad de las deficiencias iniciales del sistema mediante dicha implementación de aprendizaje profundo.

En este sentido, para la concepción del nuevo sistema de control basado en redes neuronales artificiales, se presentó un análisis comparativo de los principales modelos de construcción de redes neuronales, tomando en consideración la naturaleza del control a emular a través de la red, número y características de entradas y salidas del sistema, algoritmos de aprendizaje y funciones de activación mejor adaptados al entorno, entre otros factores de interés.

Como resultado de este análisis, fue posible presentar un modelo de red neural artificial multicapa, con una (01) capa de entrada, conformada por 3 neuronas correspondientes a los parámetros iniciales de presión, flujo y temperatura del agua de alimentación a ser convertida en vapor; cinco (05) capas ocultas de 10 neuronas cada una con función de activación ReLU, y dos (02) capas de salida con función de activación lineal, una para cada neurona o parámetro de salida a calcular mediante la red: caudal de aire y consumo de gas combustible del quemador. El entrenamiento de la red se llevó a cabo a través del algoritmo de backpropagation por el método del optimizador de Adam, empleando un aprendizaje supervisado a partir de un conjunto de 426 muestras recolectadas en campo.

Las pruebas de implementación realizadas a la red neuronal modelada permiten concluir que la misma es capaz de predecir los parámetros de salida de interés para el control de combustión con muy buena precisión. Específicamente hablando, para la predicción del caudal de aire de combustión, la red describe un error máximo de apenas 3.9% y un promedio global de 1.1%. Por su parte para la estimación del flujo de gas combustible, el error máximo presentado fue de 2.6% y un promedio global 0.6% de desviación.



Con estos resultados, se evidencia el alto nivel de aprendizaje obtenido en base a la data de campo, con lo que la red neuronal artificial desarrollada es ahora capaz de emular la acción de los operadores humanos. Dentro de este contexto, la implementación de este control tiene entonces la capacidad de garantizar la determinación del punto de ajuste óptimo para la relación aire-combustible de los generadores para diferentes cargas de producción de vapor, eliminando la necesidad de interacción humana para el ajuste de la curva de combustión del control convencional, garantizando temperaturas de operación y calidades de vapor dentro del estándar de seguridad y eficiencia de servicio de producción de los generadores de vapor.

REFERENCIAS BIBLIOGRÁFICAS

- Aggarwal, C. (2018). *Neural Networks and Deep Learning*. Springer International Publishing AG. Cham, Suiza.
- Arias, F. (2012). *El Proyecto de Investigación: Introducción a la metodología científica*. Sexta edición. Editorial Episteme, C.A. Caracas, Venezuela.
- Berzal, F. (2018). *Redes Neuronales & Deep Learning*. Fernando Berzal. Granada.
- Consultoría ITC (23 de mayo de 2020). *Manual de operación y mantenimiento de calderas de vapor*. Industrial Tijuana. Recuperado de: <http://www.industrialtijuana.com/infotecnica.htm>
- Hurtado, J. (2012). *Metodología de la investigación: Guía para una comprensión holística de la ciencia*. Cuarta edición. Ediciones Quirón S.A. Caracas, Venezuela.
- Jurado, F., Albusac, J., Castro, J., Vallejo, D., Jimenez, L., Villanueva, F., Villa, D., Gonzalez, C. y Simmross, G. (2012). *Desarrollo de Videojuegos Volumen 4: Desarrollo de componentes*. Edición Revisada. Universidad de Castilla-La Mancha. Albacete, España.
- Lammers, H., Lammers, T. y Woodruff, E. (2004). *Steam Plant Operation*. Octava edición. McGraw-Hill. New York, Estados Unidos.
- Mariño, S. y Primorac, C. (2016). *Propuesta metodológica para desarrollo de modelos de redes neuronales artificiales supervisadas*. *International Journal of Educational Research and Innovation (IJERI)*. España.
- Palella, S. y Martins, F. (2012). *Metodología de la Investigación Cuantitativa*. Tercera edición. Fondo Editorial de la Universidad Pedagógica Experimental Libertador. Caracas, Venezuela.
- Pimienta, J. y De la Orden, A. (2017). *Metodología de la Investigación*. Tercera edición. Pearson Educación de México, S.A. de C.V. Ciudad de México, México.



Premier Energy (2015). Operating Manual: Premier Energy Model PE-2025™ Enhanced Oil Recovery System. Premier Energy. Georgia, Estados Unidos.

Schlumberger Limited (22 de abril de 2020). Oilfield Glossary. Schlumberger Limited. Recuperado de: <http://www.glossary.oilfield.slb.com/>