



FACULTAD DE METALURGIA Y ELECTROMECAÁNICA
CENTRO DE ESTUDIOS DE ENERGÍA Y TECNOLOGÍA AVANZADA DE MOA

**MODELACIÓN MATEMÁTICA DEL SUBPROCESO DE POSTCOMBUSTIÓN EN UN
HORNO DE REDUCCIÓN DE MINERALES LATERÍTICOS**

Tesis presentada en opción al grado científico de Doctor en Ciencias Técnicas

DEYNIER MONTERO GÓNGORA

Moa, Holguín

2023



FACULTAD DE METALURGIA Y ELECTROMECAÁNICA
CENTRO DE ESTUDIOS DE ENERGÍA Y TECNOLOGÍA AVANZADA DE MOA

**MODELACIÓN MATEMÁTICA DEL SUBPROCESO DE POSTCOMBUSTIÓN EN UN
HORNO DE REDUCCIÓN DE MINERALES LATERÍTICOS**

Tesis presentada en opción al grado científico de Doctor en Ciencias Técnicas

Autor: Prof. Asis., Ing. Deynier Montero Góngora, M. Sc.

Tutores: Prof. Tit., Ing. Ángel Oscar Columbié Navarro, Dr. C.

Prof. Tit., Lic. Rafael Arturo Trujillo Codorníu, Dr. C.

Prof. Tit., Ing. Reineris Montero Laurencio, Dr. C.

Moa, Holguín

2023

PENSAMIENTO

*He aquí que el temor del Señor es la sabiduría,
Y el apartarse del mal, la inteligencia.*

Job 28:28

AGRADECIMIENTOS

Muy especial a ese que todo lo puede (Dios), quien me ilumina continuamente para seguir adelante.

A mi esposa e hijo por ser fuentes de inspiración.

A mis padres por sus excelentes y oportunos consejos.

A mi hermano de la fe José Antonio Poutriel por estar siempre pendiente a los detalles de la investigación y su constante apoyo.

A mis tutores por su preocupación y dedicación constantes.

A los profesores del CEETAM y del doctorado de Electromecánica, que contribuyeron con mi formación profesional.

A los profesores Cecilia Pérez Roque, José Ignacio Hernández López, Aliet Lamorú Reyes, Josefa Mestre Lamorú, y Luis Vázquez Seisdedos, por sus valiosas contribuciones.

A los compañeros de la Empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara” que me facilitaron el acceso a la información y el desarrollo de la componente experimental.

A los directivos del proyecto VLIR que me proporcionaron la estancia de investigación en la Universidad Católica de Leuven de Bélgica, para lograr publicar el artículo del grupo I.

A las personas nombradas en estas páginas y a quienes involuntariamente no he recordado.

A todos, mi eterno agradecimiento.

SÍNTESIS

La Empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara” desempeña un rol esencial en el desarrollo económico de Cuba. Dentro del proceso productivo de la industria, el horno de reducción de minerales lateríticos es una etapa clave y requiere un alto consumo de *fuel oil*, que representa alrededor del 40 % del costo unitario por tonelada producida de níquel más cobalto, y resulta vital reducir tales costos. La implementación del sistema de control automático en la postcombustión se ha visto afectada por la inexistencia de modelos matemáticos de este proceso. En la presente investigación se proponen modelos lineales para diferentes puntos de operación y modelos no lineales basados en Redes Neuronales Artificiales (RNA) que reflejan las características dinámicas del proceso. La metodología consta de la realización de experimentos activos, con secuencias binarias pseudoaleatorias moduladas en amplitud y frecuencia e insertadas en el autómatas que acciona las válvulas reguladoras de flujo de aire y variaciones en el flujo de mineral alimentado al horno, para obtener los modelos lineales. Se realizaron experimentos pasivos de 10 meses de operaciones para la obtención de dos modelos RNA (simple entrada-simple salida (SISO) y múltiples entradas-múltiples salidas (MIMO)). El modelo RNA MIMO se evaluó con diferente número de neuronas en la capa oculta y con el empleo del método de validación cruzada aleatoria, escogiéndose el mejor modelo a partir de los criterios de información de Akaike y Bayesiano. Como resultado, el modelo predice las temperaturas de los hogares cuatro y seis del horno con un error inferior a 5 °C, y un horizonte de predicción de un paso adelante (120 s). Los modelos contribuyen a predecir el perfil térmico en la zona de calentamiento del horno, como base para el diseño de estrategias de control que garanticen un mejor aprovechamiento de la energía y del combustible aditivo reductor, para disminuir las pérdidas del proceso y la contaminación ambiental.

NOMENCLATURA

6N-14N	Cámara de combustión (Hogar seis hasta Hogar 14) de la zona norte
6S-14S	Cámara de combustión (Hogar seis hasta Hogar 14) de la zona sur
H	Hogar del horno
Fp	Flujo de petróleo suministrado a las cámaras de combustión (kg/t)
Fm	Flujo de mineral alimentado al horno (t/h)
FaH4, FaH6	Flujo de aire a los hogares cuatro y seis (%)
ApH4, ApH6	Apertura de válvula reguladora de flujo de aire a los hogares cuatro y seis (%)
TH0, TH2, TH4, TH6, TH7, TH9, TH11, TH13, TH14, TH15	Temperatura de los hogares cero, dos, cuatro, seis, siete, nueve, 11, 13, 14 y 15, respectivamente (°C)
PH0, PH16	Presión en los hogares cero y 16 (mm de H ₂ O)
TC6S, TC8N, TC8S, TC10N, TC10S, TC12N, TC12S, TC15S	Temperatura de la cámara de combustión en los hogares seis, ocho, 10, 12 y 15; zonas norte y sur (°C)
SISO	Simple entrada-simple salida
MIMO	Múltiples entradas-múltiples salidas
SBPA	Secuencia binaria pseudoaleatoria
APRBS	Secuencia binaria pseudoaleatoria de amplitud modulada
PLC	Controlador lógico programable
SCADA	Sistema de supervisión, control y adquisición de datos
BJ	Modelo Box-Jenkins
OE	Modelo Error de salida
ARX	Modelo Autorregresivo con entradas exógenas
ARMAX	Modelo de media móvil autorregresiva con entradas exógenas
RNA	Redes neuronales artificiales
NARX	Estructura no lineal autorregresiva con entradas externas
MSE	Error cuadrático medio
RMSE	Raíz del error cuadrático medio

TABLA DE CONTENIDO

	Pág.
INTRODUCCIÓN.....	1
1. ESTADO DEL ARTE DE LA MODELACIÓN MATEMÁTICA EN HORNOS DE REDUCCIÓN DE MINERALES LATERÍTICOS.....	9
1.1. Modelos matemáticos de procesos industriales.....	9
1.2. Particularidades del proceso de reducción de minerales lateríticos en hornos.....	11
1.2.1. Estudios de automatización en el proceso de reducción de níquel.....	13
1.3. Aspectos sobre la identificación de sistemas.....	15
1.3.1. Modelos paramétricos empleados en sistemas industriales.....	16
1.4. Generalidades de las redes neuronales artificiales	17
1.4.1. Identificación de sistemas con redes neuronales dinámicas.....	20
1.4.2. Redes neuronales artificiales aplicadas en la metalurgia.....	21
Conclusiones parciales	23
2. MATERIALES Y MÉTODOS PARA LA MODELACIÓN MATEMÁTICA DEL SUBPROCESO DE POSTCOMBUSTIÓN.....	25

2.1.	Descripción del proceso de reducción de níquel en el horno objeto de estudio	25
2.1.1.	Descripción del subproceso de postcombustión.....	28
2.1.2.	Descripción de la instalación para la postcombustión.....	29
2.1.3.	Estado actual de la automatización del subproceso de postcombustión.....	31
2.2.	Metodología general para la modelación del subproceso de postcombustión.....	33
2.2.1.	Obtención de los modelos lineales del proceso	34
2.2.2.	Obtención de los modelos no lineales del proceso	35
2.3.	Diseño del experimento de identificación	37
2.3.1.	Diseño del experimento con SBPA para la obtención de modelos lineales	39
2.3.2.	Diseño del experimento con APRBS para la obtención de modelos lineales	40
2.3.3.	Implementación de las señales binarias en el sistema de supervisión y control.....	41
2.4.	Métodos de identificación de sistemas	43
2.4.1.	Método de Mínimos Cuadrados	43
2.5.	Modelo lineal general	45
2.6.	Modelación con redes neuronales artificiales.....	46
2.6.1.	Teoría de los modelos NARX	47
2.7.	Método de validación cruzada aleatoria con retención repetida.....	49
2.8.	Criterios de evaluación de modelos de predicción	50
2.9.	Diseño del experimento para la obtención del modelo NARX SISO.....	51
2.10.	Diseño del experimento para la obtención del modelo NARX MIMO	53
	Conclusiones parciales	55
3.	MODELACIÓN MATEMÁTICA DEL SUBPROCESO DE POSTCOMBUSTIÓN DEL HORNO DE REDUCCIÓN DE MINERALES LATERÍTICOS	56
3.1.	Análisis estadístico de los datos	56
3.2.	Análisis con series de tiempo descriptivas	58

3.3.	Experimentos previos con entrada escalón.....	59
3.4.	Modelos lineales obtenidos con el empleo de SBPA	61
3.4.1.	Modelos de TH4 y TH6 versus ApH4.....	62
3.4.2.	Modelos de TH4 y TH6 versus ApH6.....	65
3.4.3.	Modelos de TH4 y TH6 versus Fm	68
3.4.4.	Modelos lineales obtenidos con el empleo de APRBS.....	70
3.5.	Modelo RNA SISO.....	74
3.6.	Modelo RNA MIMO	75
3.7.	Implementación de las redes neuronales artificiales	78
3.8.	Valoración económica	80
3.9.	Impacto tecnológico	84
3.10.	Impacto medioambiental	84
3.11.	Impacto social.....	85
	Conclusiones parciales	85
	CONCLUSIONES.....	87
	RECOMENDACIONES	88
	REFERENCIAS BIBLIOGRÁFICAS	89
1.	VISTA LATERAL DERECHA DE LA UNIDAD BÁSICA DE PRODUCCIÓN PLANTA HORNOS DE REDUCCIÓN	I
2.	SISTEMA DE SUPERVISIÓN Y CONTROL DE UNA LÍNEA DE HORNOS	II
3.	INSTRUMENTACIÓN VINCULADA AL SUBPROCESO DE POSTCOMBUSTIÓN	III
4.	CARACTERÍSTICAS DE LAS MATERIAS PRIMAS DURANTE LA REALIZACIÓN DE EXPERIMENTOS ACTIVOS.	VIII
5.	ANÁLISIS ESTADÍSTICO DESCRIPTIVO DEL PERFIL TÉRMICO DEL HORNO EN 2015.....	IX

6. VISTA EN EL CITECT DE LOS EXPERIMENTOS 1 Y 2 CON SEÑALES BINARIAS PSEUDOALEATORIAS.	XIII
7. TOOLBOX DE IDENTIFICACIÓN DEL MATLAB®.....	XIV
8. CÓDIGO PARA EL MODELO NARX UTILIZANDO EL TOOLBOX “NNSYSD” DE MATLAB®.	XV
9. CÓDIGO PARA EL MODELO NARX UTILIZANDO “DEEP LEARNING TOOLBOX” DE MATLAB®	XVII
10. PRODUCCIÓN CIENTÍFICA DEL AUTOR SOBRE EL TEMA DE LA TESIS.....	XX

INTRODUCCIÓN

La industria metalúrgica desempeña un papel esencial en el desarrollo económico de un país, especialmente en Cuba. La metalurgia implica el procesamiento de metales, al obtener metal puro a partir de minerales metálicos. En este sentido, se insta a las empresas a incorporar la necesidad de protección ambiental y sostenibilidad en los esquemas [1-3]. Las empresas productoras de níquel en Cuba se caracterizan por procesos continuos que requieren una considerable automatización para lograr mayor eficacia y eficiencia en sus producciones.

En el diagrama de flujo del proceso lixiviación carbonato amoniacal, los hornos de múltiples hogares son una etapa clave en el proceso productivo. Estos hornos de reducción son cilindros metálicos en los que los óxidos superiores de hierro y óxido de níquel se reducen al correspondiente estado metálico [4], para lo cual se debe mantener un adecuado perfil de temperatura en atmósfera reductora (monóxido de carbono e hidrógeno) en cada hogar. El incumplimiento del perfil de gas reductor conlleva a pérdidas notables, debido a la formación de estructuras cristalinas de espinelas de hierro, olivinos y piroxenos que atrapan el níquel y el cobalto en forma de óxidos y, en menor grado, en estado metálico; así como los altos contenidos de hierro metálico en el mineral reducido, que provoca la disminución de la extracción de níquel y cobalto en el proceso de lixiviación [5].

Para lograr el perfil de temperatura deseado, el horno dispone de cámaras de combustión con quemadores de baja presión para la combustión incompleta del *fuel oil* que permite enriquecer la atmósfera reductora necesaria para la reducción de los óxidos. Esta operación requiere un alto consumo de *fuel oil*, que representa un 40 % del costo unitario por tonelada producida de níquel más cobalto [6], por lo que resulta de vital importancia determinar vías que propicien la reducción de tales costos.

El uso de la postcombustión resulta una alternativa viable al considerar la introducción de aire secundario en los hogares cuatro y seis (H4 y H6) del horno, con el propósito de lograr la combustión completa del monóxido de carbono residual y de otros gases combustibles que provienen de la combustión incompleta en los hogares inferiores [6]. La generación de calor durante la postcombustión, de conjunto con el carácter exotérmico de las reacciones que se verifican, contribuyen al precalentamiento y secado del mineral [7], además de disminuir los gases combustibles hasta valores permisibles.

El subproceso de postcombustión se caracteriza por variables, como el flujo de aire hacia H4 y H6 y la temperatura en estos hogares; el flujo y la temperatura del mineral; el flujo, la temperatura y la composición química de la mezcla de gases; y la temperatura ambiente. Esto determina que el subproceso sea considerado como un sistema MIMO. Un fenómeno característico del sistema de postcombustión es la interacción entre sus variables, de manera que cada variable de entrada afecta a las variables de salida y, recíprocamente, cada salida es afectada por varias entradas. Esto dificulta el diseño del sistema de control para la producción de níquel [8, 9].

La Empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara” de Moa, donde se realiza la investigación, comenzó a producir en el año 1986 y se basó en la tecnología Caron de la Empresa “Comandante René Ramos Latour” de Nicaro; donde los problemas de automatización de la postcombustión del horno estaban relacionados con el control de la temperatura en H4.

Actualmente, durante la explotación de los hornos de Moa existen conflictos operacionales en el control automático, dentro de los que se destacan:

1. La dificultad para establecer la relación aire combustible ($AC = \frac{m_a}{m_c} = \frac{kg}{kg} = \frac{kg \text{ de aire}}{kg \text{ de combustible}}$),

la cantidad de gases reductores necesarios y el perfil de temperatura de trabajo del horno, aparejado a la pérdida de níquel con compuestos que no se pueden disociar, incrementan los gastos por consumo energético en detrimento de la eficiencia y la operatividad de la planta.

2. La ausencia de instrumentos de medición y el ineficiente control del flujo de aire-combustión provoca fluctuación de los valores de presión requeridos para la adecuada combustión.
3. No se utiliza de forma eficiente la potencia de los motores de inducción que accionan los ventiladores encargados de suministrar el aire para las cámaras de combustión del horno.
4. Se desconocen los valores adecuados de flujo volumétrico y presión en las cámaras de combustión que garanticen la estabilidad operacional de la instalación.
5. Para el control de la postcombustión se utilizan controladores PID (Proporcional-Integral-Derivativo) convencionales [10], ajustados por prueba y error que forman parte de los lazos de control individuales, donde se manipula el flujo de aire de un mismo conducto dividido en dos ramas, que entran en conflicto. Por esta razón, normalmente el lazo de control de H4 opera en modo automático, mientras que el de H6 opera manual. Como consecuencia, los procesos físico-químicos que tienen lugar en estos hogares no se llevan a cabo de manera eficiente, lo que provoca indeseadas fluctuaciones de temperatura que influyen negativamente en el desarrollo de los procesos térmicos e hidrodinámicos dentro del horno.

Para solucionar las problemáticas anteriores, es necesario modelar los subprocesos del horno, a través de técnicas de identificación que permitan obtener modelos en funciones de transferencia y usar técnicas novedosas basadas en RNA.

Particularmente para el análisis del subproceso de postcombustión, se declaran los siguientes propósitos generales de la presente investigación:

Problema científico

Se requieren modelos matemáticos con capacidad explicativa y pronosticadora, que permitan el diseño de estrategias de control para aumentar la eficacia y la eficiencia del subproceso de postcombustión en hornos de reducción de minerales lateríticos, como los de la Empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara”.

El **objeto de estudio** es el subproceso de postcombustión de un horno de reducción de minerales lateríticos, que opera según la tecnología Caron.

Se plantea como **objetivo general**:

Obtener modelos matemáticos para el subproceso de postcombustión de un horno de reducción de minerales lateríticos, que relacionen la temperatura respecto a los cambios en los flujos de aire y el mineral alimentado; para el diseño de estrategias de control con vistas a aumentar la eficacia y la eficiencia metalúrgica del proceso, con el menor impacto ambiental.

El **campo de acción** de este trabajo es la modelación y simulación del subproceso de postcombustión en un horno de reducción de minerales lateríticos.

Dentro de este contexto, la investigación pretende cumplir los siguientes **objetivos específicos**:

1. Establecer las limitaciones y los fundamentos teóricos del modelado matemático e identificación del subproceso de postcombustión en hornos de reducción de minerales lateríticos.
2. Aplicar técnicas de identificación experimental para obtener los modelos lineales en funciones de transferencia.
3. Aplicar técnicas basadas en inteligencia artificial para obtener los modelos no lineales.
4. Validar los modelos propuestos sobre un conjunto de datos históricos del proceso.

En el cumplimiento de estos objetivos, se desarrollaron las siguientes **tareas de la investigación**:

- 1.A Revisión de las fuentes bibliográficas académicas y tecnológicas relacionadas con el objeto y campo de acción de la investigación.
- 1.B Selección y caracterización del horno de reducción de minerales lateríticos.
- 2.A Análisis del comportamiento estadístico de las variables a utilizar en la obtención de los modelos matemáticos.
- 2.B Realización de los experimentos en el subproceso de postcombustión del horno por medio de técnicas de identificación.
- 2.C Obtención de los modelos lineales en funciones de transferencia.

3.A Obtención de los modelos no lineales basados en RNA.

4.A Validación de los modelos matemáticos.

En correspondencia con el problema, objeto, objetivo y campo de acción, se establece como

hipótesis de la investigación:

Los modelos lineales en funciones de transferencia y los no lineales basados en RNA (SISO y MIMO) pueden caracterizar el subproceso de postcombustión de manera que sea posible predecir el comportamiento de la temperatura en H4 y H6 respecto a cambios en los flujos de aire y el mineral alimentado. Esto facilitaría el diseño de estrategias de control automático para aumentar la eficacia y la eficiencia metalúrgica del proceso, con la consecuente disminución del impacto ambiental y el consumo de combustible.

Métodos y técnicas empleados en la investigación:

- Histórico-lógico y de análisis síntesis con el objetivo de hacer un análisis crítico de la bibliografía consultada.
- Hipotético-deductivo, al plantear una hipótesis a partir de los resultados derivados de la revisión bibliográfica.
- Lógico-inductivo, al estudiar y aplicar métodos de identificación en un caso particular de una instalación real y arribar a conocimientos generales sobre la aplicabilidad de los resultados a otras instalaciones reales.
- Modelado, para obtener los modelos del subproceso de postcombustión del horno, las relaciones entre variables y la representación dinámica del sistema.
- Simulación, para obtener y comparar los resultados del modelado y procedimiento de identificación aplicados.

La **actualidad del trabajo** está sustentada en el interés del Estado Cubano y de su Ministerio de Energía y Minas en que las plantas que utilizan la tecnología Caron optimicen el consumo de combustible para elevar su competencia internacional. Se refleja el uso, relativamente reciente, de

las RNA para la modelación matemática de procesos tecnológicos complejos como base de sus automatizaciones y búsquedas de eficacia y eficiencia [11, 12].

Novedad científica

Modelos lineales en funciones de transferencia y no lineales basados en RNA (SISO y MIMO) para el subproceso de postcombustión en un horno de reducción de minerales lateríticos perteneciente a la Empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara”, que sirven de base en el diseño de estrategias de control automático para aumentar la eficacia y la eficiencia metalúrgica del proceso.

Aportes teóricos

1. Modelos lineales en funciones de transferencia, que no requieren avanzados recursos computacionales, abarcan diferentes puntos de operación del proceso y pueden ser empleados en estrategias de control multivariable que se insertan en los PLC de la empresa.
2. Modelo NARX SISO, que refleja las características dinámicas de la postcombustión con mayor exactitud, aunque requieren una mayor potencia de cálculo, disponible ya en algunos PLC de la empresa.
3. Modelo NARX MIMO, que incluye la descripción del modelo NARX SISO, y que presenta ventajas, tales como:
 - La estructura es MIMO a diferencia de los modelos previos SISO [8, 11, 13], lo que permite estimar el comportamiento multivariable de la postcombustión.
 - Permite readecuarse a diferentes condiciones de operación si se realizan actualizaciones de los pesos de la RNA con determinada frecuencia.
 - Permite capturar la no linealidad inherente del proceso.

Aportes metodológicos

Procedimiento de identificación para aplicar sistemáticamente en un horno de reducción de minerales lateríticos, que permita obtener modelos matemáticos que caractericen el comportamiento dinámico del sistema.

Aportes prácticos

- Diseño de dos programas en el software MATLAB® que facilitan la obtención de los modelos basados en RNA.
- Diseño de un simulador en el software MATLAB® que facilita la predicción del perfil térmico de postcombustión en el horno.

Presentación de la memoria escrita

El informe de la investigación tiene como partes fundamentales: introducción, tres capítulos, conclusiones, recomendaciones, bibliografía y anexos.

En el capítulo 1 se presenta el análisis de los trabajos precedentes relacionados con el proceso de reducción de níquel y la modelación matemática.

En el capítulo 2 se realiza la descripción del objeto de estudio y el universo donde se localiza, así como la metodología general para la obtención de los modelos matemáticos del subproceso de postcombustión y se argumenta la novedad científica. Se presentan, además, las condiciones de experimentación para la validación de los modelos propuestos.

En el capítulo 3 se exponen los resultados de la validación de los modelos y la simulación de las principales variables que intervienen durante la postcombustión.

A continuación, se presentan las conclusiones, las recomendaciones y las referencias bibliográficas.

Finalmente se incluyen los anexos que amplían y precisan el contenido.

Parte de los resultados de esta investigación se han visualizado mediante tres publicaciones en revistas de los grupos I y II:

- Montero, D; *et al.* Modelación matemática para el control de la postcombustión en un horno de reducción de níquel, *RIELAC*, Vol. XXXVI 3 /2015 p.21-34 Septiembre-Diciembre ISSN: 1815-5928 (Grupo II).
- Góngora, D., *et al.* (2020). Post-combustion artificial neural network modeling of nickel-producing multiple hearth furnace, *International Journal of Chemical Reactor Engineering*, 18(7), 20190191. doi: <https://doi.org/10.1515/ijcre-2019-0191> (Grupo I).
- Montero, D; *et al.* Modelo NARX de la postcombustión en un horno de reducción de mineral laterítico, *RIELAC*, Vol. XXXXIII 3 /2022 Septiembre-Diciembre ISSN: 1815-5928 (Grupo II).

Otros detalles sobre la producción científica del autor, anexo 10.

Se presentan 134 referencias bibliográficas tal como se resume en la siguiente tabla:

Tabla 0.1 Utilización de la bibliografía.

Período Temporal	Artículo revista científica	Evento	Informe Técnico	Libro	Tesis de Diploma	Tesis de Maestría	Tesis de Doctorado	Proyecto	Manual	Total	%
2018-2022	34	3	2	1	1	0	2	0	0	43	32,09
2013-2017	7	0	1	0	0	0	1	0	0	9	6,72
2008-2012	11	2	0	3	0	0	0	0	0	16	11,94
2003-2007	10	0	4	3	0	0	1	0	1	19	14,18
1993-2002	9	0	4	4	0	1	4	1	3	26	19,4
Antes de 1993	9	0	3	5	1	0	3	0	0	21	15,67
Total	80	5	14	16	2	1	11	1	4	134	100
%	59,7	3,73	10,45	11,94	1,49	0,75	8,21	0,75	2,98	100	

1. ESTADO DEL ARTE DE LA MODELACIÓN MATEMÁTICA EN HORNOS DE REDUCCIÓN DE MINERALES LATERÍTICOS

Los sistemas automatizados están en constante desarrollo y sus requisitos de desempeño son cada vez más exigentes; por ende, los métodos del llamado control convencional no siempre resultan adecuados. Por otro lado, las relaciones entrada - salida de los procesos pueden ser inciertas y modificadas por perturbaciones externas desconocidas. Todo ello conduce a la necesidad de aplicar nuevos enfoques para resolver estos problemas, ej: obtener modelos lineales paramétricos en diferentes puntos de operación del proceso y modelos no lineales, basados en técnicas de inteligencia artificial.

El objetivo de este capítulo es establecer los enfoques, limitaciones y logros de trabajos previos en la modelación matemática del subproceso de postcombustión de hornos de reducción de minerales lateríticos, para el diseño de estrategias de control dirigidas al aumento de la eficacia y la eficiencia metalúrgica del proceso.

1.1. Modelos matemáticos de procesos industriales

El procedimiento de identificación posee dos vías fundamentales: identificación analítica e identificación experimental [14].

- Vía analítica: consiste en desarrollar un modelo basado en las relaciones físico-químicas del proceso a identificar, mediante ecuaciones de balance de masa, de energía, otras. Este enfoque conduce generalmente a modelos complejos y no lineales que deben ser sometidos a un proceso de simplificación y linealización. El inconveniente principal de este enfoque consiste en que se

requiere un conocimiento muy especializado sobre la tecnología del proceso, no siempre disponible.

- Vía experimental: este enfoque resulta generalmente el más directo y el que produce resultados a más corto plazo. Se considera el sistema como una “caja negra” con determinadas entradas y salidas. En esta situación se realiza un conjunto de experimentos que proporcionan mediciones de las entradas y salidas durante la evolución del sistema hacia el estado estacionario, a partir de los cuales se trata de determinar el modelo del sistema.

Los modelos que representan los mecanismos de transferencia de calor en hornos, secadores y enfriadores rotatorios, son complejos, ya que involucran la conducción, la convección y la radiación, en un mismo instante de tiempo.

En la tecnología Caron se han obtenido modelos de diferentes procesos por la vía analítica: secado natural [15-20]; molienda [21]; transporte neumático de la mena laterítica [22]; enfriamiento del mineral laterítico en cilindros horizontales rotatorios [23]; secado de mineral laterítico en secadores rotatorios [24]; enfriamiento y mezcla del licor con el mineral reducido en el tanque de contacto [25-27] y calcinación del Carbonato Básico de Níquel [28-31]. La mayoría de estos modelos utilizan ecuaciones diferenciales, que se resuelven por los métodos de separación de variables, Runge Kutta y diferencias finitas.

Los modelos para un proceso en particular no son únicos, por eso se desarrollan modelos genéricos, como los que describen el comportamiento de un secador rotatorio [32] a contracorriente a partir de ajustes empíricos y propiedades físicas y mecánicas [33], los cuales constituyen una herramienta computacional para simular el comportamiento del equipo [34]. Además, se supone que los parámetros principales son independientes del tiempo, la temperatura y la posición [35], y lo consideran como un sistema de parámetros distribuidos [36] donde se aplican los conceptos de función de operación en la modelación de estos procesos.

En la obtención de modelos matemáticos se utiliza el Método de Elementos Finitos (MEF) para predecir la distribución de temperaturas en un horno rotatorio [37], el método de la dinámica de fluidos computarizada para explorar la eficiencia energética de un horno [35], los análisis energéticos y exergéticos para evaluar las pérdidas termodinámicas [38] y el consumo específico de energía en secadores [39].

La obtención de un modelo que describa el subproceso de postcombustión por la vía analítica sería en extremo complicado, pues los procesos físico-químicos involucrados en el horno conducirían a sistemas de ecuaciones diferenciales en derivadas parciales, no lineales y variables en el tiempo [9]. Por tal razón, es viable utilizar la identificación experimental para obtener modelos aproximados en diferentes puntos de operación del proceso.

1.2. Particularidades del proceso de reducción de minerales lateríticos en hornos

La postcombustión se enmarca dentro del proceso de reducción de minerales lateríticos que ocurre en el horno, el cual comprende tres etapas. Del H0 al H4, el mineral sufre un proceso de calentamiento y deshidratación, le sigue una zona de transición (Reducción Parcial + Disociación (H5 al H9), y la reducción comienza a partir del H10 [7]. El exceso de energía en la zona de calentamiento descompone parte del *fuel oil*, que provoca pérdidas del mineral a la atmósfera y contaminación ambiental por el exceso de monóxido de carbono e hidrógeno en los gases de salida del horno, al no ser suministrados al sistema de recuperación de polvo. Esto provoca que se pierda parte de la masa de reductores aportada por el aditivo, incrementa el consumo de combustible y la ineficacia del proceso de reducción. Este estudio permite ubicar al subproceso de postcombustión entre las zonas de calentamiento y la de transición.

En el estudio realizado en el horno de la Planta Piloto del Centro de Investigaciones del Níquel (CEDINIQ), que reproduce las condiciones de la tecnología de la Planta Punta Gorda, se demuestra que la condición de postcombustión de menor consumo de *fuel oil* se alcanza cuando se aplica en H4 y H6, a 750 °C en H6. Cuando no se aplica el proceso, la extracción del níquel se reduce en un

2 %, el consumo específico relativo de *fuel oil* en un 27,33 %, y el contenido porcentual de inquemados en los gases de salida, reflejado en el contenido de monóxido de carbono en chimenea, en un 1,7 %, y disminuye así las afectaciones al medio ambiente [40].

Por su parte, en [41] se plantea que el suministro del aire de postcombustión en el horno de reducción del proceso Caron de CEDINIQ genera variaciones en las extracciones de níquel y cobalto. En el caso del níquel, el aumento de la temperatura del H6 provoca una disminución de las extracciones, mientras que las extracciones de cobalto muestran un comportamiento irregular con presencia de máximos y mínimos.

Por otro lado, para mejorar el proceso de reducción de níquel en los hornos es necesario conocer cómo influye la composición mineralógica, el petróleo aditivo como catalizador de las reacciones de reducción, y establecer las principales fases que componen el sistema heterogéneo. Todos estos aspectos que dan la complejidad de este proceso no se han considerado en los modelos hasta ahora obtenidos.

El mecanismo y el estado que definen el proceso de reducción de níquel, no han sido estudiados suficientemente; ello está relacionado con la influencia de factores, tales como la naturaleza y propiedades de las fases que interaccionan y las condiciones térmicas del proceso [42].

En cuanto a la temática de la influencia de la composición mineralógica en el proceso de reducción, en las pruebas especiales realizadas con mineral de Punta Gorda, se llegó a la conclusión que la dilución del níquel en el mineral reducido de este yacimiento es menor que el que se alcanzaba en la Empresa “Comandante René Ramos Latour” de Nicaro [43]. La explicación de este comportamiento se debe a un mejor conocimiento de la variación de los elementos de níquel, hierro y cobalto, dado por la aplicación de un mejor método de muestreo y una modelación geoquímica más precisa; también a una menor composición de elementos estériles o diluyentes en los yacimientos que explota la empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara”, que demuestran cuánto puede variar la composición química mineralógica en una misma mena.

Para que ocurra la reacción en el sistema gas-sólido de la Planta Piloto de Nicaro, se consideran varias etapas: difusión del gas hacia el sólido, absorción de la fase gaseosa, reacción química en la superficie sólida, y difusión de los productos gaseosos [44]. En dicho trabajo se expone el modelo cinético y los pasos necesarios para que se lleve a cabo el proceso de reducción. La velocidad de reacción va a estar determinada por la difusión del gas al interior de las partículas y la concentración de agentes reductores, ello posibilita mejor comprensión del proceso de reducción, pues el desarrollo de la cinética de reacción depende del empleo eficiente de los gases reductores en el horno.

La reducción del mineral mediante el uso de agentes reductores procedentes del *fuel-oil* es un fenómeno fisico-químico y heterogéneo, por los diferentes estados de agregación de la materia que compone. Las porciones físicamente distintas de un sistema heterogéneo se conocen como fase separadas por límites definidos, en este caso el mineral constituye una fase sólida y los gases productos de la combustión constituyen la gaseosa [4].

En [45] se explica el efecto positivo del uso del petróleo aditivo en el incremento de los extractables de níquel y cobalto al potenciarse la atmósfera reductora en el horno. Se describen las principales reacciones químicas que ocurren en su interior, al emplear el petróleo mezclado con el mineral alimentado al proceso de reducción de minerales lateríticos.

1.2.1. Estudios de automatización en el proceso de reducción de níquel

Con el amplio desarrollo que han tenido los recursos informáticos a partir del siglo XX, la inversión en la automatización de los procesos aumenta significativamente, y permite que técnicas de control a través de modelos matemáticos puedan ser implementadas para aumentar la eficiencia energética y tecnológica.

Algunos estudios de automatización en el proceso de reducción de níquel son la concepción, diseño e implementación de la automatización adquirida a la firma inglesa Kent Instruments Limited, en 1973; que consistía en la regulación de la temperatura en H4, H10 y H15 con reguladores PID. En el caso del lazo de control de temperatura de H4 se realizó un análisis, donde se demostró que su

ineficiencia se basaba en la relación no lineal entre la temperatura y el flujo de aire, que da lugar a una acción en los cuatro cuadrantes que no puede resolver un regulador lineal como el propuesto en [46].

La concepción del sistema de control extremal que trata de mantener la temperatura en el valor máximo planteado en [47], no tuvo éxito porque requería la medición de la composición de los gases, que no fue posible realizar de manera adecuada debido a las características críticas de la atmósfera en el interior del horno. A su vez, se propuso un modelo matemático estático para el subproceso de postcombustión del horno. Sin embargo, presenta restricciones para el estudio del comportamiento dinámico del subproceso.

El regulador de polo asignado, desarrollado en [48], tampoco arrojó buenos resultados, pues requería el uso de un algoritmo de identificación en línea con elevados requerimientos de velocidad y memoria del ordenador de control, no disponibles en ese momento.

Una vez modernizada la fábrica de Nicaro en 1996, se instaló un sistema de automatización con instrumentos de la firma SIEMENS, que para el control de temperatura de H4, utilizó un regulador compacto PID que tampoco ofreció un comportamiento satisfactorio [49].

Valiosos aportes al tema del modelado dinámico del proceso de reducción se muestran en [42, 50-52], pero no se tiene en cuenta la introducción de aire secundario al horno; de manera que tampoco se adaptan para el fin previsto.

En los estudios [8, 9, 53]; se obtuvo un modelado matemático lineal de la temperatura con respecto a la apertura de las válvulas reguladoras de flujo de aire para los hornos de la Empresa “Comandante René Ramos Latour” de Nicaro, y se aportaron conclusiones para determinados puntos de operación del proceso. Los modelos que caracterizan la postcombustión se lograron mediante nueve experimentos, donde la raíz del error cuadrático medio (RMSE) está entre 0,72 y 6,1 °C. Las variables de entrada utilizadas fueron el flujo de aire a H4 y H6, y como variables de salida las temperaturas correspondientes a estos hogares. Posteriormente se agregaron dos nuevas variables de

entrada, el flujo de petróleo suministrado a las cámaras de combustión y el flujo de mineral alimentado al horno, con las mismas variables de salida. Se obtuvo un RMSE más bajo en el intervalo de 0,17 a 3,75 °C. Se probó la estrategia multivariable, que pareció ser efectiva, pero no se implementó definitivamente porque la planta niquelífera cerró en 2012, pues no era económicamente viable continuar operándola.

Si bien los modelos descritos anteriormente permitieron profundizar en el comportamiento dinámico del subproceso de postcombustión, no son directamente aplicables a los hornos de la Empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara” de Moa porque existen condiciones de operación diferentes. Los hornos de Nicaro tenían una altura de 21,3 m y nueve cámaras de combustión e inyectores (satélites) para el suministro de aire secundario en H4 y H6. En contraste, los hornos de Moa tienen una altura de 23,5 m, 10 cámaras de combustión, y no cuentan con satélites para garantizar el aire de postcombustión. Además, en la presente investigación no se tuvo en cuenta el flujo de petróleo suministrado a las cámaras de combustión porque no se registra en el sistema de supervisión, control y adquisición de datos (SCADA) de la empresa.

El proceso de reducción de níquel en hornos de múltiples hogares, tiene especificidades que limitan la aplicación de la teoría de modelación matemática que aparece en el estado del arte. Por tanto, se precisa identificarlo a partir de las variables que definen el sistema, y aprovechar las características de las mediciones y monitoreo existente, en aras de proponer una identificación del sistema, acorde con las actuales tendencias.

1.3. Aspectos sobre la identificación de sistemas

Las señales utilizadas con más frecuencia en la identificación experimental de sistemas son los escalones y las secuencias binarias pseudoaleatorias [54]. La restricción más importante de esta solución es la necesidad de introducir perturbaciones indeseables en el proceso, que a menudo tropiezan con la resistencia de los operadores. Comúnmente, el experimento de identificación se realiza con la ayuda de una computadora conectada en línea con el proceso.

En la práctica, lo ideal es recurrir a una mezcla de ambos métodos de modelado (vía analítica y experimental) para obtener el modelo final. El uso de datos reales para identificar los parámetros del modelo provee mayor exactitud, pero el proceso de identificación se facilita cuando es mayor el conocimiento de las leyes físicas que rigen el proceso [55].

El tipo de modelo, la precisión requerida y los métodos de identificación a utilizar, dependen fundamentalmente del objetivo que se persigue. Muchas veces son preferibles modelos continuos, bien en forma de funciones de transferencia o en espacio de estados; en otros casos, es suficiente un modelo simple capaz de reproducir con fidelidad las características esenciales del proceso como la ganancia, el tiempo de retardo y las constantes de tiempo dominantes.

En dependencia del algoritmo de control asociado, el uso del modelo discreto es generalizado a través de los dispositivos digitales en el control de procesos (computadoras, autómatas programables, reguladores digitales), o se utilizan modelos continuos y discretos [56].

Independientemente del objetivo de la identificación o del enfoque y métodos utilizados, es necesario tener muy en cuenta que existen diferencias entre un modelo matemático, (por sofisticado que este sea) y el proceso real. La experiencia y el sentido común recomiendan hacer uso cauteloso del modelo resultante de una identificación y tener siempre presente que la realidad es mucho más compleja [14].

Algunas aplicaciones de los modelos paramétricos en sistemas industriales se presentan a continuación.

1.3.1. Modelos paramétricos empleados en sistemas industriales

Para obtener el modelo matemático que describa la dinámica de la temperatura de clinkerización en la zona de combustión del horno rotatorio, inicialmente se desarrolló un experimento con señal escalonada para determinar el orden y los parámetros del modelo del proceso. Estos resultados se usaron en el diseño de un experimento más informativo, donde el flujo de combustible siguió una señal binaria y el modelo de media móvil autorregresiva con entradas exógenas (ARMAX) presentó

el mínimo error de predicción en comparación con los otros modelos paramétricos (ARX “Autorregresivo con entradas exógenas”, OE “Error de Salida”, y BJ “Box-Jenkins”) [57].

El diseño de un controlador de retroalimentación de estado robusto para el control efectivo de la temperatura en la zona de calentamiento del horno de recalentamiento de planchones de acero, se muestra en [58]. Basado en los datos de campo disponibles y los procedimientos de identificación del sistema, se deriva un modelo matemático de la zona de calentamiento, que presenta un modelo ARMAX de cuarto orden.

En [59] se muestra una configuración experimental con la técnica de medición simultánea para caracterizar el comportamiento electro-termo y termo-mecano-electro de resortes helicoidales submilimétricos y milimétricos con diferentes composiciones de materiales. Se infiere que el sistema es de tercer orden, y se obtiene un ajuste de 94,18 % con el modelo ARX; más adecuado para implementar un lazo de control cerrado para un mayor análisis del sistema.

En [60] se diseñó e implementó un gemelo digital (planta virtual dotada de una arquitectura) que ofrece una gestión de la incertidumbre y el control robusto de procesos. Para la representación del sistema, se calcularon los resultados de cinco identificaciones de sistemas paramétricos diferentes y luego del proceso de prueba y error, se propuso el modelo ARX. Un sistema de tercer orden fue seleccionado en base al Criterio de Información Bayesiano (BIC) y el Criterio de la Suma de Cuadrados Residual Normalizada por la Suma de Cuadrados en Serie (RSS/SSS).

La identificación de sistemas se ha extendido en la actualidad al análisis de dinámicas más complejas, con técnicas novedosas. Entre las más investigadas recientemente están las basadas en los sistemas biológicos y la inteligencia humana, que agrupan la lógica difusa, los algoritmos evolutivos, y las RNA.

1.4. Generalidades de las redes neuronales artificiales

Uno de los momentos fundamentales en el desarrollo de las RNA fue la propuesta de una ley de aprendizaje considerada como el punto de partida de los algoritmos de entrenamiento [61], y la

primera estructura de RNA fue propuesta en [62]. Desde entonces el interés suscitado por las redes ha crecido considerablemente, con nuevos modelos que han superado las limitaciones de las redes anteriores, con mayores capacidades [63].

Las RNA tienen su origen en la observación de los sistemas neuronales de los organismos vivos, sin embargo, no son un fiel reflejo de las redes biológicas [64].

Las características más relevantes de las redes son:

1. La capacidad de aprendizaje: la naturaleza no lineal de las RNA, les permite exhibir comportamientos verdaderamente complejos.
2. La posibilidad de procesamiento paralelo: en la implementación de las RNA, aumenta considerablemente la velocidad de procesamiento.
3. La significativa tolerancia a fallos: las RNA son convenientes en ciertas aplicaciones donde una avería constituya un serio peligro.
4. Fácil inserción en la tecnología existente: una red individual puede ser entrenada para desarrollar una única y bien definida tarea. Una red puede ser entrenada, comprobada, verificada y trasladada a una plataforma de hardware de bajo coste, y es fácil insertarla en aplicaciones específicas dentro de sistemas existentes.

Las RNA generalmente han sido implementadas mediante la programación sobre computadoras digitales, sin embargo, ya son implementadas en hardware, mediante montajes electrónicos o incorporando dispositivos ópticos. Tales ingenios, presentan un paso importante hacia la consecución de mayores velocidades de procesamiento, así como un camino hacia la popularización de las RNA, las convierte en un área de investigación muy activa [65].

La ingeniería de control se enfrenta a sistemas cada vez más complejos, a requisitos de diseño más exigentes y al desconocimiento de las plantas y sus entornos, que revitaliza la investigación en el campo de las RNA [66].

Las RNA poseen tres clases en función de su arquitectura y forma de procesar las señales [63, 67].

RNA estáticas: en esta clase se encuentran la red perceptrón multicapa, la red de funciones de base radial, red neuronal probabilística (PNN), como característica común no poseen memoria, solo transforman un conjunto de entradas en un conjunto de salidas y, una vez establecidos todos los parámetros de la red, las salidas dependen únicamente de las entradas. En general, la relación deseada de entradas y salidas se determina externamente mediante alguna forma de ajuste de los parámetros del sistema supervisado. Este tipo de redes se ha empleado con éxito en problemas de clasificación, en funciones lógicas, y en el campo de la aproximación funcional.

RNA dinámicas: a diferencia de la anteriores, permiten establecer una relación entre salidas y entradas y/o salidas y entradas previas, esto les añade cierta memoria. Matemáticamente, esta memoria se traduce en la aparición de ecuaciones diferenciales o ecuaciones en diferencia, que forman parte del modelo de las mismas, ejemplo: red de Hopfield, red de retardos en el tiempo (*Time Delay Neural Network*), red de tiempo discreto (*Time Discrete Neural Network*), otras. Las RNA dinámicas son útiles en problemas de modelado de dinámicas directa e inversa de sistemas complejos como robots, cohetes, naves espaciales, en la obtención de modelos de circuitos secuenciales y en la conversión de texto a voz.

RNA auto-organizativas: los nodos vecinos dentro de la RNA compiten en actividad por medio de las interacciones mutuas laterales, y se adaptan hacia detectores específicos de las diferentes señales de entrada. El aprendizaje de la red es competitivo, no supervisado o auto-organizativo. Se han aplicado con éxito en problemas de reconocimiento de patrones, control de procesos, incluso en el procesamiento de información semántica.

De estos tipos de redes, las dinámicas se perfilan como factibles para la modelación del subproceso de postcombustión del horno, pues se requiere establecer relaciones entre salidas y entradas y/o salidas y entradas previas en diferentes instantes de tiempo. Para identificar sistemas con estas redes, se deben tener en cuenta diferentes aspectos.

1.4.1. Identificación de sistemas con redes neuronales dinámicas

El proceso de identificación con RNA implica cuatro etapas: planeación del experimento para adquirir los datos con que se alimentará la red, configuración de la red, estimación de los parámetros del modelo (mediante la aplicación de algoritmos de aprendizaje), y validación [64, 68].

Al comparar los procedimientos clásicos de identificación con el empleo de RNA, los requerimientos de esta técnica son menores. En los procedimientos clásicos, el usuario debe especificar la estructura de la relación entre las entradas y las salidas, a veces muy complejas; mientras que para la identificación con RNA, solo se debe especificar la topología de la red. En este caso, se le indica a la red que obtenga un modelo capaz de reproducir valores numéricos semejantes a los de algún sistema físico [14]. En cuanto a los elementos de entrada y estructura, el usuario debe especificar los datos de entrada - salida del proceso, idénticamente en ambos procedimientos [69].

El paradigma de RNA más utilizado es el perceptrón multicapa (MLP) que aproxima las relaciones no lineales existentes entre un conjunto de datos de entrada (variables de proceso causales) y el conjunto de datos de salida correspondiente (variables dependientes) [70].

El interés creciente por las RNA se debe a su gran versatilidad y al continuo avance en los algoritmos de entrenamiento de redes y del hardware [71]. Además, se han distinguido por poseer una combinación única de características (ej., basadas en datos, de naturaleza autoadaptativa, inherentemente no lineales obtenidas y aproximadas de aplicación universal). Son capaces de reconocer regularidades y patrones en los datos de entrada, aprender de la experiencia y luego proporcionar resultados generalizados sobre la base de conocimientos previos conocidos.

Las RNA se utilizan para estudiar y predecir el comportamiento de una variedad de procesos industriales [72-75]. Algunas aplicaciones recientes de las RNA en la identificación de sistemas dinámicos no lineales, se muestran en [76-79]. En detalle, [76] aplicó aprendizaje profundo para la identificación no paramétrica de amplificadores de potencia y sistemas de control. [77] desarrolló

una estrategia de aprendizaje profundo para el modelado aerodinámico y aeroelástico inestable, mientras que [78, 79] abordaron el pronóstico de series temporales caóticas. En particular, la importante contribución de [79] es la introducción de un mecanismo especial para mejorar la predicción a largo plazo de series temporales caóticas. En todos estos estudios se empleó una arquitectura de red de tipo recurrente: específicamente, la arquitectura adoptada en [76] que exploró la RNA Elman (ENN), que consistía en células de memoria a largo/corto plazo (LSTM) de los trabajos [77-79].

Otro de los campos donde se ha demostrado la efectividad de las RNA con vistas a garantizar eficiencia en las producciones es en la metalurgia. De ahí, que sea necesario consultar algunos trabajos de referencia para la investigación objeto de estudio.

1.4.2. Redes neuronales artificiales aplicadas en la metalurgia

El perfil térmico a lo largo del horno de reducción de níquel tiene una correlación multivariable y representa un sistema complejo y no lineal. Es por eso que es difícil desarrollar un modelo del proceso para evaluar la temperatura en sus puntos. La investigación en el área del horno de níquel también es rara de encontrar, aunque el níquel representa un producto básico tanto en el negocio de metal como en la necesidad del estilo de vida.

En [80] se desarrolló un modelo NARX para el horno horizontal de la planta de procesamiento de níquel de Tailandia, donde se obtienen errores inferiores a 5 °C para cada termopar que tiene un rango de hasta 900 °C, y se considera que son resultados aceptables para el análisis, simulación, monitoreo y control del proceso. A su vez, un modelo NARX fue empleado en la predicción de la temperatura y el contenido de silicio del metal caliente. El algoritmo propuesto fue evaluado en base a su eficiencia en la simulación del proceso industrial de fabricación de metal caliente en un alto horno [81].

En [82, 83] se utilizaron las RNA con el algoritmo de entrenamiento de Levenberg-Marquardt para la predicción de la presión del aire en el colector de un sistema de suministro de aire para la

combustión del horno objeto de estudio, que mostró una correlación del 98 % y un 71 % en su generalización.

Por otro lado, en [84] se mejora la eficiencia general del horno de solera múltiple en la calcinación de caolín mediante el desarrollo de estrategias de control que incorporan sensores blandos basados en RNA, para estimar las limitaciones relacionadas con la mineralogía.

La aplicación de las RNA en procesos de pulvimetalurgia se proporciona en los trabajos [85-87]. En [85] se investigó un tratamiento hidrometalúrgico de dos etapas del concentrado de eudialito con RNA y otros métodos. En [86] se propuso un modelo RNA multicapa con algoritmo de aprendizaje *backpropagation* para lograr una mejor predicción de las características de salida (propiedades mecánicas, dimensiones de la herramienta, otras). En [87] se introdujo un perceptrón multicapa para predecir la calidad del producto y los resultados se decodificaron en una medida de la calidad del pronóstico para evaluar el desempeño del modelo generativo.

La combinación del seguimiento de partículas con la capacidad de generalización de las RNA y la utilización de los datos de análisis de liberación del mineral en procesos de separación magnética y por gravedad de un mineral complejo de Western Erzgebirge, Alemania; se muestra en [88].

En [89] se desarrolla un modelo RNA para la predicción de la vibración de explosión utilizando 248 registros de datos recopilados de tres minas de carbón de la India, con diversas condiciones de geominería. El coeficiente de correlación entre la velocidad máxima de partículas medida y la salida del modelo fue de 0,96, con un porcentaje de error promedio de 11,85.

La comparación de los métodos del conjunto de aprendizaje automático (bosques aleatorios, aumento de gradiente) con una RNA se llevan a cabo en [90] para predecir la temperatura de inicio de martensita de los aceros.

Los efectos del biosurfactante ramnolípido (RL) en el rendimiento de flotación de una muestra de carbón se analizan en [91]. La correlación entre la condición de la adición de RL y las respuestas del proceso se modelaron utilizando RNA. Basado en los errores MSE, RMSE, y el error porcentual

como medidas de precisión del modelo; el algoritmo de Levenberg-Marquardt con arquitectura de siete neuronas en la capa de entrada, 16 neuronas en la capa oculta, y una neurona en la capa de salida [7-16-1], predijo adecuadamente la respuesta del proceso.

Por su parte, en [92] se propusieron una familia de RNA para el sistema Al-Cu (Aluminio, Cobre) como un ejemplo del potencial de aprendizaje automático que puede lograr una precisión cercana a los primeros principios para muchos aspectos metalúrgicos importantes de esta aleación.

Una metodología fue propuesta en [93] que es capaz de predecir seis salidas de la planta simultáneamente (recuperación metalúrgica de zinc (Zn) a partir de concentrado de Zn, recuperación metalúrgica de Zn a partir de concentrado de plomo (Pb) y recuperaciones metalúrgicas de Zn a partir de relaves, masa de concentrado de Zn, masa de concentrado de Pb y masa de relaves). Se utilizó una técnica de RNA y las predicciones del modelo con un factor de aumento de escala se reconciliaron con las respuestas de la planta, lo que mostró resultados consistentes.

En [94] se aplicó exitosamente un enfoque de RNA en la investigación para predecir el estado del revestimiento del equipo metalúrgico. Su efectividad fue confirmada por los valores más bajos del error de pronóstico en comparación con los métodos de pronósticos clásicos.

Conclusiones parciales

1. La modelación y control del perfil térmico en los hornos de reducción de minerales lateríticos ha sido objeto de varios trabajos. Los más cercanos a la investigación resultan los modelos de los hornos de Nicaro que, aunque profundizaron en el comportamiento dinámico del subproceso de postcombustión, no son directamente aplicables a los hornos de Moa porque existen condiciones de operación diferentes.
2. En la modelación de procesos industriales complejos y no lineales, donde los métodos tradicionales de cálculos no son efectivos, las RNA se presentan como una herramienta potente. En este sentido, se reportan algunos trabajos sobre la modelación de hornos metalúrgicos

diferentes al objeto de estudio, donde se fijan cotas de errores para la predicción del perfil térmico, que sirven de referencia para esta investigación.

2. MATERIALES Y MÉTODOS PARA LA MODELACIÓN MATEMÁTICA DEL SUBPROCESO DE POSTCOMBUSTIÓN

El proceso tecnológico de la Empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara” está basado en la tecnología Caron [95]. La reducción de minerales lateríticos es una de las etapas más importantes del proceso químico. El grado de reducción por las reacciones del proceso depende de un conjunto de variables y parámetros, su interacción en el proceso tecnológico, determina los valores de la cantidad de níquel extractable, como principal indicador de calidad en el producto final.

En este capítulo se hace un esbozo de los aspectos relacionados con el proceso de reducción, fundamentalmente, el subproceso de postcombustión que tiene lugar en el horno de múltiples hogares; con el objetivo de establecer la metodología para la modelación matemática del objeto de estudio, a partir del diseño de experimentos de identificación y métodos complementarios para validar y evaluar los modelos matemáticos.

2.1. Descripción del proceso de reducción de níquel en el horno objeto de estudio

El proceso que se realiza en la Unidad Básica de Producción Planta Hornos de Reducción (anexo 1) debe garantizar la reducción del óxido de níquel a níquel metálico, apto para la lixiviación amoniacal. Para ello la planta cuenta con 24 hornos tipo Herreshoff [96], compuestos por 17 hogares numerados de arriba hacia abajo desde el H0 hasta el H16, encerrados en un cilindro metálico de 23,5 m de alto y 6,78 m de diámetro, revestido interiormente por material refractario (figura 2.1). El mineral se introduce en el horno por el H0, tras ser dosificado por un sistema de pesaje automatizado. Posteriormente, fluye a contracorriente con los gases reductores y, en su descenso, se seca, calienta y reduce según las reacciones que se indican a continuación [4].

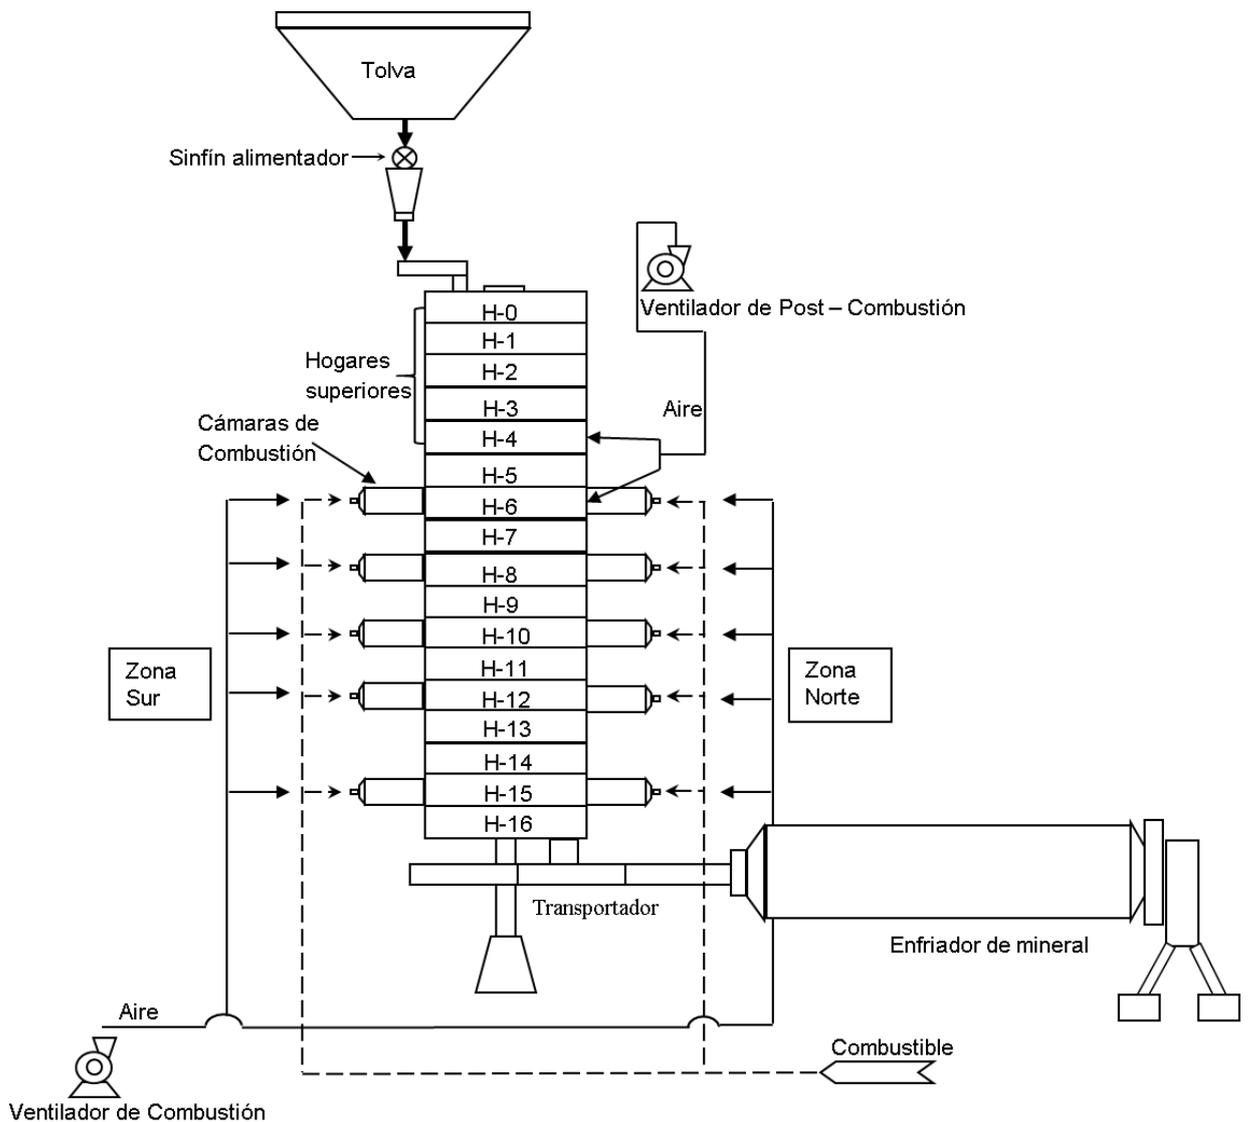
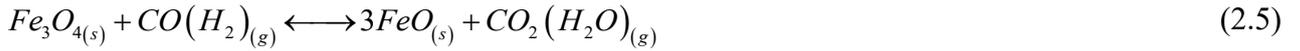
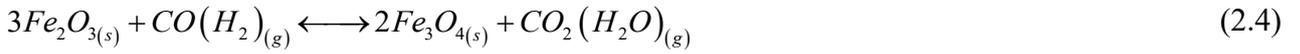
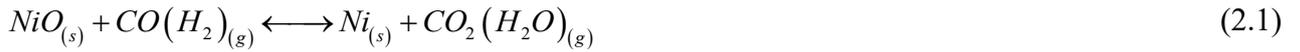


Figura 2.1 Diagrama de flujo del proceso de reducción en el horno

La reducción se logra al establecer condiciones, determinadas por un perfil de temperatura (figura 2.2) y una concentración determinada de gases reductores ($\text{CO} + \text{H}_2$). Para ello el horno

dispone de 10 cámaras de combustión, ubicadas en H6, H8, H10, H12 y H15, equipadas con quemadores donde se realiza la oxidación incompleta del combustible (petróleo). Estas cámaras, además de generar calor, enriquecen la atmósfera reductora y en su interior ocurren reacciones que garantizan temperaturas de 1 350-1 450 °C. El horno opera con una ligera presión positiva para evitar la entrada de aire que reoxide al mineral, lo que se logra al mantener determinada diferencia de presión entre H0 y H16. El tiempo de retención del mineral en el horno es aproximadamente 2 700 s.

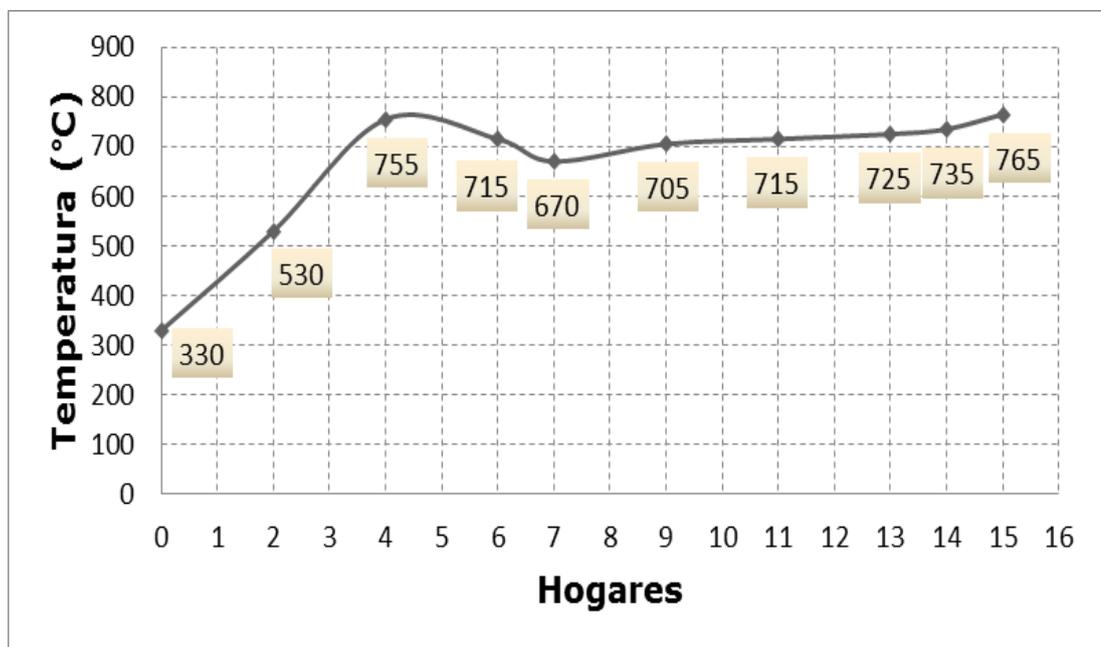


Figura 2.2 Perfil de temperatura en los hogares del horno de reducción

Los gases que salen del horno arrastran consigo partículas de mineral en forma de polvo, las más gruesas se recuperan por un sistema de aspiración llamado batería de ciclones (NIOGAZ del tipo TsN-11 con diámetro interior $\varnothing = 800$ mm y ángulo de inclinación 11°), las restantes partículas viajan con los gases a través de un conducto hacia una batería de precipitadores electrostáticos donde se recupera un 98 % del material sólido restante. El mineral recuperado por los ciclones cae, por gravedad, al horno a través del H0; el recuperado por los electrofiltros se almacena en los silos de mineral. Una vez reducido el mineral, es descargado por el H16 y enviado a un enfriador a través de un transportador de tornillo sinfín, para lograr temperaturas por debajo de 260 °C. Al mineral que

sale del enfriador se le agrega una solución carbonato amoniacal, y se obtiene la pulpa que se envía a la Unidad Básica de Producción Planta Lixiviación y Lavado [97].

En el proceso de reducción de níquel, la postcombustión tiene una incidencia directa en la eficiencia económica del proceso de tostación reductora en hornos Herreshoff, por su influencia en el perfil térmico del horno, la velocidad de calentamiento, el grado de reducción del níquel, y el consumo específico de *fuel oil* [40].

2.1.1. Descripción del subproceso de postcombustión

En H4 y H6 se introduce aire secundario por medio de un ventilador (figura 2.1) con el propósito de quemar el CO y H₂ no consumidos en las etapas de reducción previas, según las siguientes ecuaciones [53]:



En las ecuaciones (2.6) y (2.7), las reacciones de oxidación son exotérmicas y proporcionan parte del calor necesario en los hogares superiores (H4 a H0). La postcombustión también evita que la concentración de CO y H₂, en los gases que salen del horno, supere los límites de emisión permisibles, y contribuye a disminuir la contaminación ambiental. Además, aumenta la eficiencia energética general del proceso, pues se requiere la introducción de menor volumen de gases de las cámaras para mantener el perfil térmico y esto incide en un menor consumo específico de *fuel oil* [6, 9, 98].

Los fenómenos físico-químicos que tienen lugar en H4 y H6 son relativamente complicados si se tienen en cuenta los fenómenos de transferencia de calor que ocurren en los mismos y la naturaleza de los minerales portadores de níquel presentes en los distintos yacimientos utilizados. En [48] se ofrece un análisis de estos fenómenos.

Debido a que la cantidad de reductores puede variar de forma no controlada, la relación entre TH4 y ApH4 en estado de régimen estacionario suele ser de la forma que se ilustra en la figura 2.3 [8]. Este comportamiento es una característica estática que ha impedido el funcionamiento exitoso de los reguladores PID instalados para el control automático de la temperatura de dicho hogar, en los hornos de reducción de la Empresa “Comandante René Ramos Latour” de Nicaro.

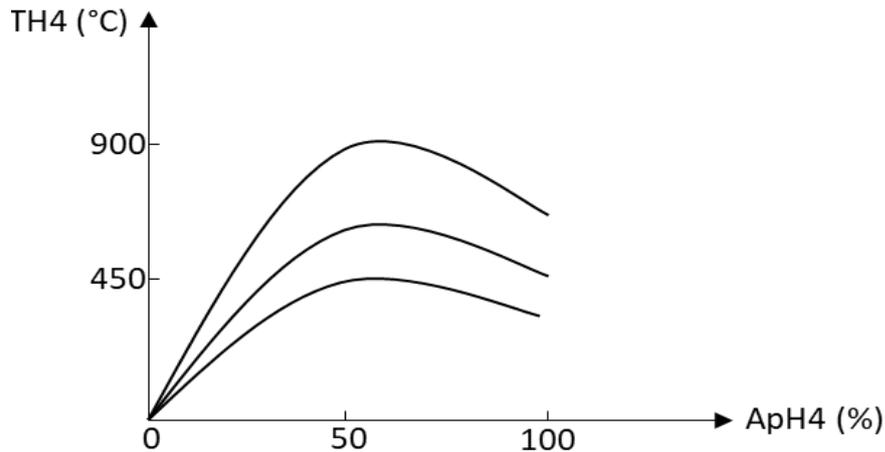


Figura 2.3. Relación entre apertura de válvula y temperatura en H4 a estado de régimen estacionario Fuente: [47]

Previo a la modelación matemática del subproceso de postcombustión con vistas a incrementar la eficiencia productiva, se deben tener en cuenta algunas especificaciones técnicas y constructivas que son determinantes para el desarrollo de la ciencia.

2.1.2. Descripción de la instalación para la postcombustión

El sistema de postcombustión está constituido básicamente por un ventilador centrífugo (tabla 2.1) instalado en el piso superior (techo) del horno, con toma de succión de aire caliente (150 a 200 °C) desde la chimenea del eje central y un conducto de aire desde el ventilador hasta H4 y H6, con sistema de regulación de flujo a través de válvulas de mariposa.

Tabla 2.1 Datos técnicos del ventilador de postcombustión.

<i>Tipo de ventilador</i>	<i>PHD-685/100-100S</i>
Velocidad del rotor	233,4 rad/s
Densidad	855 kg/m ³
Motor	11 kW
Diámetro del ventilador	685 mm X Tamaño 100 %

El conducto de aire de postcombustión que se encuentra a la salida del ventilador, tiene un diámetro interior de 0,407 m y baja paralelo al cuerpo del horno hasta H4, donde se ramifica en dos conductos de igual diámetro, uno hacia H4 y otro hacia H6 (figura 2.1).

En la figura 2.4 se muestran las características del ventilador para las condiciones constantes en la que está operando. La curva del ventilador intercepta a la curva característica del sistema en el punto de funcionamiento (A); para un flujo de aire aproximado que circula antes de la bifurcación de 6 796 m³/h, con una presión de 3 kPa.

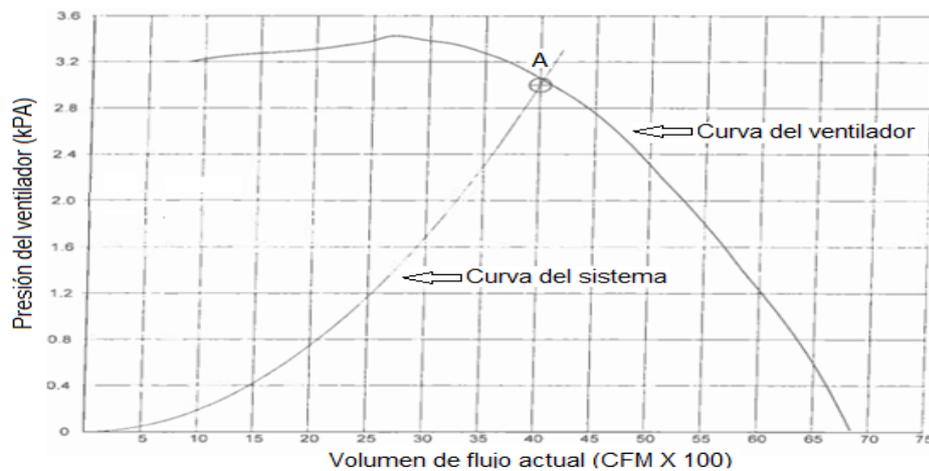


Figura 2.4 Características del ventilador de postcombustión

Fuente: <http://www.priorindustries.com/>

Al considerar que el flujo total de aire que se garantiza antes de la ramificación es constante y corresponde a un sistema de aire con ducto fijo, se presentan en la tabla 2.2 el flujo de aire a H4 y H6 después de la bifurcación, en función de las aperturas de las válvulas.

Tabla 2.2 Flujo de aire equivalente en función de las aperturas de válvulas. Fuente: Autor

<i>ApH4 y ApH6</i> (%)	<i>FaH4 y FaH6</i> (m ³ /h)
10	679,6
20	1 359,2
30	2 038,8
40	2 718,4
50	3 398,0
60	4 077,6
70	4 757,2
80	5 436,8
90	6 116,4
100	6 796,0

2.1.3. Estado actual de la automatización del subproceso de postcombustión

Para cumplir con los estándares internacionales de eficiencia metalúrgica del subproceso de postcombustión del horno; se requiere un sistema de automatización que pueda controlar, supervisar, recopilar, y analizar datos, así como generar informes a distancia mediante una aplicación informática.

En la Unidad Básica de Producción Planta Hornos de Reducción se encuentra instalado un sistema de supervisión y control (CITECT). Cada horno tiene asignado un autómat, que es encargado de recepcionar todas las señales de las diferentes variables del proceso; intercambia información con otro ubicado en el panel de control, para darle al operador toda la información de proceso a través de una computadora. En el panel de control existen dos bloques, donde se ubican los reguladores de presión y temperatura, así como las romanas para la dosificación del mineral a los hornos. Existe también un equipo indicador (OP-35) con una pantalla digital para ejecutar la parada o arranque de los motores eléctricos acoplados a los diferentes equipos tecnológicos, abrir o cerrar válvulas automáticas y *ON-OFF*. Esta operación también se realiza desde las computadoras [97].

En la tabla 2.3 y el anexo 3 se describe la instrumentación vinculada al subproceso de postcombustión con sus características.

Tabla 2.3 Instrumentación del subproceso de postcombustión.

<i>Nombre</i>	<i>Denominación</i>	<i>Rango</i>	<i>Tipo</i>	<i>Marca</i>	<i>Observaciones</i>
Tp	Termopar con convertidor (4 a 20 mA)	0 a 1 000 °C	K Cromel- Alumel	Thermibel	Mide la temperatura en H4 y H6
Vc	Válvula de control con actuador de giro	0,2 a 1,0 kgf/cm ²	Mariposa		Regula flujo de aire hacia H4 y H6
PI	Posicionador Inteligente	0 a 100 %	SIPART PS2	Siemens	Controla la posición de la válvula
Ag	Analizador de gases Ultramat 507	0 a 10 %	Ondas infrarrojas no dispersivo	Siemens	Indica la concentración del monóxido de carbono residual

Actualmente está instalado el sistema de supervisión y control EROS [99] en los hornos dos y cinco, que permite la medición del flujo de mineral alimentado al horno, otra de las variables del subproceso de postcombustión. En el anexo 2 se muestran los detalles del sistema de supervisión y control del horno.

2.1.4. Variables del subproceso de postcombustión

Al considerar que las variables de interés para la identificación han de ser aquellas útiles para el control, y que el objetivo de este es mantener TH4 y TH6 del horno en el rango establecido, el sistema se consideró como una caja negra (figura 2.5) cuyas variables son:

Variables de entrada,

- ApH4 (Apertura de la válvula reguladora de flujo de aire al hogar cuatro), [%].
- ApH6 (Apertura de la válvula reguladora de flujo de aire al hogar seis), [%].

Variables de salida,

- TH4 (Temperatura en el hogar cuatro), [°C].
- TH6 (Temperatura en el hogar seis), [°C].

Las principales perturbaciones que afectan a este proceso son:

- Fm (Cambios en el flujo de mineral), [t/h].
- Cm (Composición química de los elementos Ni, Co, Fe, SiO₂, MgO, S, C, alimentados al horno), [%].
- Tm (Temperatura del mineral), [°C].
- Hm (Humedad externa del mineral), [%].
- Vcm (Velocidad de calentamiento del mineral en la zona de postcombustión), [°C/min].
- Fc (Flujo de combustible suministrado a las cámaras de combustión), [kg/t].
- Fg (Flujo de gases), [m³/h].
- Tg (Temperatura de los gases), [°C].

- C_{qg} (Composición química de la mezcla de gases), [%].
- T_a (Temperatura ambiente), [°C].
- H_{ra} (Humedad relativa del medioambiente), [%].
- Ph (Presión en el interior del horno), [mm de H₂O].
- T_{as} (Temperatura del aire secundario inyectado en H4 y H6), [°C].

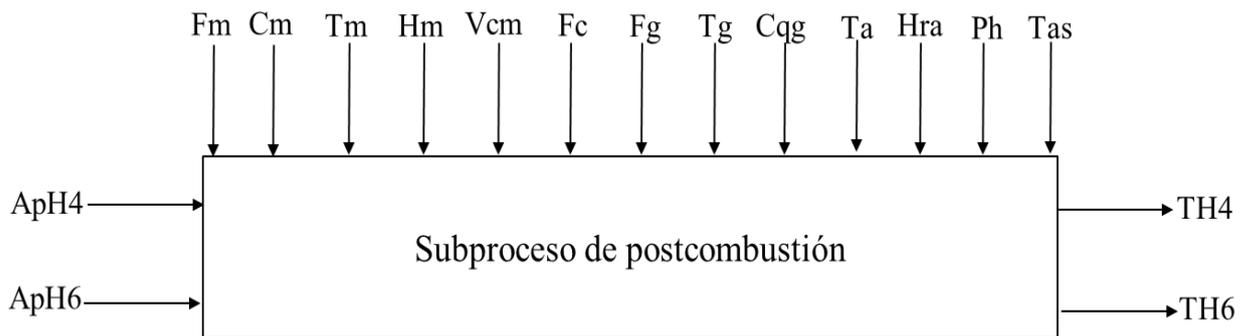


Figura 2.5 Subproceso de postcombustión visto como caja negra

F_m es una variable de coordinación que depende del sistema de mayor envergadura (horno), que debe tener un valor prácticamente constante de 20 t/h, aunque las condiciones pueden variar y F_m ser una perturbación para el control del subproceso de postcombustión.

Las variables ApH_4 y ApH_6 son manipuladas directamente por válvulas, que son elementos de acción final en los lazos de control automático. Las otras variables como el perfil térmico de las cámaras y los restantes hogares no se consideran en la estructura de los modelos [11].

La metodología a aplicar sistemáticamente en el horno de reducción de minerales lateríticos, que permita obtener los modelos del comportamiento dinámico del subproceso de postcombustión; se describe a continuación.

2.2. Metodología general para la modelación del subproceso de postcombustión

Para la modelación del subproceso de postcombustión fueron utilizados los sistemas de supervisión y control CITECT y EROS, que permitieron medir las variables de interés para el estudio y análisis del subproceso de postcombustión. El software MATLAB®, específicamente, *The System Identification Toolbox* (anexo 7), *Artificial Neural Network "NNSYSD"*, y el módulo de *Deep*

Learning 14.2; se emplearon para la obtención de los modelos lineales y no lineales del proceso. Las modelaciones se ejecutaron en una laptop Dell Latitude 5310 con procesador Intel (R) Core (TM) i5-10210U CPU a una frecuencia 1,60 GHz 2,11 GHz y una memoria RAM de 8 GB.

Los experimentos se realizaron en un horno de reducción que operaba en condiciones técnicas adecuadas y con buena sensibilidad de respuesta de las temperaturas de H4 y H6, ante la presencia de variaciones en la apertura de las válvulas reguladoras de flujo de aire. El horno estaba provisto de ocho cámaras de combustión (6S, 8N, 8S, 10N, 10S, 12N, 12S y 15S), 67 brazos en el eje central y todos los hogares se encontraban en buen estado técnico.

Las características del combustible y los detalles sobre la composición química del mineral suministrados a la Unidad Básica de Producción Planta de Hornos de Reducción de la Empresa Productora de Níquel y Cobalto "Comandante Ernesto Che Guevara" para el desarrollo de los experimentos activos, se pueden encontrar en el anexo 4, con valores cercanos a los parámetros nominales que se utilizan con regularidad en la Planta.

2.2.1. Obtención de los modelos lineales del proceso

El diagrama de flujo mostrado en la figura 2.6, explica las etapas para la obtención de los modelos lineales, donde se siguieron los pasos del proceso de identificación por la vía experimental [100].

Se llevaron a cabo experimentos previos con señal escalón para determinar las constantes de tiempo dominantes del subproceso de postcombustión, la presencia de no linealidades y los detalles de la construcción de las señales de excitación definitivas. Luego, se siguieron cuatro etapas para la obtención de los modelos lineales:

1. Diseño del experimento con señales de excitación. Se excitó el sistema con una señal de entrada diseñada expresamente con este fin y se registró la evolución de entradas y salidas durante un intervalo de tiempo.
2. Elección de la estructura del modelo. Se probaron las estructuras de modelos discretos (BJ, OE, ARX, y ARMAX) y para cada una se tomaron diferentes órdenes.

3. Estimación de los parámetros del modelo. Se procedió a la estimación de los parámetros de la estructura que mejor ajustaba la respuesta del modelo a los datos de entrada-salida obtenidos experimentalmente.
4. Validación del modelo. Se determinó si el modelo obtenido satisfacía el grado de exactitud requerido para la aplicación en cuestión. Ante un modelo no válido, se revisaba si el conjunto de datos representaba la dinámica del proceso, la estructura escogida era la adecuada o el criterio de ajuste de los parámetros era el más apropiado.

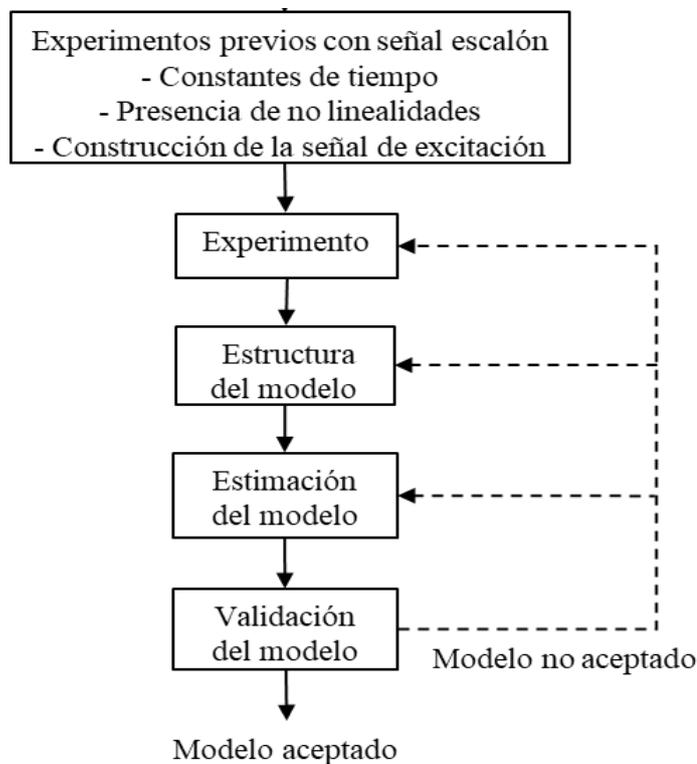


Figura 2.6 Metodología para la modelación lineal del proceso Fuente: Autor

Para la obtención de los modelos lineales se hizo un tratamiento previo de las variables TH4, TH6, ApH4, ApH6, Fm (descrito en el epígrafe 3.4), que consistió en sustraer el valor medio de los datos y hacer que la media de los mismos fuera cero a través del comando *dtrend* del programa MATLAB®, luego se seleccionó una parte de los datos para la estimación y otra en la validación.

2.2.2. Obtención de los modelos no lineales del proceso

En la figura 2.7 se muestran las etapas para la obtención de los modelos no lineales basados en RNA.

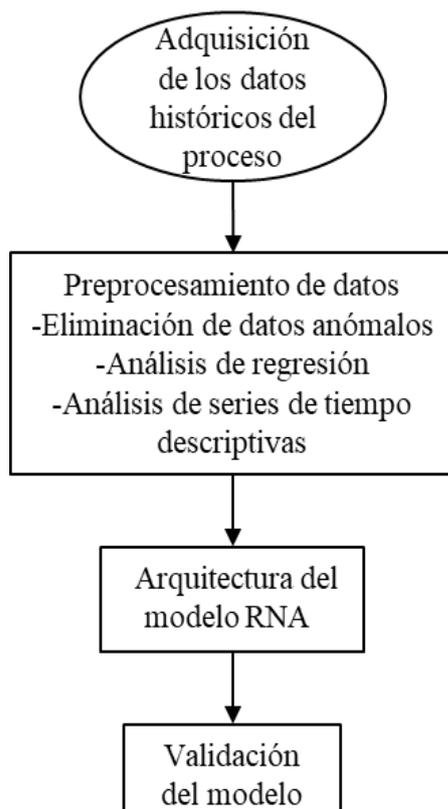


Figura 2.7 Metodología para la modelación no lineal del proceso

Se emplearon datos históricos del horno correspondientes a 10 meses (distribuidos en tres meses de 2015, cuatro meses de 2018, y tres meses de 2022, con un período de muestreo de 120 s) con el objetivo de tener una idea de la variabilidad del proceso en diferentes períodos (tabla 2.4).

Tabla 2.4 Valores mínimos y máximos de las variables del horno en diferentes años.

Variable	2015		2018		2022	
	Rango (mínimo-máximo)					
ApH4 (%)	0	100,0	0	100,0	0	0
ApH6 (%)	0	59,6	0	100,0	0	90,4
TH4 (°C)	480,9	956,7	445,0	939,8	111,1	1 034,8
TH6 (°C)	503,2	931,5	487,0	964,9	137,9	1 063,8

Se eliminaron los datos anómalos mediante el comando *filloutliers* del programa MATLAB®, que establece como anómalo un valor que se aleje de la media en más de tres desviaciones estándar y lo reemplaza por un valor medio entre el valor anterior y posterior al anómalo. Luego con la función *mapminmax* se normalizaron los datos al rango [-1 1].

Los métodos de análisis de regresión y los de series temporales descriptivas se utilizaron con el objetivo de determinar las variables que más influyen en el comportamiento de TH4 y TH6.

Los detalles de la arquitectura y validación de los modelos RNA (SISO y MIMO) se muestran en los epígrafes 2.9 y 2.10.

En el siguiente epígrafe se presenta el diseño de experimentos conjuntamente con la descripción de las variables de interés medidas, manipuladas y acondicionadas, para llevar a cabo la modelación matemática [101].

2.3. Diseño del experimento de identificación

Un punto crucial es el diseño de la señal que se va a utilizar para excitar al sistema, luego se aplica la misma y durante su aplicación se recopilan los datos y se procesan fuera de línea en una computadora. Los datos experimentales pueden ser alterados a través de un nuevo experimento que normalmente consume tiempo. Por tanto, se proyectó el experimento cuidadosamente para que los datos fueran lo suficientemente informativos [101]. Los experimentos se realizaron cuando el proceso estaba en un modo de operación próximo al deseado.

Se realizaron cuatro experimentos preliminares para caracterizar el proceso. Para el análisis se utilizó la respuesta al paso escalón o el análisis de correlación de datos, por la sencillez de los métodos. Los experimentos preliminares como sugiere [102] permitieron determinar:

- la constante de tiempo fundamental o dominante;
- la amplitud permitida de la entrada;
- la presencia de no linealidades;
- y la variación temporal del proceso.

Estas informaciones se utilizaron para el proyecto de experimentos de identificación:

- selección de las variables de entrada y salida;
- señal de entrada (forma, amplitud, espectro);
- tasa de muestreo;

- duración del experimento;
- e identificación en lazo abierto.

Como el proceso a ser identificado es no-lineal y se buscó un modelo lineal para representarlo, el experimento fue realizado en torno a diferentes puntos de operación del proceso. El rango de operación del modelo determinó, en parte, la amplitud permitida de la señal de entrada y la selección de la estructura del modelo.

Un modelo lineal que pueda ser usado para el control regulatorio estacionario en torno de un valor de referencia dado, requiere un experimento con una amplitud de entrada baja, lo suficiente para que la linealización no sea violada. Algunas veces la validación indica que el modelo obtenido no es lo suficientemente preciso. Eso puede ocurrir por:

- la amplitud insuficiente de la entrada;
- la señal de entrada no es persistentemente excitante;
- la estructura del modelo no-identificable;
- y la corta duración del experimento.

En este caso, un nuevo experimento es la única forma de obtener un modelo más representativo de la dinámica del sistema.

Con el propósito de integrar las recomendaciones del proceso de identificación, se presenta la excitación del sistema con secuencias binarias pseudoaleatorias moduladas en amplitud y frecuencia (programadas en el autómata), para identificar el comportamiento de las variables de interés del subproceso de postcombustión del horno.

Las señales aleatorias poseen con respecto a otras, como el escalón, la ventaja de que su amplitud puede ser muy pequeña, y reducen el grado de perturbación que se introduce en la planta objeto de identificación. Por otra parte, estas señales pueden superponerse a los valores normales de la variable de entrada, independientemente de las variaciones de esta, sin que se afecte, en teoría, el proceso de identificación [14].

2.3.1. Diseño del experimento con SBPA para la obtención de modelos lineales

Al tener en cuenta las consideraciones realizadas en [103] y [104] para la realización de los experimentos, se seleccionó como señal de entrada la Secuencia Binaria Pseudo-Aleatoria (SBPA) o *Pseudo-Random Binary Sequence* (PRBS).

Estas señales son periódicas y sus funciones de autocorrelación se aproximan a la función Delta de Dirac y se codifican mediante secuencias de ceros y unos, que satisfacen una ecuación en diferencias del tipo:

$$x(t) = a_m D^m x(t) \oplus a_{m-1} D^{m-1} x(t) \oplus \dots \oplus a_1 D x(t) \quad (2.8)$$

donde:

$D = q^{-1}$: operador de retardo, de manera que $D^m x(t) = x(t-m)$; \oplus : operador de suma módulo 2;

$x(t)$: variable binaria que asume valores 0 ó 1; a_i : coeficientes binarios que asumen también valores

0 ó 1; m : orden de la secuencia.

Los detalles de cómo se seleccionan los coeficientes a_i pueden encontrarse en [14]. De acuerdo con Selva [105], el orden de la secuencia debe oscilar de cinco a siete, y se escoge a $n = 5$. La selección de un orden mayor implicaría experimentos muy largos, no permitidos por la dirección de la Unidad Básica de Producción Planta Hornos de Reducción; uno menor ofrecería muy poca información [8].

El período de la secuencia es: $M = 2^5 - 1 = 31$, lo que corresponde a una SBPA de máxima longitud y en la tabla 2.5 se muestran los resultados de la ecuación (2.8) para el orden de la secuencia escogida.

El 1 se corresponde con la apertura de la válvula y el 0 con el cierre. Los valores de 0 y 1 deben ser simétricos con respecto a la posición normal del elemento de control, de manera que el efecto neto o promedio de la perturbación introducida al final del experimento sea cero [8].

Las SBPA fueron aplicadas a ApH4 y ApH6, con el fin de obtener las respuestas de TH4 y TH6. Se introdujo una SBPA de forma manual (no programada en el PLC) al Fm para observar la influencia del mismo en el proceso.

Como señal de entrada para excitar al proceso se utilizaron también las APRBS.

Tabla 2.5 Secuencia de orden cinco generada para la excitación de SBPA.

$x(t)$	$x(t-3)$	$x(t-5)$	$x(t)$	$x(t-3)$	$x(t-5)$	$x(t)$	$x(t-3)$	$x(t-5)$
1	0	1	0	0	0	0	1	1
1	0	1	0	1	1	1	1	0
0	0	0	0	0	0	1	0	1
1	1	0	1	0	1	1	0	1
1	1	0	0	0	0	1	1	0
1	0	1	0	0	0	1	1	0
0	1	1	1	1	0	0	1	1
1	1	0	0	0	0	0	1	1
0	1	1	1	0	1	0	1	1
1	0	1	1	1	0			
0	1	1	0	0	0			

2.3.2. Diseño del experimento con APRBS para la obtención de modelos lineales

En la señal APRBS (figura 2.8) se modula la frecuencia de excitación y la amplitud, aunque cubre un rango de frecuencias mayor que la SBPA, pues existen más parámetros como el rango y la distribución de amplitudes de la señal de entrada.

En este caso al diseño clásico de una SBPA, según el criterio ofrecido por [106], se añadió un generador de números aleatorios para seleccionar valores de amplitud de entrada en el rango de u_{\min} a u_{\max} . Aunque la distribución de amplitudes y frecuencias de la señal de prueba resultante no está igualmente distribuida sobre el rango completo de operación, no representa un problema para una secuencia de prueba de longitud suficiente.

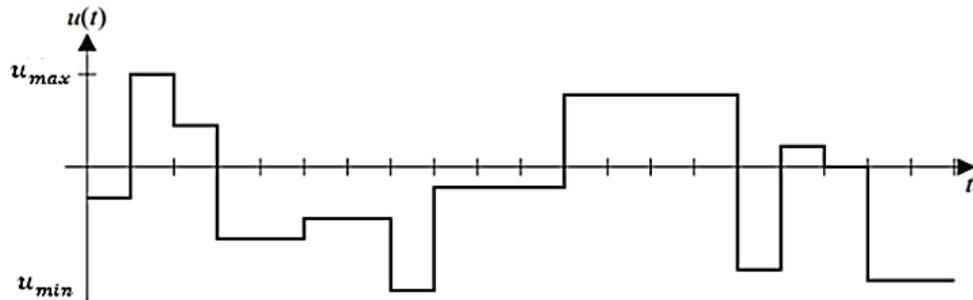


Figura 2.8 Señal binaria pseudoaleatoria de amplitud modulada Fuente: [107]

Para los experimentos con APRBS, en el flujo de aire se generó una SBPA de quinto orden con un período de conmutación de 60 s, escogido a partir de las curvas de reacción de TH4 y TH6 y se tomó un período de muestreo de 3 s. Luego se generó una secuencia de valores aleatorios con la ayuda del comando *rand* del MATLAB®, en el rango de amplitud de las aperturas de las válvulas de H4 y H6, que se añadieron a los estados de la SBPA antes generada. Esta amplitud se tomó con el intervalo típico en que operan las válvulas. En estas consideraciones se obtuvo una señal modulada con amplitud y frecuencia.

Para los experimentos del Fm se generó una SBPA de tercer orden, con un período de conmutación de 300 s, de manera similar al caso anterior. Luego se generó una secuencia de valores aleatorios en el rango de amplitud en que opera el dispositivo de pesaje, que se añadieron a los estados de la SBPA antes generada. Esta amplitud se tomó por el intervalo típico de la carga del horno.

Para tener acceso a los datos de entrada (A_{pH4} , A_{pH6}) se modificó el CITECT, pues ambas variables no eran monitoreadas de manera continua.

2.3.3. Implementación de las señales binarias en el sistema de supervisión y control

Antes de iniciar esta investigación, los lazos de control de TH4 y TH6 del horno utilizaban reguladores autónomos (SIPART DR-20), que recibían las señales procedentes de los termopares y actuaban sobre los posicionadores (PS1) de las válvulas de mariposa, todo a través del PLC S5 [108].

Por consiguiente, se eliminaron los reguladores autónomos y se hicieron conexiones a tres hilos entre el PLC y los posicionadores de las válvulas, para actuar directamente sobre estos desde el autómatas.

Luego se elaboró un programa en el PLC que funciona con el uso de dos temporizadores: uno para el pulso alto y el otro para el pulso bajo. La base de tiempo del primer pulso se introduce a través del SCADA (figura 2.9) y a partir de ahí se recalculan los restantes. En el tiempo de cada pulso “Duración Amp”, se escribe en la salida el último valor del porcentaje de apertura de la válvula asignado manualmente en el SCADA, sumado o restado del valor de apertura existente en ese momento.

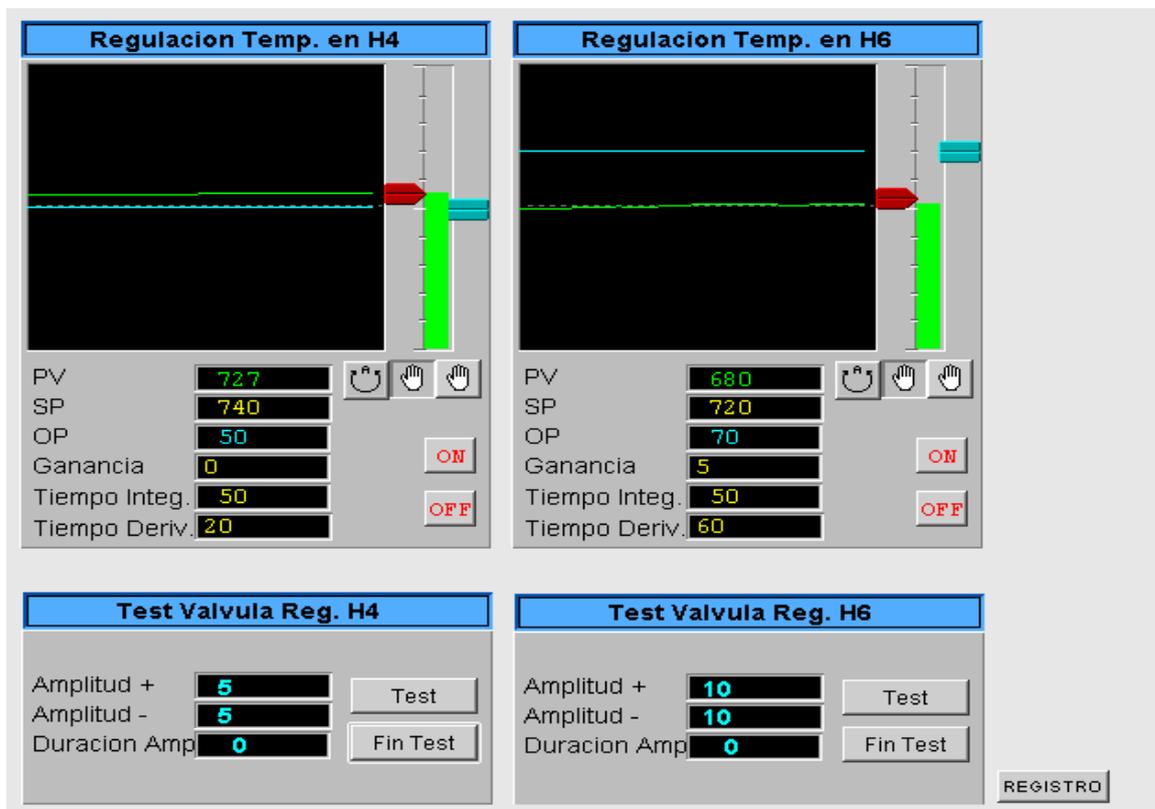


Figura 2.9 Pantalla del SCADA CITECT para configurar y manipular la secuencia de pulsos

En la pantalla se ajustan los parámetros necesarios para la manipulación de los pulsos que son:

- Amplitud +: es el valor del “1” en la secuencia.
- Amplitud -: es el valor del “0” en la secuencia.
- Duración Amp: duración del primer pulso a partir del cual se calcula la duración de los otros pulsos.
- Test: botón para iniciar la secuencia de pulsos.
- Fin Test: botón para finalizar la secuencia de pulsos.

La implementación de las señales descritas anteriormente se complementa con métodos matemáticos para ajustar los parámetros de una estructura a un conjunto de datos de entrada-salida.

2.4. Métodos de identificación de sistemas

Algunos de los métodos más utilizados en el campo de la identificación son Variables Instrumentales y Mínimos Cuadrados [109], los cuales permiten la estimación de los parámetros del modelo.

2.4.1. Método de Mínimos Cuadrados

El principio de los Mínimos Cuadrados indica que los parámetros de un modelo se deben elegir de tal forma que la suma de los cuadrados de las diferencias entre los valores de la salida observada (reales) y los estimados, multiplicada por factores que midan el grado de precisión, alcance un mínimo [103].

Al considerar un modelo genérico:

$$G(z) = \frac{b_0 + b_1 z^{-1} + \dots + b_m z^{-m}}{a_0 + a_1 z^{-1} + \dots + a_n z^{-n}} * z^{-d} \quad (2.9)$$

la identificación se realiza mediante la estimación de los parámetros desconocidos $[a_0, a_1, \dots, a_n, b_0, b_1, \dots, b_m]$ y d es el retardo del sistema. Para ello se procede como se expone: dados los $k+1$ valores de la entrada y los k de la salida, la salida estimada, $\hat{y}(k+1)$ será:

$$\hat{y}(k+1) = x_{k+1}^t \theta \quad (2.10)$$

donde:

$$\theta = [a_0, a_1, \dots, a_n, b_0, b_1, \dots, b_m] \quad (2.11)$$

$$x_{k+1} = [-y(k), -y(k-1), \dots, -y(k-n+1), u(k+1-d), u(k-d), \dots, u(k-m+1-d)] \quad (2.12)$$

La discrepancia entre la salida real y la estimada viene dada por la siguiente expresión de error:

$$e(k+1) = y(k+1) - \hat{y}(k+1) \quad (2.13)$$

Al repetir este planteamiento para N medidas sucesivas, las salidas correspondientes a esos N instantes se pueden expresar mediante la ecuación matricial (2.14).

$$\begin{pmatrix} y(k+1) \\ y(k+2) \\ \vdots \\ y(k+N) \end{pmatrix} = \begin{bmatrix} -y(k) & -y(k-1) & u(k+1-d) & u(k-d) \\ -y(k+1) & -y(k) & u(k+2-d) & u(k+1-d) \\ \vdots & \vdots & \vdots & \vdots \\ -y(k+N-1) & -y(k+N-2) & u(k+N-d) & u(k+N-1-d) \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ b_0 \\ b_1 \end{bmatrix} \quad (2.14)$$

La ecuación $Y = X\theta$ presenta infinitas soluciones y se tomará la que minimice el error con el método de Mínimos Cuadrados. En otras palabras, el estimador de mínimos cuadrados será el que proporcione los parámetros que minimizan la suma de los cuadrados de los errores J_k .

$$J_k = \frac{1}{2} \sum_{i=K+1}^{K+N} e^2(i) \quad (2.15)$$

Los parámetros que minimizan el error se obtienen al resolver el siguiente producto matricial:

$$\hat{\theta} = (X^T X)^{-1} (X^T Y) \quad (2.16)$$

La matriz $(X^T X)$ es cuadrada, y en determinadas condiciones, que se denominan de excitación permanente, tiene inversa [54]. Para la técnica de identificación de excitación con señales típicas de prueba en la variable de entrada, las entradas usuales como escalón o impulso no provocan una excitación permanente, por tanto, en ese caso no se garantiza que la matriz $(X^T X)$ tenga inversa [103].

En la actualidad el desarrollo de ciencias computacionales ha permitido crear herramientas de software para la identificación de sistemas, como el MATLAB®, para procesar modelos no paramétricos y paramétricos como ARX, BJ, ARMAX, OE, análisis de correlación, estimación directa de respuesta a impulso, entre otros.

2.5. Modelo lineal general

Un modelo lineal general de un sistema puede ser descrito según la figura 2.10. La salida medida $y(t)$ se debe a la entrada $u(t)$ y al ruido $e(t)$. G denota las propiedades dinámicas del sistema, es decir, cómo la salida se forma desde la entrada. Para sistemas lineales se llama función de transferencia entre la entrada y la salida. H refiere las propiedades del ruido y se le llama también modelo del ruido, y describe cómo está formada la perturbación en la salida [110].

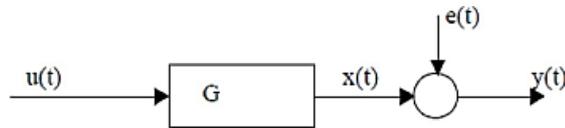


Figura 2.10 Esquema de un modelo lineal Fuente: [110]

donde:

$$y(t) = Gu(t) + He(t) \quad (2.17)$$

La estructura de un modelo lineal es:

$$A(q)y(t) = \left(\frac{B(q)}{F(q)} \right) u(t) \pm \left(\frac{C(q)}{D(q)} \right) e(t) \quad (2.18)$$

donde A, B, C, D y F son polinomios en el operador de retraso q^{-1}

$$A(q) = 1 + a_1 q^{-1} + \dots + a_{na} q^{-na} \quad (2.19)$$

$$B(q) = 1 + b_1 q^{-1} + \dots + b_{nb} q^{-nb} \quad (2.20)$$

$$C(q) = 1 + c_1 q^{-1} + \dots + c_{nc} q^{-nc} \quad (2.21)$$

$$D(q) = 1 + d_1 q^{-1} + \dots + d_{nd} q^{-nd} \quad (2.22)$$

$$F(q) = 1 + f_1 q^{-1} + \dots + f_{nf} q^{-nf} \quad (2.23)$$

Los términos na , nb , nc , nd y nf representan los órdenes de los polinomios, mientras que a , b , c , d y f son los coeficientes de la función de transferencia discreta G , según Mínimos Cuadrados y Variable Instrumental.

Los modelos paramétricos con estructuras AR, ARX, ARMAX, OE y BJ son casos particulares de la estructura general y se obtienen según corresponda.

La estructura AR corresponde con $nb=nf=nc=nd=0$ y además $u(t)=0$,

la estructura ARX corresponde con $nf=nc=nd=0$,

la estructura ARMAX corresponde con $nf=nd=0$,

la estructura OE corresponde con $na=nc=nd=0$,

la estructura BJ corresponde a $na=0$.

2.6. Modelación con redes neuronales artificiales

Para la obtención de los modelos no lineales se utilizaron las RNA y se tuvieron en cuenta aspectos como su arquitectura, entrenamiento y validación, estimación insesgada de la precisión del modelo y la selección del mejor modelo candidato como resultado del proceso de prueba y error.

Las RNA son un conjunto de varias unidades de procesamiento simple llamadas neuronas que se interconectan entre sí, y producen una secuencia de activaciones. Las neuronas de entrada, y ocultas, son activadas a través de sensores que perciben el entorno y conexiones ponderadas de las neuronas previamente activas, respectivamente. Las neuronas de salida pueden influir en el entorno disparando determinadas acciones. Una neurona es una unidad computacional genérica que toma n entradas y produce una salida única. En la figura 2.11 se muestra una neurona con tres entradas x_1, x_2, x_3 y una salida y . Cada nodo o unidad (neurona artificial), se conecta a otras unidades a través de arcos dirigidos (modela la conexión axón \rightarrow dendritas).

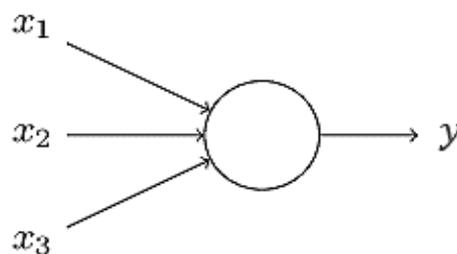


Figura 2.11 Neurona con tres entradas

Una RNA combina muchas neuronas simples de tal manera que la salida de una neurona puede ser la entrada de otras. En la figura 2.12 se muestra un ejemplo de RNA. Cada neurona es representada por un círculo. La capa de neuronas que se encuentran más a la izquierda es denominada la capa de entrada, obviamente esta capa está conformada por las neuronas de entrada. La capa más a la derecha se denomina, por razones análogas, la capa de salida. La capa media es llamada capa oculta.

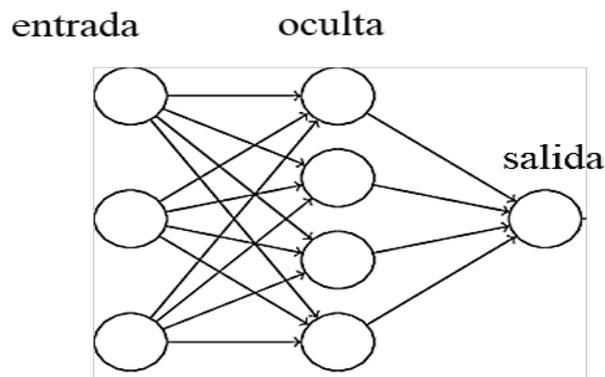


Figura 2.12 Representación esquemática de una RNA simple con una sola salida

2.6.1. Teoría de los modelos NARX

La RNA NARX es una técnica de modelado de series de tiempo que relaciona el valor actual de una serie de tiempo con sus valores pasados y los valores actuales y pasados de otras series de tiempo de entradas exógenas [111]. Esta característica de las redes NARX, que acepta variables dinámicas de diferentes conjuntos de series de tiempo, las hace superior a otras redes que utilizan la retropropagación a través del tiempo (BPTT) [112]. Las RNA recurrentes, incluyendo NARX, son de naturaleza cíclica. Las conexiones de retardo de tiempo, que transfieren valores entre activaciones sucesivas, forman los ciclos que incluyen las entradas exógenas y entradas endógenas [113]. Las RNA NARX realizan este procedimiento a través del aprendizaje autónomo [114] y crean interconexiones complejas entre las variables exógenas, que las convierte en un enfoque confiable para el análisis de pronóstico de series temporales [115].

La técnica NARX se define según la siguiente ecuación:

$$y(t+n) = f(y(t+1), \dots, y(t+n-1), x(t-l+1), \dots, x(t-l+n-1)) + e \quad (2.24)$$

donde n es el paso de tiempo discreto, $y(t+n)$ es el valor predicho, $f(\cdot)$ es la función de mapeo de la RNA, $y(t+1), \dots, y(t+n-1)$ son los valores pronosticados en el pasado, l es el número de retrasos, $x(t-l+1), \dots, x(t-l+n-1)$ son los valores pasados para las variables exógenas (incluye l número de retrasos), y e es el término de error. La variable $y(t)$ se define en (2.24), donde φ es la función de activación de la capa oculta, β_{ji} y γ_{ji} son los pesos de entrada de la capa oculta en la neurona j , α_i son los pesos de salida de la capa oculta y k es el número de nodos de entrada.

$$y(t) = \sum_i \alpha_i \varphi \left(\sum_{j=1}^k (\beta_{ji} x_{t-j} + \gamma_{ji} y_{t-1}) \right) \quad (2.25)$$

En la técnica NARX, se utiliza un perceptrón multicapa recurrente (RMLP) para estimar la función de mapeo de $f(\cdot)$, que consta de capas de entrada, capas ocultas y capas de salida. RMLP también incluye neuronas, funciones de activación y pesos. Dentro de la capa oculta, las funciones de la RNA se operan a través de las neuronas interiores. Las neuronas multiplican los vectores de entrada de las capas anteriores por los vectores de peso y proporcionan la salida escalar. Posteriormente, la función de activación mapea cada capa de salida para generar la salida de la neurona que se reenviará a la siguiente capa. En otras palabras, para calcular la salida, la suma ponderada de las entradas se aplica a la función de activación. Cuando finaliza la mejora de la generalización (en el período de entrenamiento) y los cambios en los valores de error cuadrático medio (MSE) se estabilizan, el proceso de entrenamiento se detiene automáticamente [116]. MSE es un criterio de evaluación de rendimiento crucial que ayuda a determinar los hiperparámetros iniciales óptimos para la RNA.

El MSE se puede obtener de acuerdo con la ecuación:

$$MSE = \frac{SSE}{df} \quad (2.26)$$

donde SSE es la suma de los errores cuadráticos y df es el grado de libertad. Obviamente, el valor MSE más bajo para los modelos de RNA conduce al modelo óptimo. Después de ajustar el primer modelo a través de la arquitectura en serie-paralelo, se pueden pronosticar más pasos de tiempo en

una arquitectura en paralelo de lazo cerrado, donde cada salida predicha (en el paso anterior) se alimenta al modelo para predecir una salida futura.

En NARX, el número de capas ocultas, retrasos y neuronas, como los principales hiperparámetros, influyen en la precisión de los resultados. Es ideal considerar todos los hiperparámetros al mismo tiempo; sin embargo, aumenta el tiempo de proceso [117].

2.7. Método de validación cruzada aleatoria con retención repetida

La validación cruzada se utiliza en entornos donde el objetivo principal es estimar la precisión de un modelo que se llevará a cabo a la práctica [118]. Es una técnica muy utilizada en proyectos de inteligencia artificial para validar modelos generados.

Este método crea múltiples divisiones aleatorias del conjunto de datos inicial en datos de entrenamiento, validación, y prueba, lo que garantiza una estimación menos sesgada de la precisión que el modelo obtendría ante nuevos datos (figura 2.13).

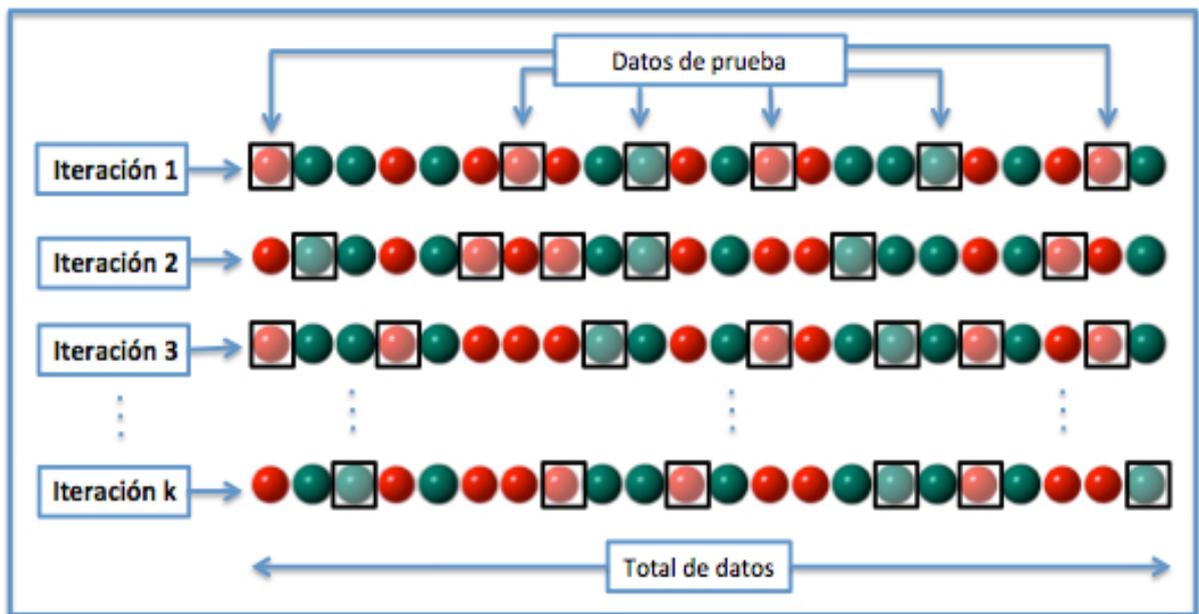


Figura 2.13 División del conjunto de datos aleatoriamente

Fuente: https://commons.wikimedia.org/wiki/File:Random_cross_validation.jpg

Para cada división, el modelo se ajusta a los datos de entrenamiento y la precisión predictiva se evalúa utilizando los datos de prueba. La precisión que se le atribuirá al modelo será la media

aritmética de los valores obtenidos para las diferentes divisiones. Esto garantiza una evaluación insesgada de la precisión del modelo [119].

2.8. Criterios de evaluación de modelos de predicción

Al comparar varios modelos predictivos, por lo general, existe una compensación entre la bondad del ajuste y la parsimonia [120]: los modelos de baja parsimonia (es decir, modelos con muchos parámetros) tienden a tener mejor ajuste que los modelos de alta parsimonia. Esto no suele ser bueno; agregar más parámetros generalmente da como resultado un buen ajuste del modelo para los datos disponibles, pero es probable que ese mismo modelo sea inútil para predecir otros conjuntos de datos. Encontrar el equilibrio adecuado entre parsimonia y bondad de ajuste puede ser un desafío. Los criterios de información de Akaike (AIC) y Bayesiano o Schwarz (BIC) comparan la calidad de un conjunto de modelos. AIC y BIC se pueden calcular como [121, 122]:

$$AIC(k) = -2 \ln(L) + 2k \quad (2.27)$$

$$BIC(k) = -2 \ln(L) + k \ln(N) \quad (2.28)$$

donde k es el número de parámetros ajustados en el modelo, L el valor máximo de la función de verosimilitud del mismo, y N es el tamaño de la muestra. Para el análisis de regresión basado en mínimos cuadrados, AIC y BIC se pueden calcular con el MSE [123]:

$$AIC(k) = N \ln(MSE(k)) + 2k \quad (2.29)$$

$$BIC(k) = N \ln(MSE(k)) + k \ln(N) \quad (2.30)$$

donde $MSE(k)$ es el error cuadrático medio del modelo candidato.

Se puede notar que cada criterio contiene dos componentes: el primero mide el error de predicción, que indica qué tan bien se ajusta el modelo a los datos y el segundo es la función de costo, para penalizar el modelo cuando se le agregan más parámetros. Por tanto, existe una compensación entre el mejor ajuste y la complejidad del modelo. En general, el valor del criterio disminuye cuando se

incluyen unos primeros parámetros en el modelo, debido a la reducción del error de predicción. Cuando se incluye una cantidad suficiente de parámetros, el componente de penalización se vuelve significativo, lo que lleva a un mayor valor. El modelo con valores mínimos de AIC y BIC se trata como una opción óptima de rendimiento de predicción y una representación parsimoniosa del sistema [124]. En la tabla 2.6 se muestra un resumen de las ventajas y limitaciones reportadas del AIC/BIC.

Tabla 2.6 Ventaja y limitación de los criterios AIC y BIC. Fuente: [124]

Criterio	Ventaja	Limitación
AIC	Minimiza la función de riesgo útil cuando el modelo verdadero no es un candidato y el modelo es complejo.	El modelo no funciona bien para datos fuera de la muestra y suele ser más complicado.
BIC	Es consistente en la selección del modelo verdadero cuando el modelo es un candidato. El modelo tiene un mejor rendimiento fuera de la muestra.	No es consistente cuando el modelo es demasiado complejo o la incertidumbre es demasiado fuerte.

2.9. Diseño del experimento para la obtención del modelo NARX SISO

El empleo de la RNA se justifica porque la estructura de múltiples variables no permite evaluar un solo proceso estocástico de temperaturas en todo el horno, sino que existen series de tiempo específicas en las diferentes cámaras y hogares, lo cual impide encontrar una tendencia general. El tiempo de retención del mineral en el horno es de 2 700 s aproximadamente, y debe cumplirse en condiciones normales. Las RNA pueden aprender de los patrones ocultos en esas variables y ajustar los comportamientos estacionarios.

Se seleccionaron las variables ApH4, TH4, ApH6, TH6, que pertenecen a los tres meses de 2015 para estimar dos modelos RNA SISO. Luego, este modelo fue validado con las mismas variables correspondientes a los cuatro meses de 2018 [11].

La selección adecuada del número de capas y las neuronas en cada capa tiene un efecto mayor en el rendimiento de la red que el efecto de la función de transferencia y entrenamiento [125]. En este estudio, el número de neuronas en la capa oculta se eligió por prueba y error.

En concreto, se tomó una arquitectura de red totalmente conectada con tres regresores como entradas, función de activación tangente hiperbólica en la capa oculta y una neurona con función de activación lineal como salida. Se utilizó el algoritmo de entrenamiento Levenberg-Marquardt [106], que implica bajos errores de predicción en la etapa de entrenamiento y estos tienden a aumentar en la validación; por ello, la obtención de un buen modelo depende principalmente del comportamiento de los errores de predicción de estos nuevos datos. En este paso se prueba lo aprendido por la red. La red obtenida se valida primeramente para los datos de entrenamiento y luego para los de validación.

El toolbox de RNA desarrollado por Nørgaard [126], proporciona cinco estructuras de modelos: NNARX “no lineal autorregresivo exógeno”, NNOE “no lineal con error de salida”, NNARMAX1 “no lineal con media móvil autorregresiva exógena (filtro de ruido lineal)”, NNARMAX2 “no lineal con media móvil autorregresiva exógena”, NNSSIF “no lineal en espacio de estado”. En este caso, se seleccionó el modelo NNARX porque la regla básica que ofrece el autor en el manual es utilizarlo siempre que sea posible, pues solo este tiene un predictor sin realimentación; los otros tienen realimentación a través de los regresores que en la terminología de la red significa que la red se convierte en recurrente y, por consiguiente, puede conducir a la inestabilidad en ciertos rangos de operación.

El modelo NNARX utilizado se muestra en la figura 2.14, donde $x(t)$ es la entrada, $y(t)$ es la salida de la red un paso adelante. La estructura regresiva $[n_a n_b n_k]$ fue 221, donde n_a es el número de salidas

pasadas, n_b es el número de entradas pasadas, y n_k es el retardo de tiempo del sistema. Aunque se realizaron 30 pruebas, los mejores resultados se obtuvieron con esta estructura. En el anexo 8 se muestra el código en MATLAB® para la obtención del modelo dinámico SISO.

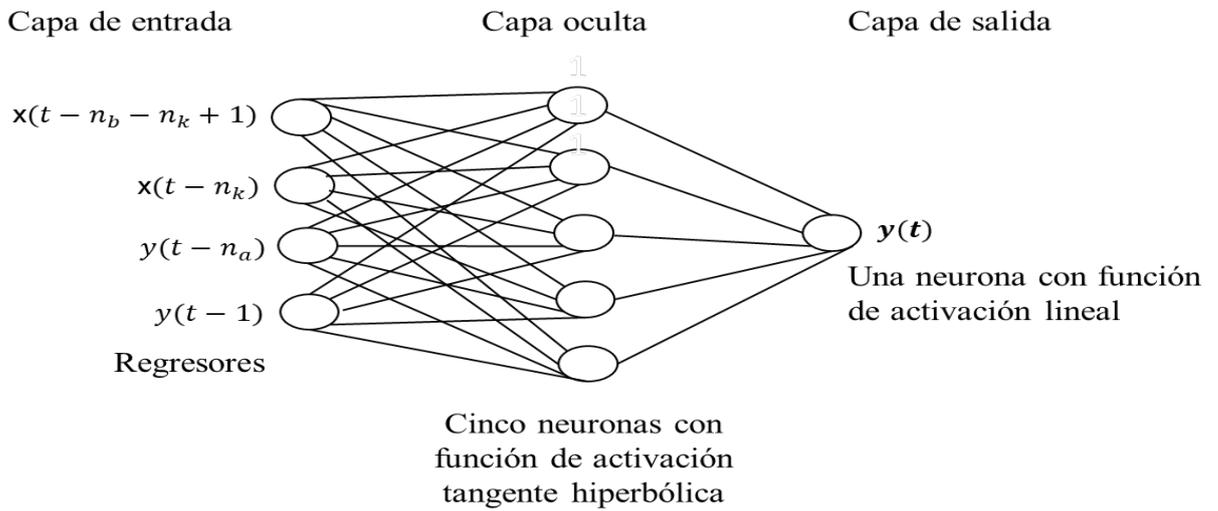


Figura 2.14. Arquitectura de la RNA

2.10. Diseño del experimento para la obtención del modelo NARX MIMO

Fueron elegidas en este estudio tres capas para el modelo NARX: capa de entrada, capa oculta y capa de salida (figura 2.15). En la capa de entrada hay dos neuronas que representan las dos variables de entrada (ApH4, ApH6). Se implementaron cinco retrasos en la capa oculta, de acuerdo con la identificación de las constantes de tiempo predominantes de 600 s para los dos hogares de postcombustión (ver epígrafe 3.3) y al considerar que los datos históricos se recolectan con un período de muestreo de 120 s. El número de neuronas en la capa oculta fue variado de 1 hasta 30 con función de activación (tangente hiperbólica) y dos neuronas con función de activación lineal en la capa de salida que representan a las variables de salida TH4 y TH6.

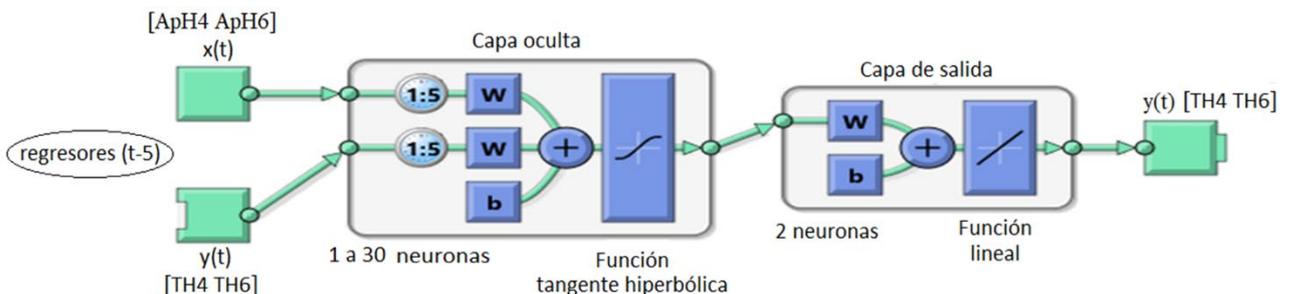


Figura 2.15. Modelo NARX para el subproceso de postcombustión del horno

Los datos de entrada-salida correspondientes a los tres meses de 2015 son presentados al modelo NARX en matriz $2 \times 64 \times 146$ cada uno, un sistema 2×2 . El conjunto de datos se divide aleatoriamente en 3 partes: 70 % para entrenamiento, 15 % para validación y 15 % para prueba. El número de repeticiones escogido para la aplicación de esta técnica fue $k=16$, lo que garantizó que la probabilidad de que un dato se escogiera al menos una vez en el conjunto de prueba fuera mayor que 0,90 y prácticamente el 95 % [127]. Para cada división se entrenó el modelo y se promediaron los RMSE. De esta forma se obtuvo el RMSE promedio para una cantidad específica de neuronas en la capa oculta. Luego este proceso se repitió con diferente número de neuronas en la capa oculta para seleccionar el modelo con mejores resultados [12]. La selección se hace a partir del modelo con menores valores de AIC y BIC. En la figura 2.16 se muestra un algoritmo para el procesamiento del modelo NARX MIMO y en el anexo 9 se muestra el código en MATLAB®.

Para $i = 1$ hasta 30 \rightarrow Variar el número de neuronas en la capa oculta de la RNA.

Repetir $j = 1$ hasta 16 \rightarrow Número de repeticiones en cada cantidad de neuronas.

De los 64 146 datos, dividir aleatoriamente tres subconjuntos.

$\left\{ \begin{array}{l} 70 \% \text{ "Entrenamiento"} \\ 15 \% \text{ "Validación"} \\ 15 \% \text{ "Prueba"} \end{array} \right.$

Modelar y simular la RNA

$RMSE_{ij} \rightarrow$ Con los datos de Prueba, calcular los 16 errores cuadráticos medios en cada número de neuronas.

$\overline{RMSE}_i^{(j)} \rightarrow$ Calcular para cada i el promedio en j de los 16 errores cuadráticos medios por cada número de neuronas.

$AIC(i)_j$ y $BIC(i)_j \rightarrow$ Calcular los criterios de información AIC y BIC para seleccionar el mejor conjunto de modelos.

$RMSE = \min_{ij} \{ \overline{RMSE}_i^{(j)} \} \rightarrow$ Guardar la estructura de neuronas con el menor promedio de error cuadrático medio.

$AIC = \min_{ij} \{ AIC(i)_j \} \rightarrow$ Guardar la estructura de neuronas con el menor AIC.

$BIC = \min_{ij} \{ BIC(i)_j \} \rightarrow$ Guardar la estructura de neuronas con el menor BIC.

Figura 2.16. Algoritmo para el entrenamiento del modelo NARX MIMO

Para la generalización del modelo NARX se utilizó un conjunto de datos de años diferentes que no participó en el entrenamiento del modelo y se diseñó el experimento numérico al dividirlo en 20 subconjuntos, los 10 primeros abarcan 80 567 datos del 2018, y los restantes comprenden 65 313 datos del 2022. Los subconjuntos están conectados, temporalmente, uno tras otro. Luego se calculó el RMSE para cada subconjunto a partir del modelo identificado con los datos del 2015. El horizonte de predicción empleado es de un paso adelante (120 s) [12].

Durante la experimentación pasiva, las perturbaciones descritas en la figura 2.5 pudieron haber tenido influencia en el desarrollo del subproceso de postcombustión. Sin embargo, al no poder controlarlas directamente, se tienen en cuenta durante la validación del modelo porque pasan a formar parte del RMSE.

Conclusiones parciales

1. La metodología propuesta para la modelación matemática engloba un análisis estadístico de las principales variables del subproceso de postcombustión del horno, el empleo de señales binarias pseudoaleatorias para el diseño de experimentos, métodos matemáticos, técnicas de validación y criterios de evaluación de modelos.
2. Para la identificación del subproceso de postcombustión se pueden utilizar dos tipos de modelos:
 - Modelos lineales paramétricos, que no requieren avanzados recursos computacionales, abarcan diferentes puntos de operación del proceso y pueden ser empleados en estrategias de control multivariable que se insertan en los PLC de la industria.
 - Modelos no lineales basados en RNA, con menores errores de predicción, requieren una mayor potencia de cálculo y se emplean en estrategias de control inteligente.
3. La configuración de la interfaz para monitorear las variables de interés de la postcombustión y la existencia de chips neuronales en los PLC, permiten la implementación práctica de la modelación matemática en el sistema de supervisión y control (CITECT) de la Unidad Básica de Producción Planta Hornos de Reducción.

3. MODELACIÓN MATEMÁTICA DEL SUBPROCESO DE POSTCOMBUSTIÓN DEL HORNO DE REDUCCIÓN DE MINERALES LATERÍTICOS

La modelación en el área de procesamiento de minerales es una tarea difícil, este tipo de materiales constituye un sistema excepcionalmente complejo comparado con otros materiales que se procesan por las industrias del cemento, el papel o la química pues contiene intrínsecamente una mezcla de menas con propiedades que varían aleatoriamente (granulometría, contenido y asociaciones mineralógicas y distribución de las características superficiales). En el horno objeto de investigación ocurren cambios grandes y rápidos en las condiciones de operación y por tanto se requiere de un modelo matemático para estimar el comportamiento del proceso y la interacción entre las variables.

El capítulo tiene como objetivos: obtener modelos lineales y no lineales basados en inteligencia artificial, para el diseño de estrategias de control automático y realizar la evaluación técnico-económico, ambiental, y social de los resultados.

3.1. Análisis estadístico de los datos

Los resultados del análisis estadístico de la tendencia general del perfil térmico de H4 y H6 durante los tres meses de trabajo de 2015 se presentan en el anexo 5.

Mediante el análisis de regresión paso a paso hacia atrás, se determinaron las variables independientes que más influyen en TH4 y TH6 (ecuaciones (3.1) y (3.2)).

$$TH4 = -145,9 - 0,6 \cdot ApH4 - 0,02 \cdot TH6 - 0,09 \cdot ApH6 - 0,1 \cdot TH7 - 0,01 \cdot TH9 - 0,7 \cdot TH0 + 0,1 \cdot TH13 - 0,9 \cdot TH14 + 1,3 \cdot TH15 + 1,6 \cdot TH2 \quad (3.1)$$

$$TH6 = -61,2 + 0,1 \cdot TC6N + 0,2 \cdot TC6S + 0,4 \cdot TH0 - 0,3 \cdot TH11 + 0,5 \cdot TH13 - 0,7 \cdot TH14 + 0,4 \cdot TH15 - 0,1 \cdot TH2 - 0,1 \cdot TH4 - 0,1 \cdot ApH4 + 1,5 \cdot ApH6 + 0,9 \cdot TH7 - 0,3 \cdot TH9 \quad (3.2)$$

En la tabla 3.1, el estadístico R^2 indica que el modelo (3.1) explica un 0,51 de la variabilidad en TH4, mientras que el modelo (3.2) explica un 0,41 de la variabilidad en TH6. El error estándar de la estimación muestra la desviación típica de los residuos, que es 53,55 para TH4 y 52,79 para TH6.

Tabla 3.1. Resumen del análisis de regresión para TH4 y TH6.

<i>Estadísticas de la regresión</i>	<i>Variabes</i>	
	<i>TH4</i>	<i>TH6</i>
Coefficiente de correlación múltiple	0,71	0,64
Coefficiente de determinación R^2	0,51	0,41
R^2 ajustado	0,51	0,41
Error típico	53,55	52,79

Las tablas 3.2 y 3.3 muestran el análisis de varianza para las variables dependientes TH4 y TH6. Se resalta que los porcentajes son inferiores a 0,05, por lo que existe relación estadísticamente significativa entre las variables para un nivel de confianza del 95 %.

Tabla 3.2. Análisis de varianza para TH4.

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>Grados de Libertad</i>	<i>Cuadrado Medio</i>	<i>Componentes de la Varianza</i>	<i>Porcentaje</i>
Modelo	$1,95714 \cdot 10^8$	10	$1,95714 \cdot 10^7$	6825,50	0,0000
Residuo	$1,839 \cdot 10^8$	64 135	2867,4		

Tabla 3.3. Análisis de varianza para TH6.

<i>Fuente</i>	<i>Suma de Cuadrados</i>	<i>Grados de Libertad</i>	<i>Cuadrado Medio</i>	<i>Componentes de la Varianza</i>	<i>Porcentaje</i>
Modelo	$1,25089 \cdot 10^8$	13	$9,62222 \cdot 10^6$	3452,28	0,0000
Residuo	$1,78749 \cdot 10^8$	64 132	2787,21		

Como resultado del análisis estadístico, de las 22 variables independientes asumidas; se toma en consideración la influencia de 10 variables para TH4 (con un coeficiente de correlación de 0,71) y 13 variables se consideran para TH6 (con un coeficiente de correlación de 0,64). Los valores de los coeficientes de regresión no son muy significativos (0,51 y 0,41) dado que el 49 y 59 % de la variabilidad no pueden ser explicados por los modelos lineales. Esto confirma el hecho de que la relación entre estas variables es no lineal. Por esta razón, se deben obtener modelos lineales en diferentes puntos de operación del proceso, y modelos no lineales que aprendan los patrones ocultos

de las variables y ajusten los comportamientos estacionarios.

3.2. Análisis con series de tiempo descriptivas

En las figuras 3.1 y 3.2 se observan las funciones de autocorrelación (FAC) de la serie de tiempo estocástica univariada y con intervalos de confianza (IC) para TH4 y TH6.

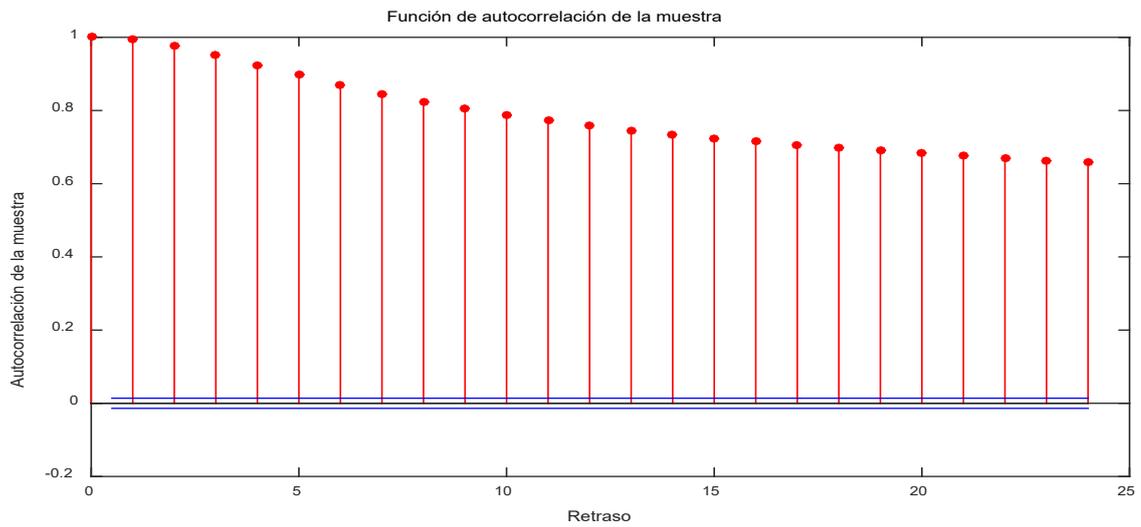


Figura 3.1. Correlograma para TH4 con la función *autocorr*

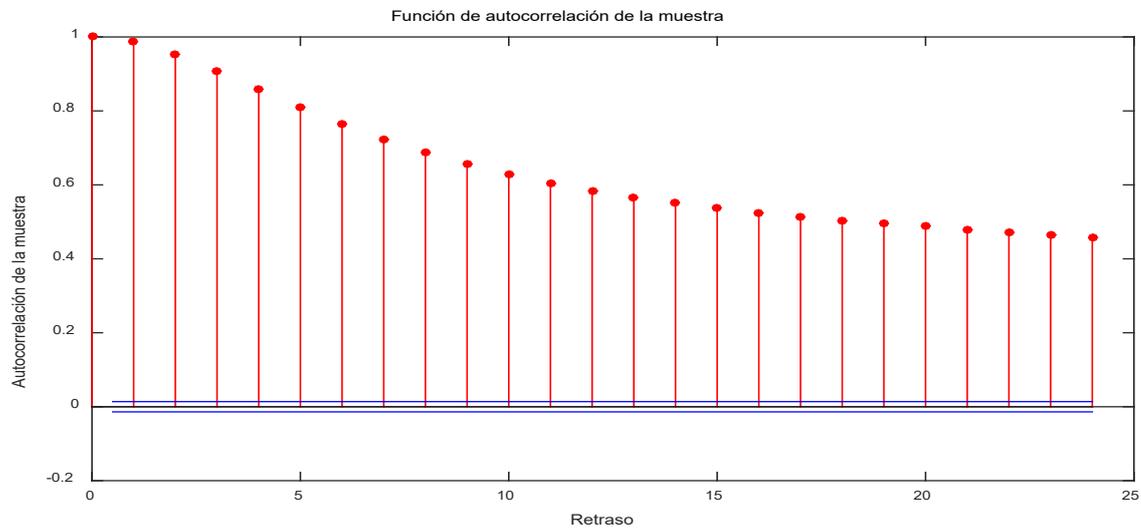


Figura 3.2. Correlograma para TH6 con la función *autocorr*

La FAC en el retraso cero es igual a 1 por defecto (la correlación de una serie de tiempo consigo mismo) y se traza como un punto de referencia. Las líneas azules horizontales son los IC aproximados al 95 %. Hay una alta autocorrelación hasta los primeros 10 retrasos para TH4 y hasta los primeros cinco retrasos para TH6. Cada retraso equivale a 120 s [120]. Ver anexo 5 (tabla IV).

3.3. Experimentos previos con entrada escalón

Prueba A (figura 3.3): se aplicó un escalón positivo (+20 %) a ApH4 que se encontraba inicialmente en un 20 %, ApH6 se mantuvo constante en 60 % y Fm en 20,6 t/h. El valor inicial de TH4 era 700 °C y luego se estableció en 730 °C.

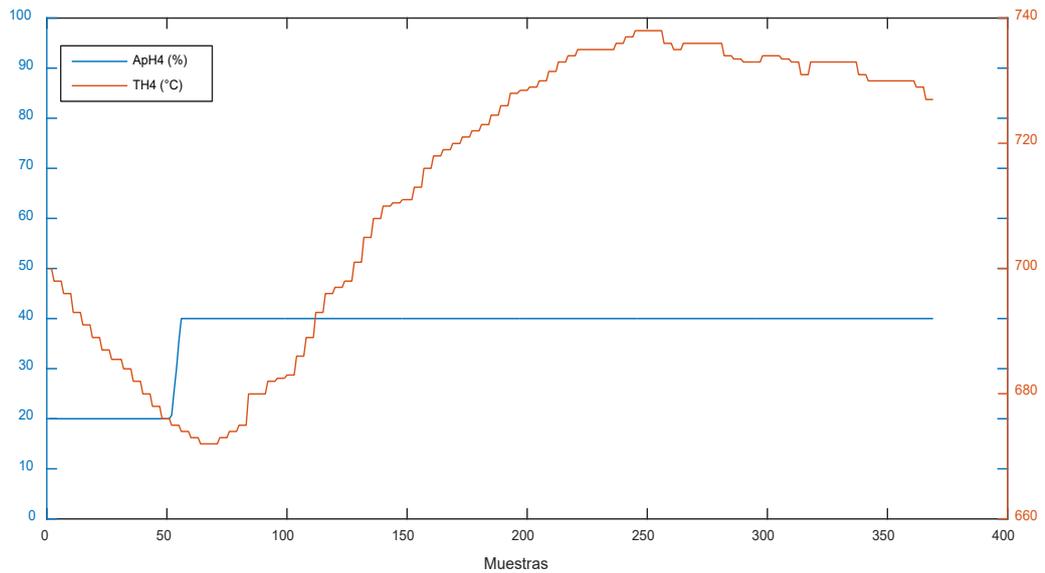


Figura 3.3 Respuesta de TH4 ante un escalón en ApH4

Prueba B (figura 3.4): se aplicó un escalón positivo (+20 %) a ApH6, que se encontraba inicialmente en 60 %, ApH4 se mantuvo constante en 40 % y Fm en 21,4 t/h. TH6 alcanzó el nuevo estado estacionario en 718 °C.

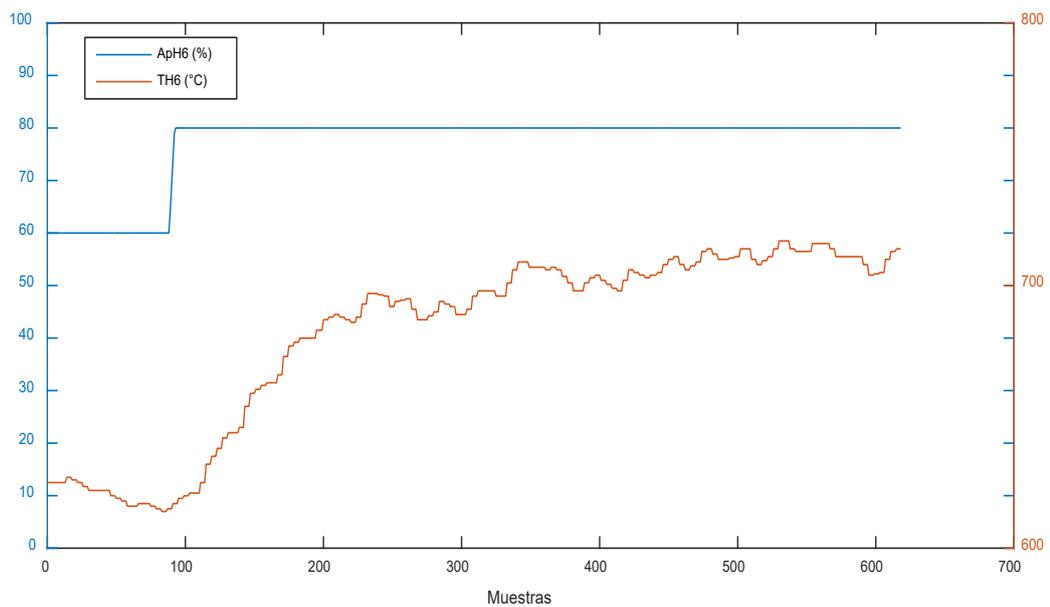


Figura 3.4. Respuesta de TH6 ante un escalón en ApH6

Se tomó el valor de amplitud del 20 % en los escalones de H4 y H6, para que el cambio en la dinámica del proceso fuera notorio y que el sistema no llegara a niveles críticos. Se obtuvo una constante de tiempo de 600 s para H4 y H6, al excitar los valores de ApH4 y ApH6. Al aplicar valores inferiores al 20 % en las aperturas de las válvulas, las variables de interés (TH4 y TH6) no son sensibles [128].

Se realizaron además las pruebas C y D para determinar posibles no linealidades en el proceso.

Prueba C (figura 3.5): para un Fm de 18,2 t/h y ApH6 constante en 25 %, se aplicaron escalones positivos (+20 %) a ApH4 desde 0 hasta 100 %, al dejar transcurrir la constante de tiempo de 600 s en cada porcentaje de apertura de válvula, antes de provocar el siguiente cambio. Se considera que a partir del 40 % de ApH4, TH4 aumenta debido a que la cantidad de aire es suficiente para la postcombustión de los gases, mientras que Fm desciende y arrastra moléculas de oxígeno hacia H6; que reaccionan con los gases reductores y, por consiguiente, aumenta TH6.

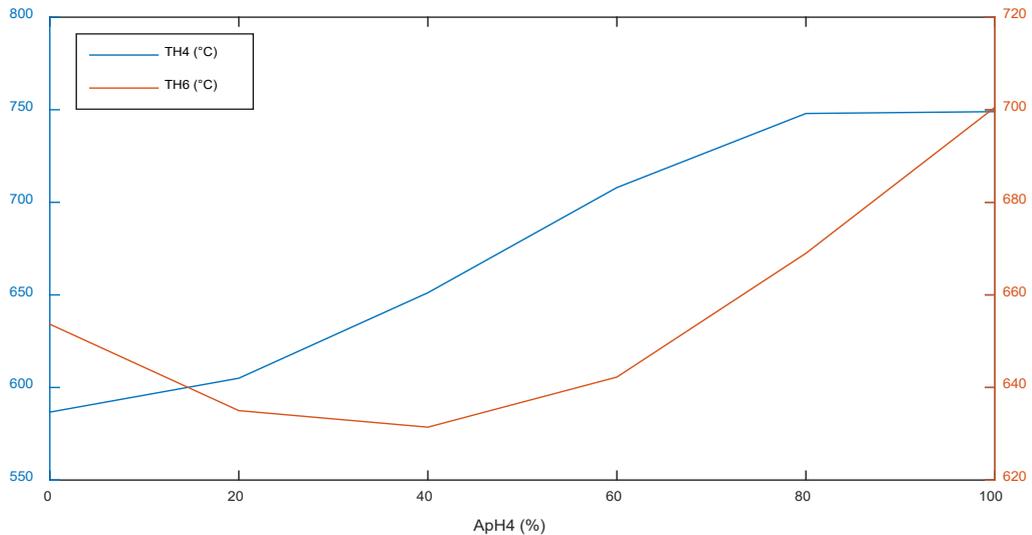


Figura 3.5. Relación entre TH4 y TH6 con ApH4, en estado estacionario

Prueba D (figura 3.6): con un Fm de 18,2 t/h y ApH4 constante en 55 %, se aplicaron escalones positivos (+20 %) a ApH6 desde 0 hasta 90 %, al dejar transcurrir la constante de tiempo de 600 s en cada porcentaje de apertura de válvula alcanzado, antes de provocar el siguiente cambio.

En el rango de 0 a 40 % en ApH6, se considera que la cantidad de aire no es suficiente para la postcombustión de los gases reductores. Este aire se comporta como un aire de dilución (aire

secundario para aumentar el volumen de gases en la cámara de combustión), al tener en cuenta que el vapor de agua y el nitrógeno presente en el aire atmosférico no intervienen en la reacción exotérmica; se absorbe parte del calor liberado en la combustión de H6. A partir del 40 % de apertura, TH6 aumenta porque se quema el CO en este hogar y por tanto se aprecia una disminución de TH4, debido a que la cantidad de gases reductores que llegan a este hogar no es suficiente para la reacción química.

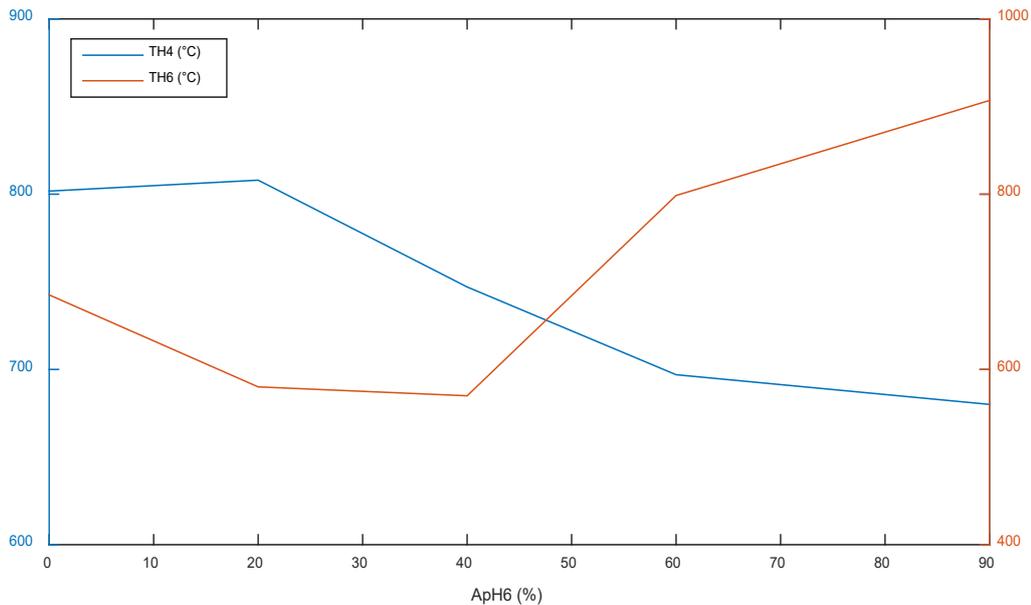


Figura 3.6. Relación entre TH4 y TH6 con ApH6, en estado estacionario

El comportamiento térmico de H4 y H6 como resultado de estas pruebas, refleja características estáticas que han impedido el funcionamiento exitoso de los reguladores PID instalados para el control automático de la temperatura de dichos hogares [8].

3.4. Modelos lineales obtenidos con el empleo de SBPA

Se realizaron 20 experimentos activos en diferentes rangos de operación del proceso. En la tabla 3.4 se muestra un resumen de los seis experimentos que mejor resultados brindaron, para la obtención de los modelos lineales en funciones de transferencia.

Las métricas utilizadas para cuantificar el grado de adecuación de los modelos lineales fueron el RMSE y el índice de ajuste (FIT) que constituye una medida cuantitativa de la calidad del modelo y se obtiene a partir de la norma de los errores residuales entre la salida medida y la salida estimada

por el modelo (donde los valores cercanos al 100 % significan una mejor aproximación y por consiguiente un mejor modelo).

Tabla 3.4. Resumen de los experimentos activos.

Número del experimento	Flujo de mineral (t/h)	Variable manipulada	Rango	Variable controlada	Rango (°C)	RMSE (°C)	FIT (%)
1	21	ApH4	29 - 74 (%)	TH4	757 - 785	21,38	68,68
				TH6	668 - 693	31,12	47,73
2	21,8	ApH6	39 - 90 (%)	TH4	757 - 785	26,27	69,09
				TH6	661 - 741	27,02	69,13
3	19 - 21	Peso descargado por la romana	67 - 132 (kg/h)	TH4	698 - 724	18,82	72,35
				TH6	641 - 690	20,19	70,15
4	18,2	ApH4	12 - 57 (%)	TH4	714 - 975	11,08	83,05
				TH6	752 - 765	0,83	73,21
5	21,8	ApH6	20 - 68 (%)	TH4	676 - 810	3,84	63,43
				TH6	743 - 797	12,82	74,21
6	16 - 19	Fm	16 - 19 (t/h)	TH4	694 - 785	4,65	84,34
				TH6	749 - 786	1,86	80,12

3.4.1. Modelos de TH4 y TH6 versus ApH4

Durante el experimento 1 se tomaron 190 datos correspondientes a las variables TH4, TH6 y ApH4 con un período de muestreo de 10 s, tras aplicarle a esta última una SBPA de orden cinco con dos réplicas. En este caso la apertura experimentó una variación de 29 a 74 % de su recorrido total. El horno se encontraba operando con una carga de 21 t/h y ApH6 se mantuvo constante en 60 %.

En la figura 3.7 y el anexo 6 (figura A.7.1) se observan las mediciones de las variables de entrada y de salida. En la figura 3.8 se muestra la comparación entre la salida real y la salida del modelo, que evidencia la correspondencia entre ellas, y el modelo BJ 22222 (3.3) obtuvo un RMSE de 21,38 °C (FIT = 68,68 %).

$$\frac{TH4(s)}{ApH4(s)} = \frac{0,0013s + 4,25 \times 10^{-5}}{s^2 + 0,01s + 0,0001} e^{-10s} \quad (3.3)$$

En la figura 3.9 se observa que la función de correlación de los residuos se encuentra dentro de los niveles de confianza representados en líneas discontinuas [-0,32 0,32] y, a continuación, aparece la

función de correlación cruzada entre los residuos y la entrada, dentro de los intervalos de confiabilidad $[-0,12 \ 0,12]$, por tanto, es aceptable.

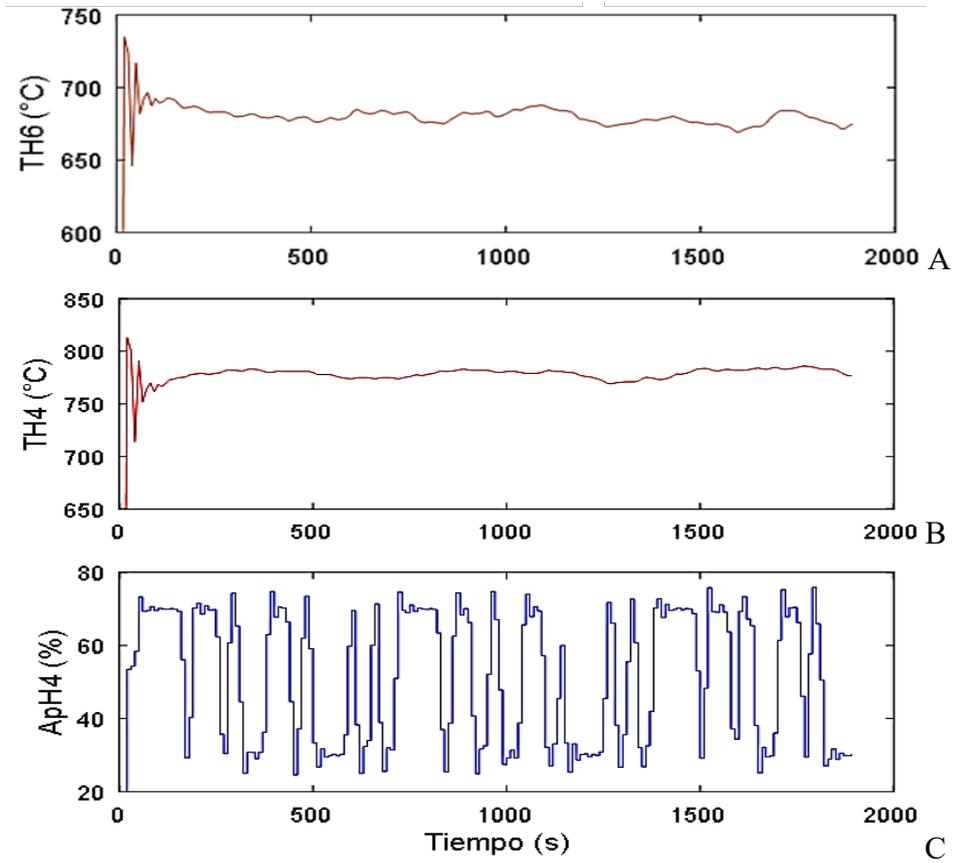


Figura 3.7. Respuesta temporal al variar ApH4 con señal SBPA (A-Salida TH6, B-Salida TH4 y C-Entrada ApH4)

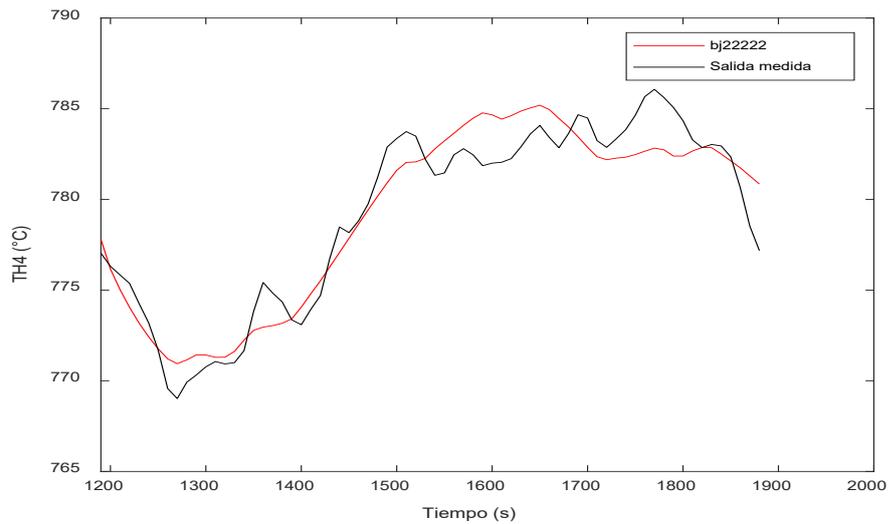


Figura 3.8. Comparación de la salida medida con la salida del modelo (TH4/ApH4)

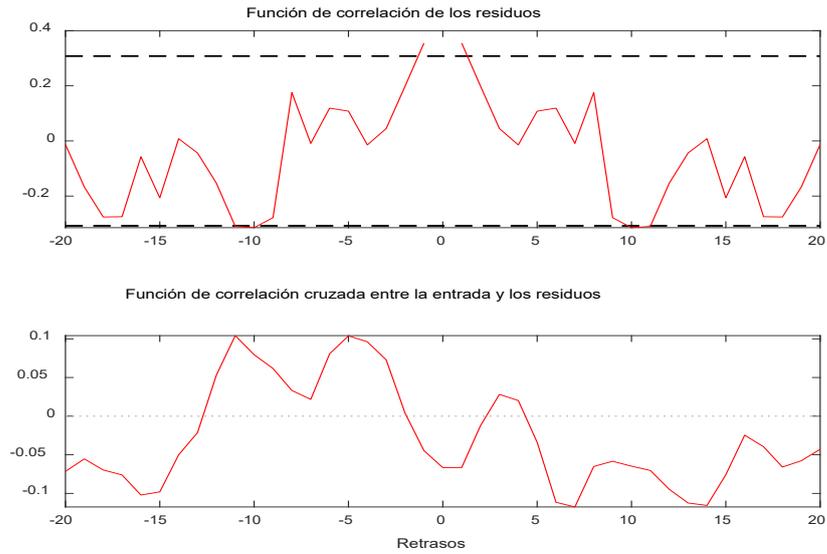


Figura 3.9. Prueba de residuos para el modelo estimado TH4 vs. ApH4

Para TH6 en función de ApH4 se obtuvo como mejor modelo el BJ 22221 (3.4) con un RMSE de 31,12 °C (FIT = 47,73 %). Los resultados de la validación se presentan en la figura 3.10, donde no se aprecia una adecuada correspondencia entre ambas curvas. A su vez, este modelo es inferior al modelo de TH4 (3.3) en cuanto a los criterios de validación.

$$\frac{TH6(s)}{ApH4(s)} = \frac{0,00013s - 4,93 \times 10^{-5}}{s^2 + 0,007s + 0,0002} \quad (3.4)$$

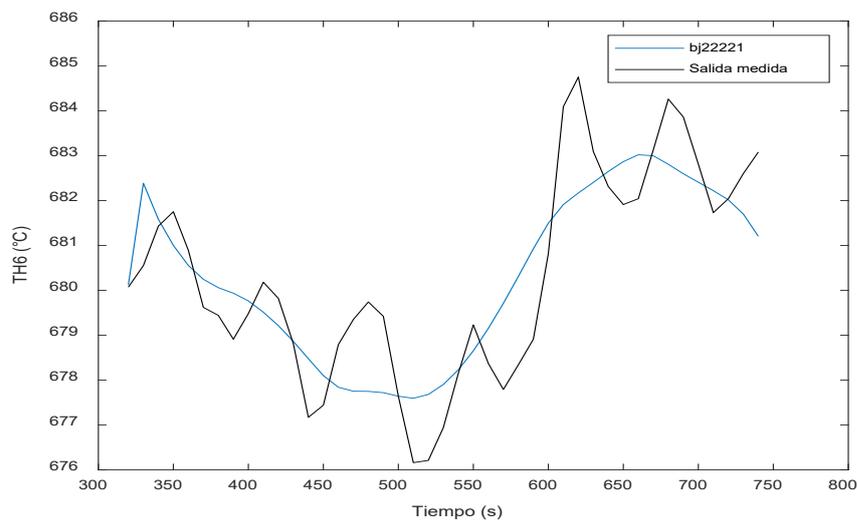


Figura 3.10. Comparación de la salida medida con la salida del modelo (TH6/ApH4)

En la figura 3.11 se muestran los residuos, donde se puede observar que tanto la función de correlación como la de correlación cruzada entre la entrada y los residuos se encuentran dentro de los niveles de confianza.

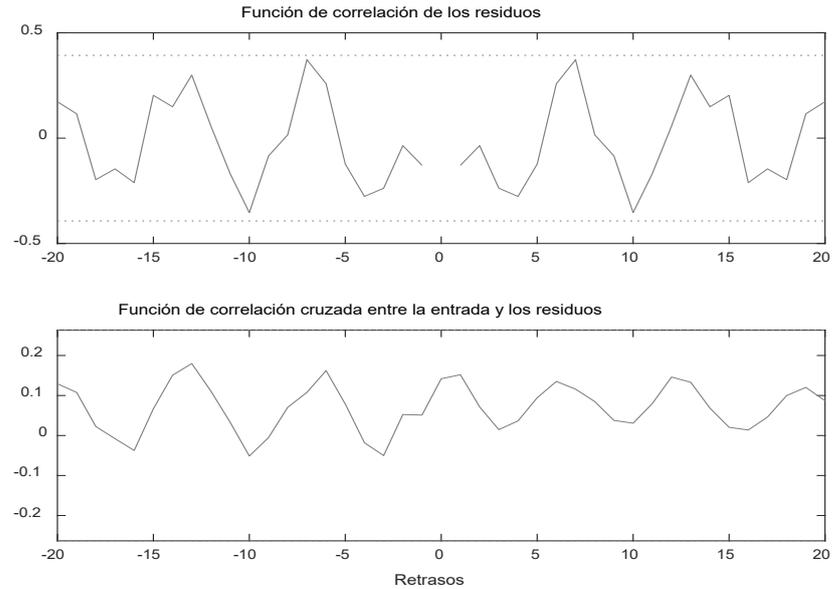


Figura 3.11. Prueba de residuos para el modelo estimado TH6 vs. ApH4

3.4.2. Modelos de TH4 y TH6 versus ApH6

Durante el experimento 2 se tomaron 100 datos correspondientes a las variables TH4, TH6 y ApH6 con un período de muestreo de 10 s, tras aplicarle a esta última una SBPA de orden cinco con una réplica. En este caso la apertura experimentó una variación de 39 a 90 % de su recorrido total. El horno operaba con una carga de 21,8 t/h y la apertura de la válvula en el hogar H4 se mantuvo constante en 40 %. En la figura 3.12 y el anexo 6 (figura A.7.2) se pueden observar las mediciones de las variables de entrada y de salida.

Para TH4 se obtuvo como mejor modelo el ARMAX 3333 de orden 3 con un RMSE de 26,27 °C (FIT = 69,09 %).

$$\frac{TH4(s)}{ApH6(s)} = \frac{0,06s^2 - 0,04s + 0,15}{s^3 + 1,05s^2 + 6,22s + 0,13} e^{-2s} \quad (3.5)$$

Para TH6 se obtuvo un RMSE de 27,02 °C (FIT = 69,13 %) con el modelo ARMAX 2221, el cual es un modelo de orden 2.

$$\frac{TH6(s)}{ApH6(s)} = \frac{-0,02s + 0,02}{s^2 + 0,09s + 0,02} \quad (3.6)$$

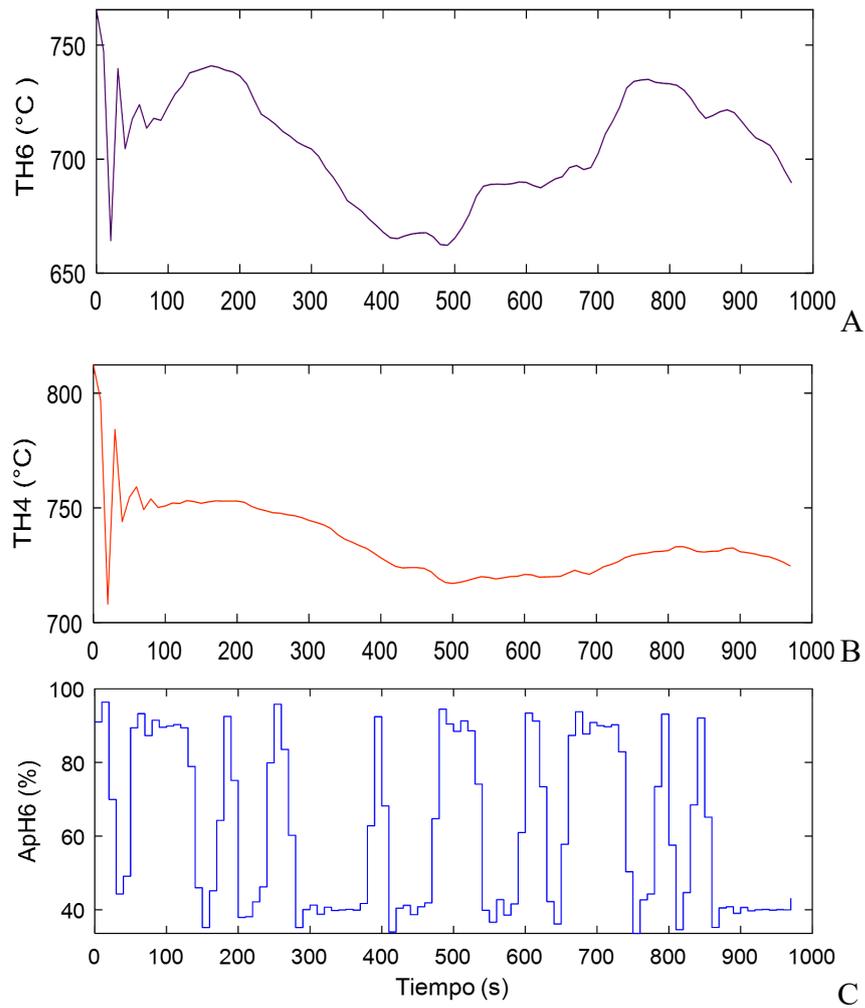


Figura 3.12. Respuesta temporal al variar ApH6 con señal SBPA (A-Salida TH6, B- Salida TH4 y C-Entrada ApH6)

En las figuras 3.13 y 3.14 se presentan de forma ampliada la comparación entre las salidas reales y las salidas de los modelos, se evidencia la correspondencia entre ellas, con funciones de residuos dentro de los intervalos de confiabilidad (figuras 3.15 y 3.16).

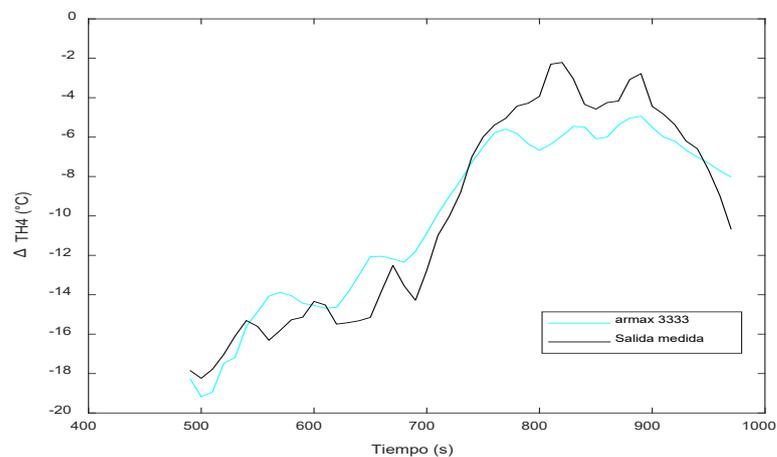


Figura 3.13. Salida real menos salida del modelo simulado TH4 vs. ApH6

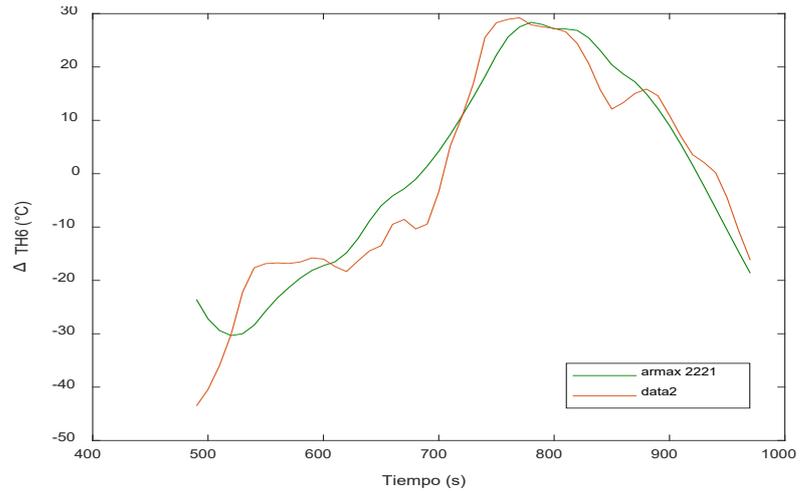


Figura 3.14. Salida real menos salida del modelo simulado TH6 vs. ApH6

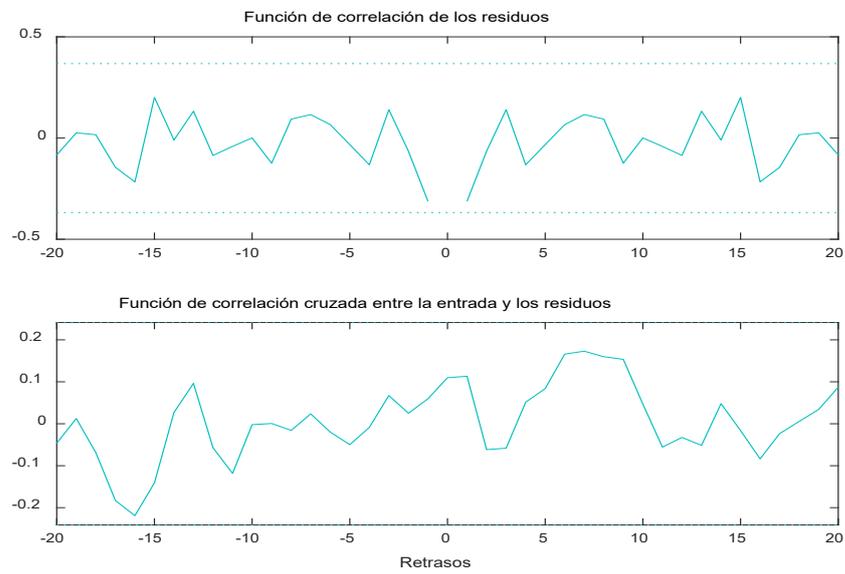


Figura 3.15. Prueba de residuos para el modelo estimado TH4 vs. ApH6

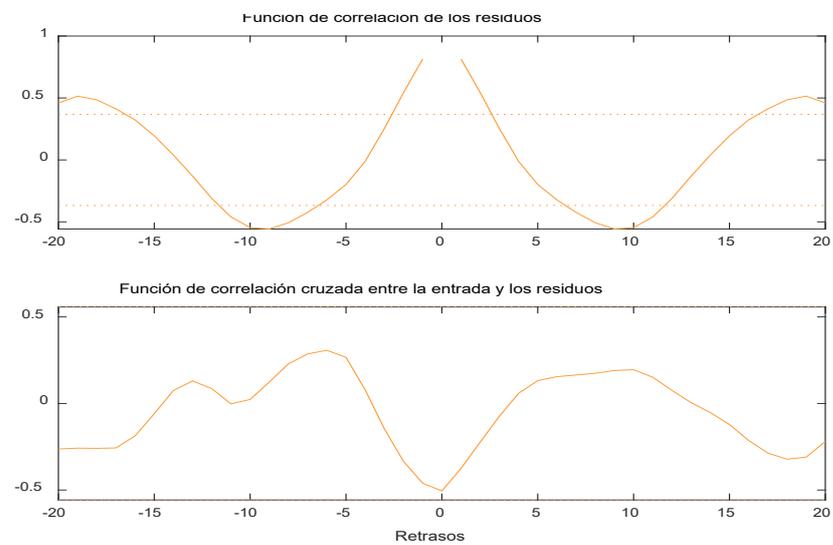


Figura 3.16. Prueba de residuos para el modelo estimado TH6 vs. ApH6

3.4.3. Modelos de TH4 y TH6 versus Fm

De las variables registradas en el EROS para la medición del flujo de mineral, se seleccionó Peso descargado por la romana [kg], pues las restantes señales que se registran son muy ruidosas. En el experimento 3 se aplicó de forma manual (no programada en el PLC) una SBPA de orden tres con una réplica (tabla 3.5) al flujo de mineral de la romana 2, que se movió en un rango de 67 a 132 kg/h con un período de conmutación de la señal de 240 s, mientras que las aperturas de las válvulas reguladoras de flujo de aire en H4 y H6 se mantuvieron constantes en 70 y 50 %, respectivamente. En la figura 3.17 se pueden observar las mediciones de las variables de entrada y de salida.

Tabla 3.5. Secuencia de orden tres.

$X(t)$	$X(t-1)$	$X(t-3)$
1	0	1
1	1	0
1	1	0
0	1	1
1	0	1
0	1	1
0	0	0

Para TH4 se obtuvo como mejor modelo el BJ 22221 de orden 4 con un RMSE de 18,82 °C (FIT = 72,35 %).

$$\frac{TH4(s)}{Fm(s)} = \frac{3 \times 10^{-5} s^3 - 6,4 \times 10^{-5} s^2 - 1,6 \times 10^{-6} s + 2 \times 10^{-10}}{s^4 + 0,04 s^3 + 0,0004 s^2 + 6,7 \times 10^{-7} s - 9 \times 10^{-11}} e^{-240s} \quad (3.7)$$

Para TH6, el mejor RMSE correspondió al BJ 22221 con 20,19 °C (FIT = 70,15 %).

$$\frac{TH6(s)}{Fm(s)} = \frac{0,0009 s^3 + 7,2 \times 10^{-6} s^2 - 8,6 \times 10^{-8} s - 1,3 \times 10^{-10}}{s^4 + 0,02 s^3 + 1,5 \times 10^{-5} s^2 - 1,5 \times 10^{-8} s - 1,5 \times 10^{-11}} e^{-240s} \quad (3.8)$$

En las figuras 3.18 y 3.19 se compara la salida del modelo con la salida medida de TH4 y TH6. Las cualidades de los modelos obtenidos se aproximan a los del sistema real, y exhiben cierto grado de imprecisión.

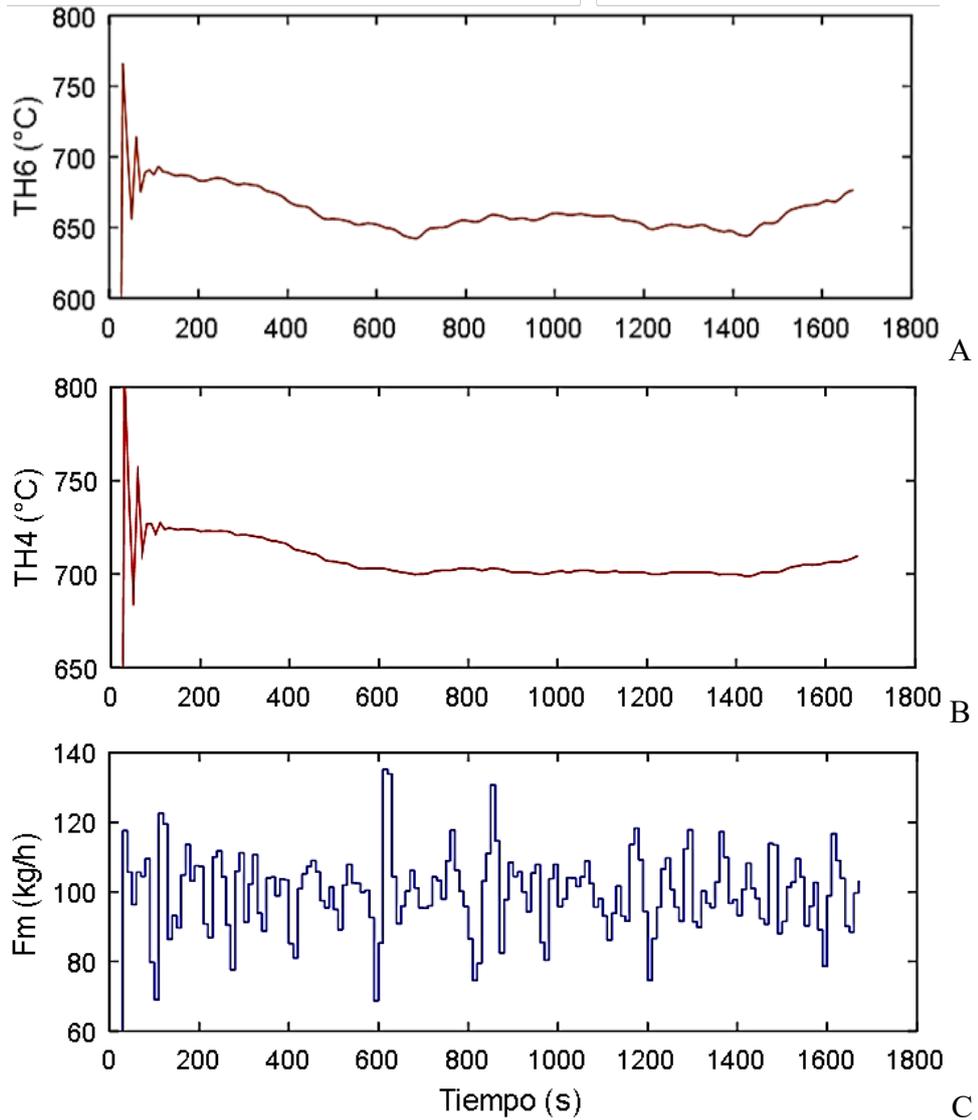


Figura 3.17. Respuesta temporal al variar Fm con señal SBPA (A-Salida TH6, B-Salida TH4 y C-Entrada Fm)

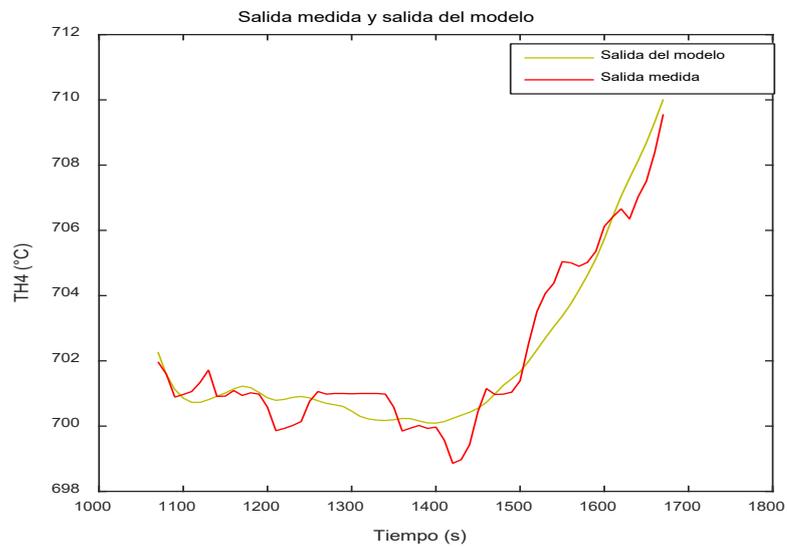


Figura 3.18. Salida real menos salida del modelo simulado TH4 vs. Fm

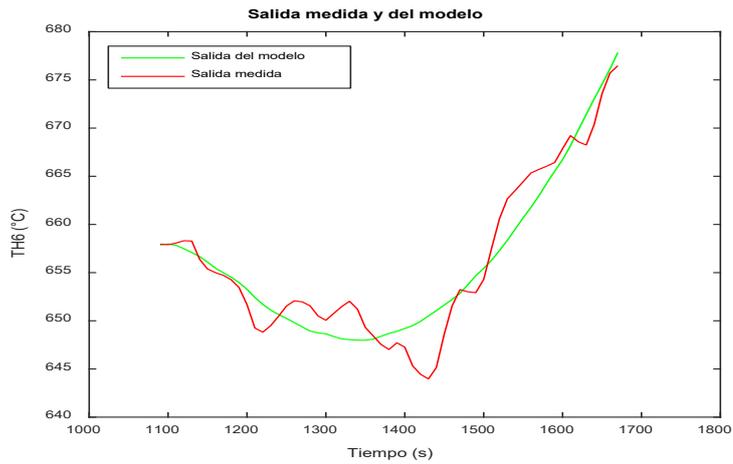


Figura 3.19. Salida real menos salida del modelo simulado TH6 vs. Fm

3.4.4. Modelos lineales obtenidos con el empleo de APRBS

En la figura 3.20 (experimento 4) se observa el gráfico temporal obtenido al aplicar una APRBS sobre la apertura de la válvula reguladora de flujo de aire H4 (ApH4), en el rango de 12 a 57 % con ApH6 constante en 40 % y un flujo de mineral alimentado al horno de 18,2 t/h. En la parte superior se muestra el comportamiento de las variables de salida (TH6, TH4).

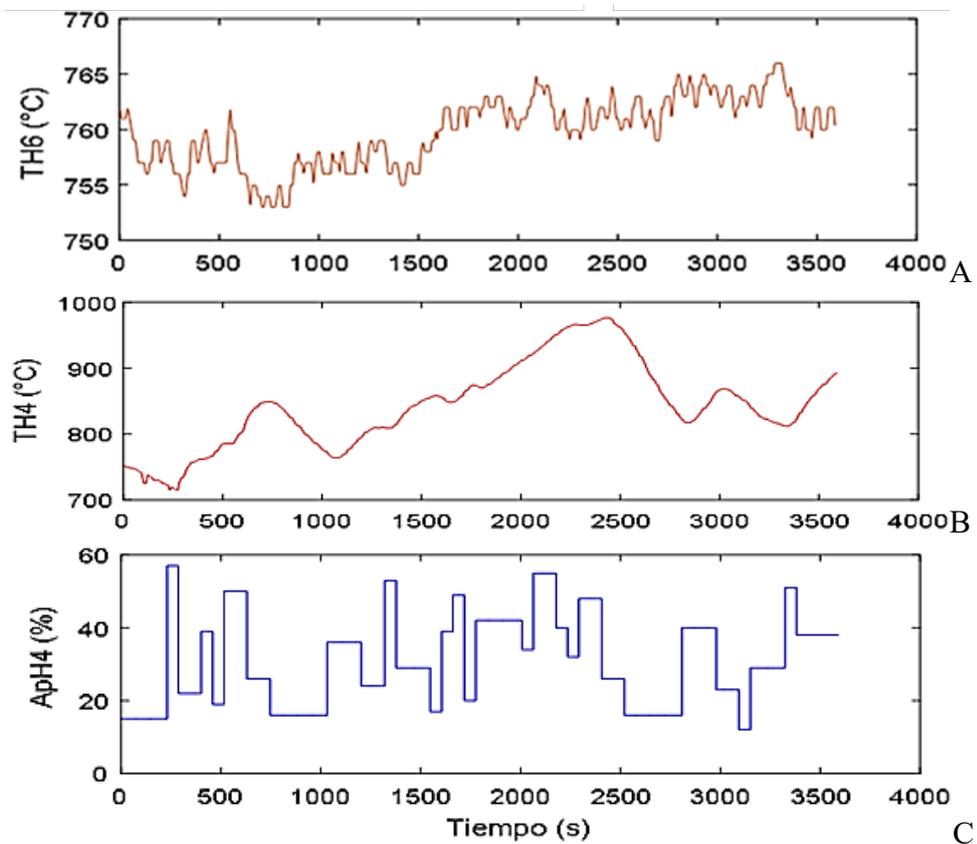


Figura 3.20. Respuesta temporal al variar ApH4 con señal APRBS (A-Salida TH6, B- Salida TH4 y C- Entrada ApH4)

En la figura 3.21 (experimento 5) se observa el gráfico temporal obtenido al variar de 20 a 68 % la (ApH6). El horno operaba con un Fm de 18,2 t/h y ApH4 constante en 25 %. En la parte superior de la figura se muestra el comportamiento de las variables de salida (TH4, TH6), y se evidencia el comportamiento decreciente de TH4 e, inversamente proporcional a TH6 debido a la interacción entre estas variables.

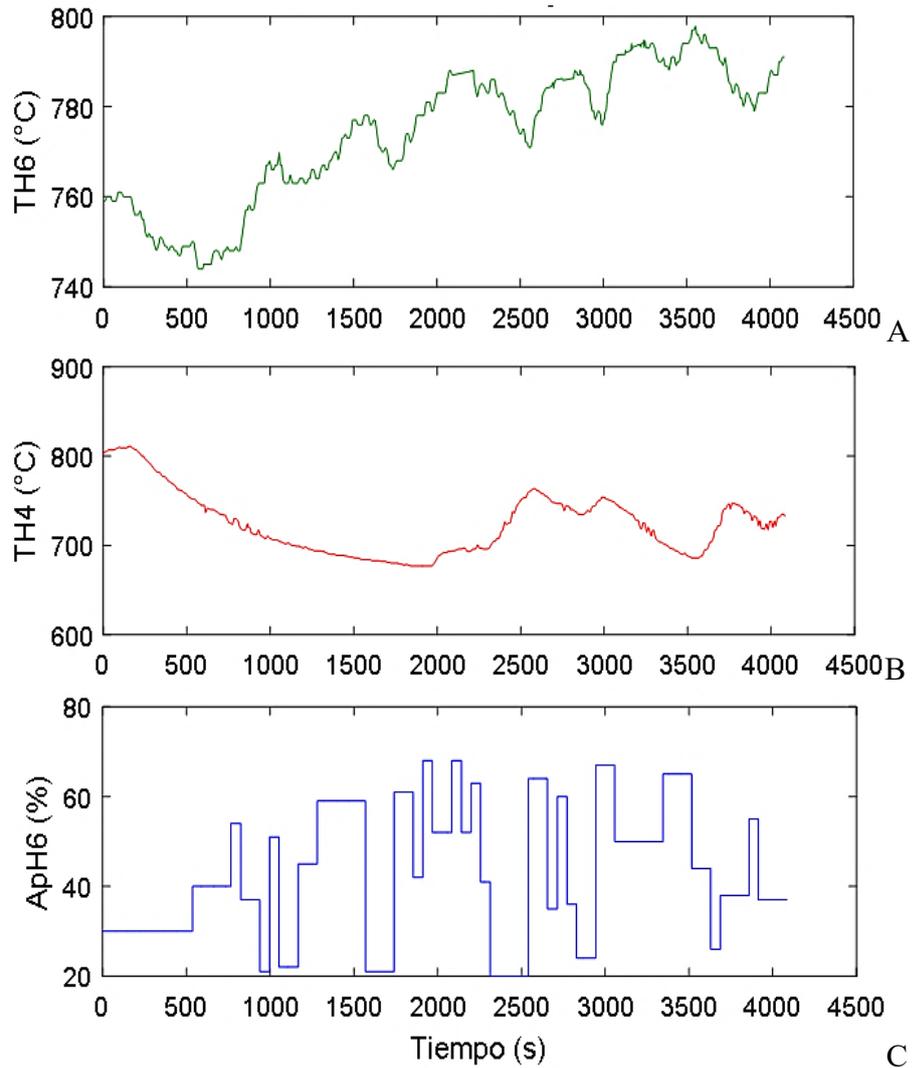


Figura 3.21. Respuesta temporal al variar ApH6 con señal APRBS (A-Salida TH6, B- Salida TH4 y C- Entrada ApH6)

En la figura 3.22 (experimento 6) se observan los resultados de las variables de entrada y salida obtenidos tras experimentar con flujos de 16 a 19 t/h, mientras que las aperturas de las válvulas reguladoras de flujo de aire en H4 y H6 se mantuvieron constantes en 20 y 30 %, respectivamente.

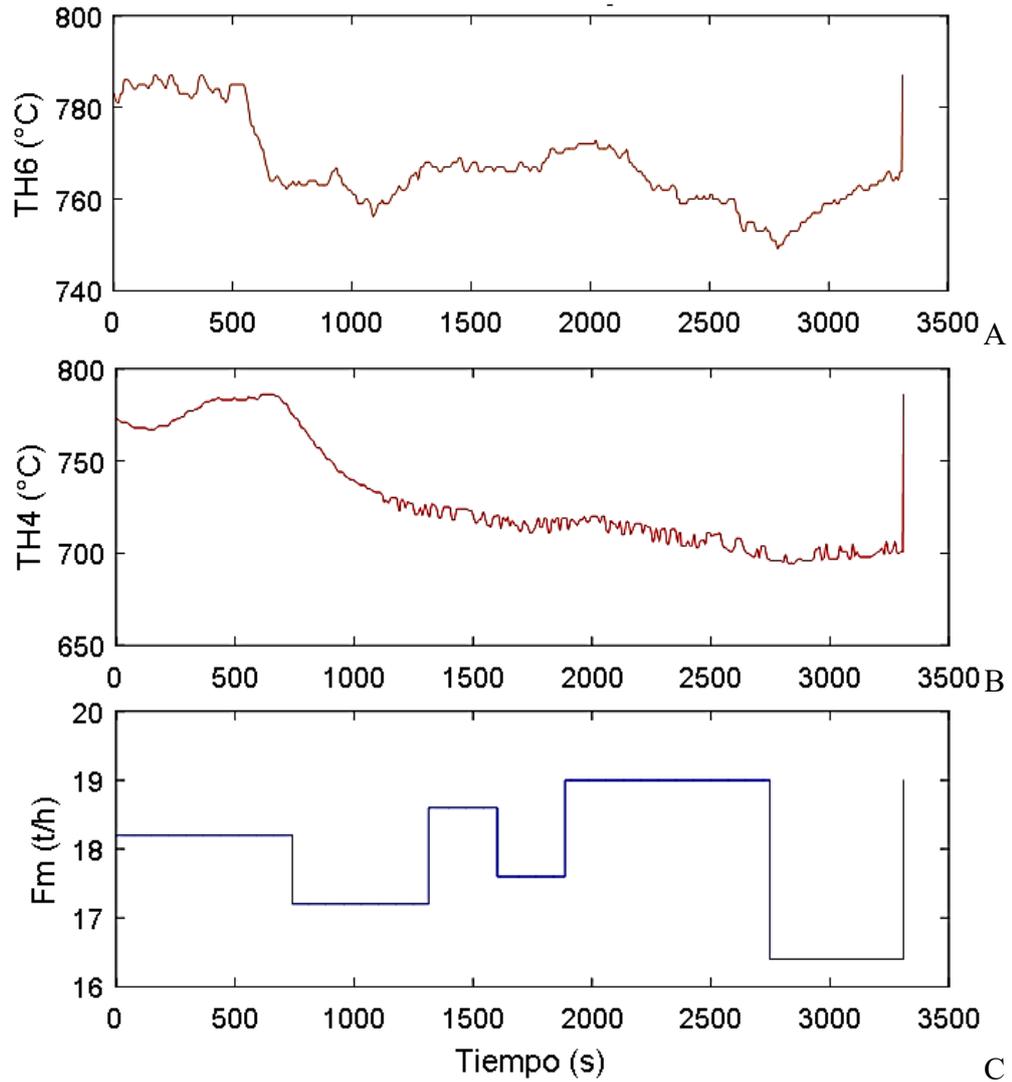


Figura 3.22. Respuesta temporal al variar F_m con señal APRBS (A-Salida TH6, B-Salida TH4 y C-Entrada F_m)

Se determinaron modelos SISO en correspondencia por lo propuesto en [129], con estructuras OE y ARX, para diferentes órdenes, y se obtuvieron sus equivalentes continuos [13].

- Modelos obtenidos al variar A_{pH4} :

OE 233 con un RMSE de 11,08 °C (FIT = 83,05 %).

$$\frac{TH4(s)}{A_{pH4}(s)} = \frac{0,0008s^2 + 0,0005s - 8,3e^{-8}}{s^3 + 0,18s^2 + 4,2e^{-5}s - 4,7e^{-8}} \quad (3.9)$$

ARX 331 con un RMSE de 0,83 °C (FIT = 73,21 %).

$$\frac{TH6(s)}{A_{pH4}(s)} = \frac{-0,0006s^2 - 3,4e^{-6}s - 1,2e^{-7}}{s^3 - 0,004s^2 - 0,0005s - 4,3e^{-7}} \quad (3.10)$$

- Modelos obtenidos al variar ApH6:

ARX 222 con un RMSE de 12,82 °C (FIT = 74,21 %).

$$\frac{TH6(s)}{ApH6(s)} = \frac{0,003s - 2,4e^{-5}}{s^2 - 0,003s - 5,12e^{-5}} \quad (3.11)$$

ARX 333 con un RMSE de 3,84 °C (FIT = 63,43 %).

$$\frac{TH4(s)}{ApH6(s)} = \frac{-0,0003s^2 - 0,0001s - 6,5e^{-8}}{s^3 - 0,007s^2 - 8,7e^{-5}s - 4,07e^{-8}} \quad (3.12)$$

- Modelos obtenidos al variar Fm:

OE 233 con un RMSE de 4,65 °C (FIT = 84,34 %).

$$\frac{TH4(s)}{Fm(s)} = \frac{-0,0004s^2 - 0,0003s - 2,7e^{-7}}{s^3 - 0,01s^2 - 2,5e^{-5}s - 3e^{-7}} \quad (3.13)$$

OE 233 con un RMSE de 1,86 °C (FIT = 80,12 %).

$$\frac{TH6(s)}{Fm(s)} = \frac{-0,2s - 4,9e^{-5}}{s^2 - 0,002s - 2,4e^{-6}} \quad (3.14)$$

En cada caso, los modelos estimados reflejaron el comportamiento del subproceso de postcombustión de forma adecuada, lo que constituye una premisa importante para el diseño de estrategias de control de elevado desempeño, donde es necesaria una fase de simulación [13]. Con respecto a la validación de los modelos, se efectuaron análisis de residuos (errores de predicción) y correlación cruzada, como se proponen en los epígrafes 3.4.1 y 3.4.2.

En la tabla 3.6 se muestra un resumen de los errores de predicción logrados con los modelos lineales identificados mediante las señales SBPA y APRBS, y se evidencia que los modelos obtenidos con APRBS presentan mejor ajuste en relación con los modelos obtenidos mediante SBPA, propuestos en [130], por lo que su comportamiento resulta representativo a la dinámica del sistema. A su vez, estos resultados están en el rango del RMSE logrado con modelos lineales aplicados a un proceso de reducción de níquel, similar al objeto de estudio [53].

Tabla 3.6 Ajuste comparativo de los modelos lineales.

No.	Modelos	RMSE (°C)	
		SBPA	APRBS
1	$TH4(s)$	21,38	11,08
	$ApH4(s)$		
2	$TH6(s)$	31,12	0,83
	$ApH4(s)$		
3	$TH6(s)$	27,02	12,82
	$ApH6(s)$		
4	$TH4(s)$	26,27	3,84
	$ApH6(s)$		
5	$TH4(s)$	18,82	4,65
	$Fm(s)$		
6	$TH6(s)$	20,19	1,86
	$Fm(s)$		

3.5. Modelo RNA SISO

Los resultados muestran errores de predicción para TH4 de 6,13 °C (figura 3.23) y 8,12 °C para TH6 (figura 3.24), con cinco neuronas y función de activación tangente hiperbólica en la capa oculta.

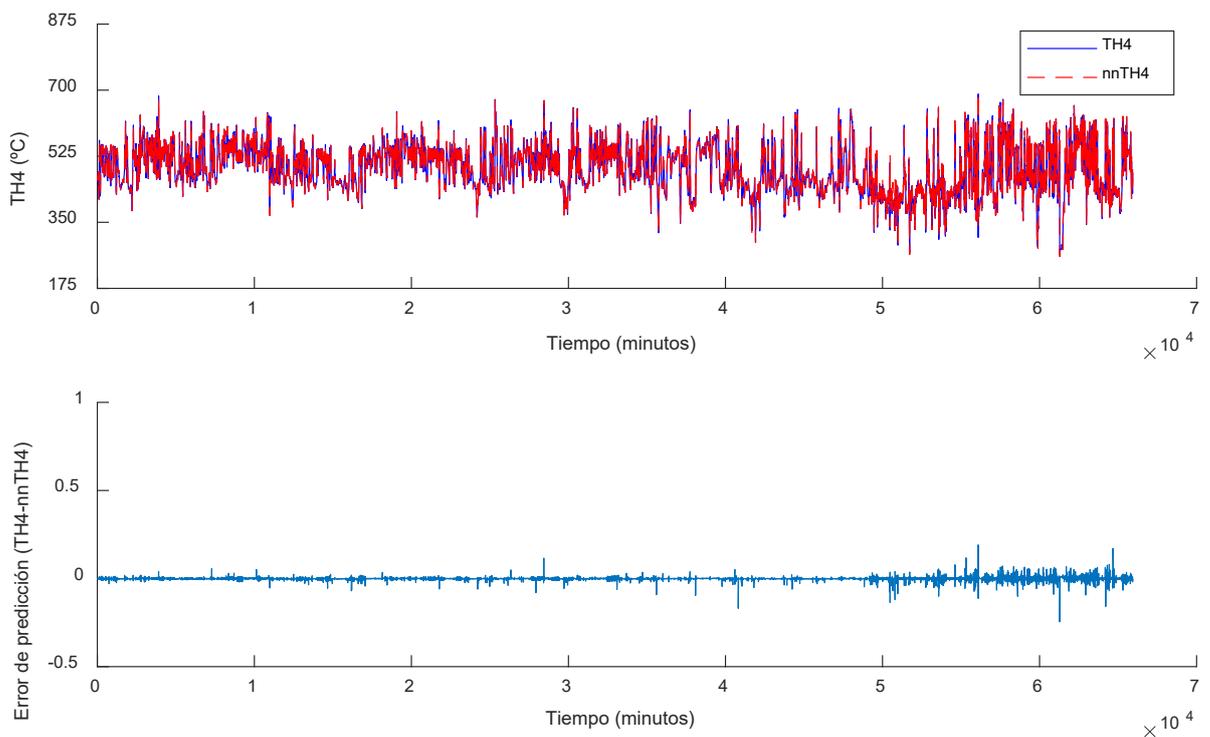


Figura 3.23. Predicción de TH4 con cuatro meses de operación en 2018

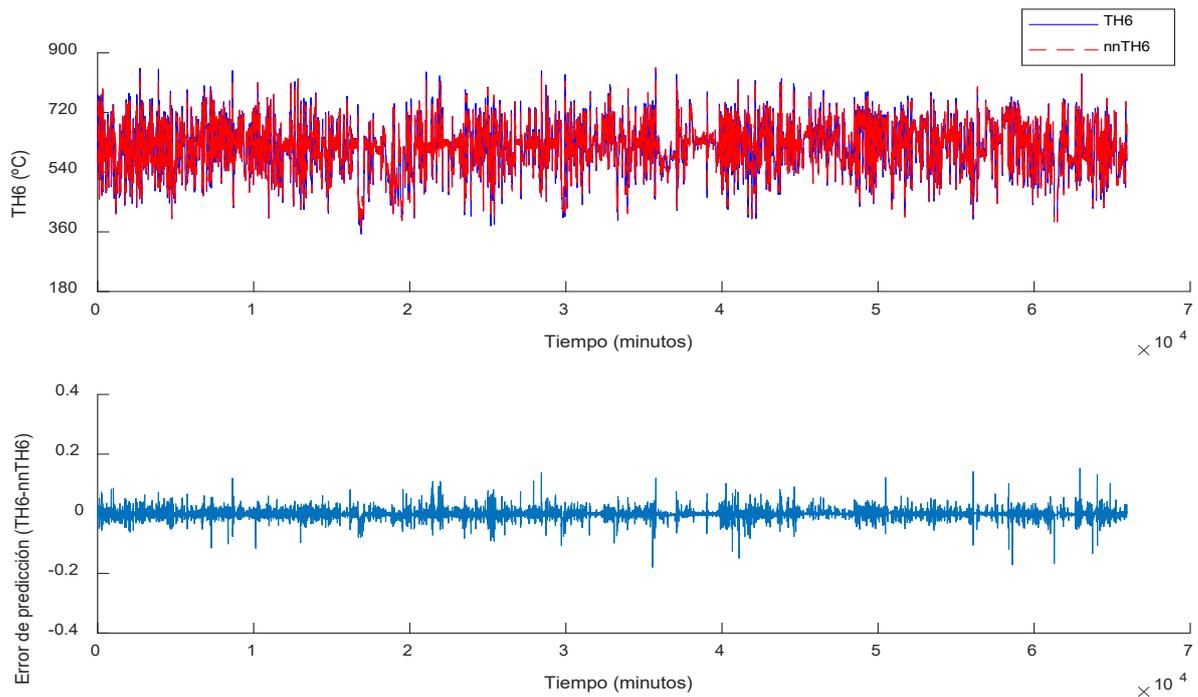


Figura 3.24. Predicción de TH6 con cuatro meses de operación en 2018

3.6. Modelo RNA MIMO

El resultado del proceso de prueba y error con el modelo NARX MIMO se muestra en la tabla 3.7. Al comparar los valores de AIC y BIC, el BIC de 28 936,7 sugiere un modelo con 41 parámetros y tres neuronas en la capa oculta, más sencillo que el modelo sugerido por el AIC de 27 879,7 con 340 parámetros y 26 neuronas en la capa oculta. Además, el modelo sugerido por BIC, aunque con menos parámetros del modelo, posee una capacidad predictiva ($\overline{RMSE} = 4,7 \text{ }^\circ\text{C}$) con un coeficiente de variación ($CV = 3,8 \%$), que es aproximada a la del modelo basado en AIC ($\overline{RMSE} = 4,5 \text{ }^\circ\text{C}$, $CV = 3,5 \%$). Esto resulta de vital importancia para lograr una representación parsimoniosa de sistemas no lineales complejos en muchas situaciones de aplicación, porque un modelo con menos parámetros puede reducir en gran medida el trabajo de recopilación de datos y beneficiar el proceso de comprensión de los sistemas.

En la figura 3.25 se muestran los resultados de uno de los entrenamientos con tres neuronas en la capa oculta. La regresión es para medir la correlación entre la salida de la red y la salida real del conjunto de datos analizados. Para los datos de prueba el valor de regresión es 0,99727 (cercano a

1) y representa que el rendimiento de la red tiene una fuerte relación con el dato real según el conjunto de 64 146 datos proporcionados (figura 3.25 a).

Por su parte, ($MSE = 25,9 \text{ } ^\circ\text{C}$) es el error cuadrático medio entre la salida de la red (nn) y la salida real del conjunto dado (figura 3.25 b). Se constata que el modelo NARX tiene éxito para capturar el modelo dinámico del sistema, pues se logran errores de predicción de $5 \text{ } ^\circ\text{C}$, y se consideran bajos en comparación con el rango de temperatura (superiores a $900 \text{ } ^\circ\text{C}$) de los termopares instalados en H4 y H6 del horno.

Tabla 3.7 Proceso de prueba y error al variar neuronas en la capa oculta del modelo NARX.

<i>Neuronas</i>	\overline{RMSE}	<i>k</i>	<i>AIC</i>	<i>BIC</i>	<i>CV</i>
1	45,0	15	72 978,0	73 085,6	0,8
2	4,6	28	28 992,1	29 192,9	2,7
3	4,7	41	28 642,6	28 936,7	3,8
4	4,7	54	28 753,9	29 141,2	3,7
5	4,7	67	28 771,8	29 252,3	3,6
6	4,7	80	28 920,0	29 493,7	2,7
7	4,6	93	28 530,4	29 197,4	4,0
8	4,6	106	28 857,1	29 617,3	2,9
9	4,5	119	28 572,9	29 426,3	2,6
10	4,6	132	28 696,3	29 642,9	4,6
11	4,5	145	28 389,7	29 429,6	3,9
12	4,5	158	28 664,8	29 797,9	3,0
13	4,6	171	28 556,1	29 782,4	4,5
14	4,5	184	28 211,5	29 531,1	3,8
15	4,5	197	28 085,4	29 498,2	3,5
16	4,5	210	28 544,8	30 050,9	3,6
17	4,5	223	27 911,9	29 511,2	3,7
18	4,5	236	28 621,2	30 313,7	4,2
19	4,6	249	28 493,7	30 279,4	4,3
20	4,4	262	28 249,3	30 128,3	3,3
21	4,5	275	28 085,2	30 057,4	3,6
22	4,5	288	28 550,3	30 615,8	3,2
23	4,5	301	28 095,9	30 254,6	3,7
24	4,5	314	28 048,1	30 300,0	4,2
25	4,5	327	28 417,5	30 762,7	3,8
26	4,5	340	27 879,7	30 318,1	3,5
27	4,5	353	28 128,1	30 659,8	4,1
28	4,5	366	28 484,5	31 109,3	3,3
29	4,5	379	28 356,4	31 074,5	3,6
30	4,5	392	29 103,9	31 915,2	3,2

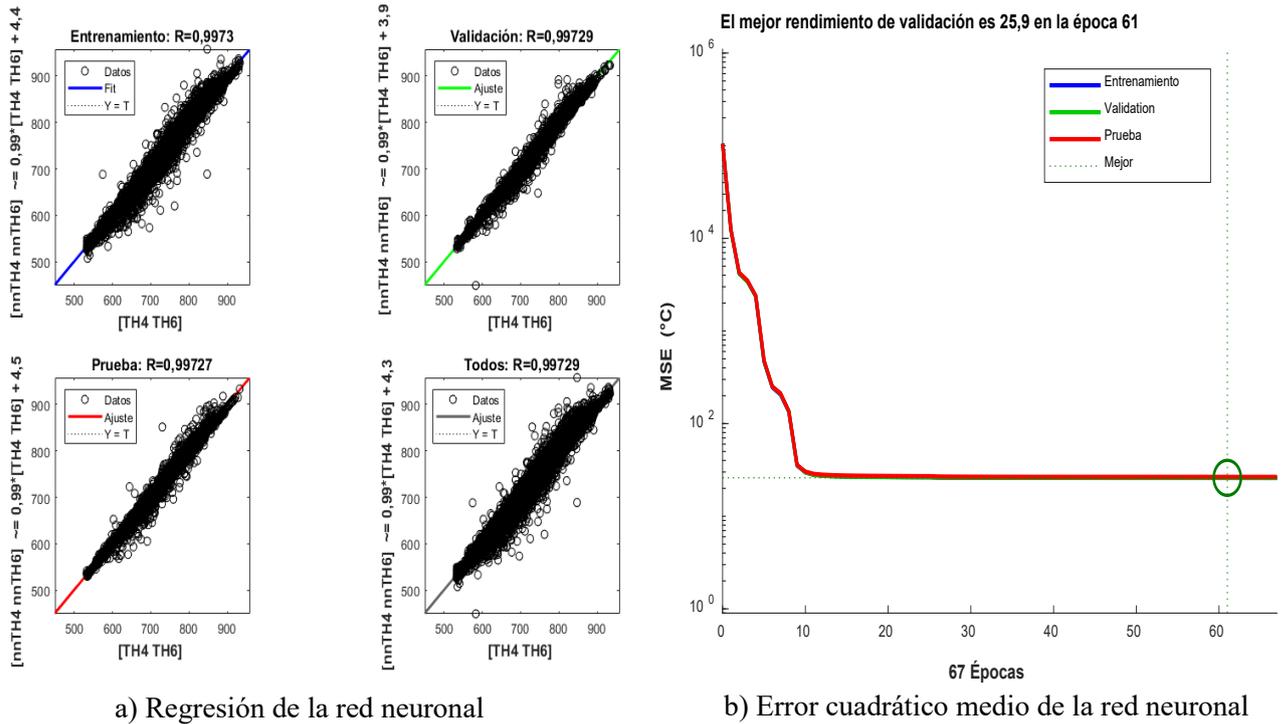


Figura 3.25. Entrenamiento del modelo NARX con tres neuronas en la capa oculta

Estos resultados están en el rango de los errores obtenidos en [80] en la modelación del perfil térmico de un horno de reducción de níquel con características diferentes al objeto de estudio de esta investigación. A su vez, en [131] se demuestra que el modelo obtenido mediante el uso de RNA, refleja las características dinámicas del subproceso de postcombustión con menor error que los modelos lineales, se prueba así las potencialidades que ofrece esta herramienta de inteligencia artificial.

Mediante el modelo NARX identificado se logra resolver un sistema complejo que incluye múltiples variables y un sistema no lineal. Sin embargo, se debe considerar la adquisición de datos confiables de la planta. Por tal razón, el proveedor de datos debe garantizar que los sensores del proceso estén en buenas condiciones para capturar series de tiempo, aptas para el entrenamiento del modelo.

Los resultados de la generalización del modelo identificado con datos de 2015, adaptado a dos años diferentes, se muestran en la tabla 3.8. El RMSE promedio de la serie temporal del 2018 fue $8,1^{\circ}\text{C}$, y $14,4^{\circ}\text{C}$ para el 2022, ambos con valores de regresión cercanos a 1.

Tabla 3.8 Generalización del modelo NARX MIMO.

<i>Subconjunto temporal</i>	<i>cuatro meses de 2018</i>		<i>tres meses de 2022</i>	
	Generalización RMSE	Generalización R	Generalización RMSE	Generalización R
1	7,3	0,9947	5,9	0,9973
2	7,1	0,9961	5,4	0,9992
3	7	0,9958	83	0,9935
4	7,9	0,9949	22	0,9962
5	8,8	0,9931	3,8	0,9991
6	7,6	0,9947	7,3	0,9955
7	8,2	0,9935	3,1	0,9994
8	7,2	0,9951	2,9	0,9988
9	8,7	0,9944	4,4	0,9988
10	11	0,9913	6,1	0,9976

Los errores de generalización son superiores al error del modelo identificado del 2015 (5 °C) porque las condiciones de operación del horno pudieron haber variado, sin embargo, el modelo puede readecuarse a esos nuevos datos, a partir de una actualización de los pesos de la red con determinada frecuencia. En el caso de los subconjuntos 3 y 4 del 2022, el error subió considerablemente porque se produjo la parada de la empresa debido a la contingencia energética del país. Se demuestra que la solución final de identificación requiere un aprendizaje en línea con realimentación en tiempo real, además de alargar el tiempo de eficacia de los coeficientes identificados con el modelo NARX.

Se sugiere al personal de la industria que monitoree el RMSE con el modelo identificado en línea, como un dato más de operación y como señalizador para la entrada en tiempo real del control en los subconjuntos temporales. Pues en los intervalos de tiempo donde el error es bajo podrían tornarse una especie de patrón para la Unidad Básica de Producción Planta Hornos de Reducción, e invitarían a muchos investigadores a proponer esquemas de control en tiempo real.

3.7. Implementación de las redes neuronales artificiales

Se propone la construcción de un simulador (figura 3.26) de propósito específico (fundación de un *startup*: entrenamiento de operadores e ingenieros de las plantas) para uso de la Empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara” en capacitación.

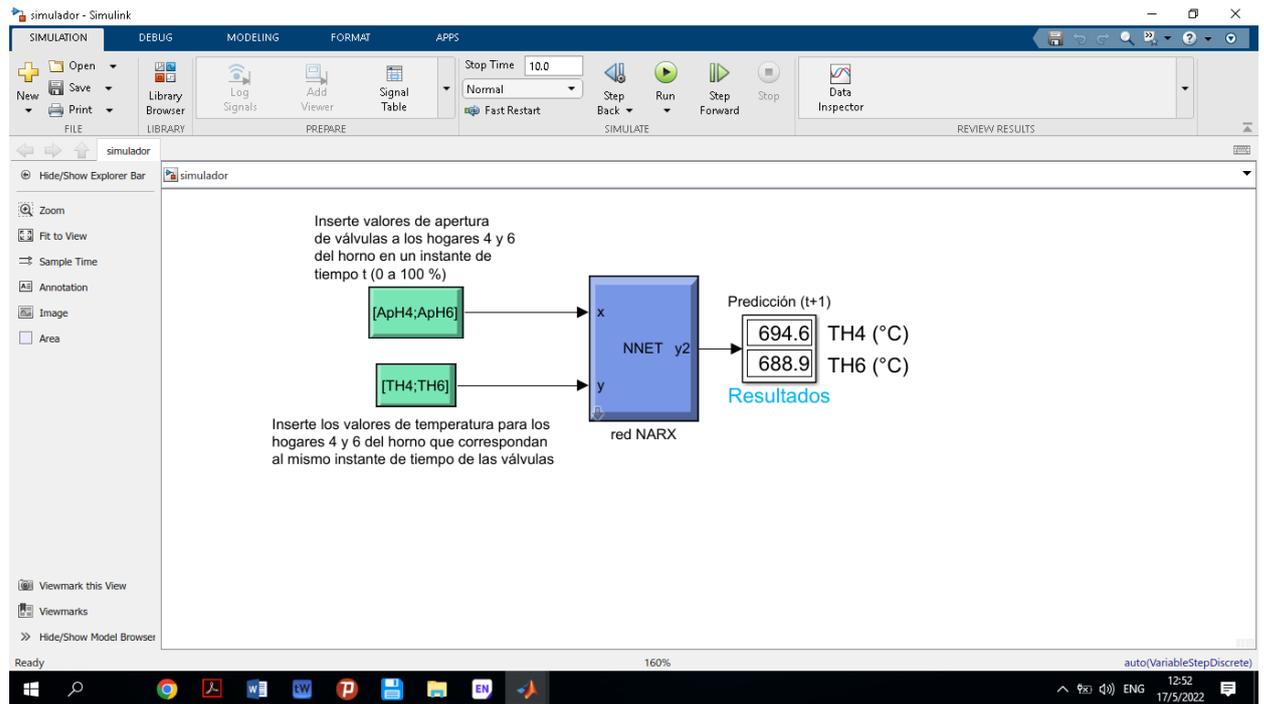


Figura 3.26. Simulador del proceso de postcombustión con el modelo NARX

Para la identificación y posterior estrategia de control del subproceso de postcombustión del horno de reducción de minerales lateríticos, se proponen los siguientes modos de implementación de las RNA:

- Simulación de la red sobre un ordenador convencional mediante un software específico. Es la forma más simple. La mayor desventaja radica en el hecho de que se intentan simular redes con un alto grado de paralelismo sobre máquinas que ejecutan las operaciones en secuencia.
- Mediante uno o varios circuitos integrados específicos, se trata de construir un elemento o conjunto de elementos que se comporte lo más similarmente posible a como lo haría una RNA. Son los llamados chips neuronales con inserción en los PLC. Estos funcionan a alta velocidad y permiten el proceso en tiempo real.

La comercialización de productos de software es la forma más extendida para simular RNA. La diferencia entre los distintos productos de software radica en el tipo y el número de arquitecturas de red que soporta la velocidad de procesamiento, interfaz gráfica y exportación de código C para el desarrollo automático de aplicaciones [132].

Algunos de los productos comerciales son: ANSim, ExpertNet (DOS, Windows), Neuralesk (Windows), Neuralworks Pro II/Plus (DOS, OS/2, UNIX, VMS).

3.8. Valoración económica

El control adecuado de la postcombustión tiene un efecto económico apreciable, pues se logra mayor eficiencia del proceso que se desarrolla en los hornos de reducción. El máximo aprovechamiento del potencial energético de los elementos reductores (CO, H₂) que no han participado en el proceso de reducción, evita la expulsión al medio ambiente de considerables cantidades de calor y disminuye las pérdidas de mineral en forma de polvo, contenido en los gases de escape de los hornos.

El control automático de la postcombustión a partir de los modelos matemáticos identificados podría reducir las pérdidas de calor que se producen en los gases de salida; se pueden calcular como pérdidas por incombustión química del combustible, Q_3 , en $\frac{kJ}{kg}$. El cálculo de las pérdidas de calor q_3 en %

se realiza por la siguiente metodología [133]:

$$q_3 = (126,4 * CO + 108 * H_2 + 358,2 * CH_4) * \left(\frac{V_{gs}^\circ * (100 - q_4)}{Q_1} \right) \quad (3.15)$$

donde V_{gs}° es el volumen teórico de gases secos, q_4 es el porcentaje de las pérdidas por incombustión mecánica ($q_4 = 0$ para combustibles líquidos), y $CH_4 = 0$.

$$V_{gs}^\circ = V_{CO_2} + V_{SO_2} + V_{N_2} \quad (3.16)$$

$$V_{gs}^\circ = 1,866 * \left(\frac{C + 0,375 * S}{100} \right) + 0,79 * V^\circ + 0,008 * N \quad (3.17)$$

N se toma como 0.

$$V^\circ = [0,0889 * C + 0,2667 * H + 0,0333(S - O)] * K_{aire} \quad (3.18)$$

K_{aire} para la combustión incompleta se toma igual a 0,9.

O se asume con valor 0.

Los datos para la evaluación de las fórmulas anteriores se ofrecen en la tabla 3.9.

Tabla 3.9 Datos para los cálculos.

Símbolo	Valor	Descripción
C	86 %	Composición química del petróleo utilizado en la Unidad Básica de Producción Planta Hornos de Reducción
H_2	10,5 %	
S	2,9 %	
$Otros$	0,6 %	
Q_l	9 524,7 kcal/kg _c	Valor calórico inferior del combustible
$IndCp$	54 kg _c /t	Consumo específico de petróleo en las cámaras de combustión
V_{gt}	15 000 m ³ /h	Volumen total de gases en el horno
F_m	20 t/h	Flujo de mineral a procesar
h_m	4,5 %	Humedad del mineral en base seca
r	3,0 %	Reciclo (polvo arrastrado por los gases de salida)
P_a	2,82 %	Cantidad de petróleo aditivo
f_o	89,55 %	Eficiencia operativa
C_{tp}	629,8 USD	Precio de la tonelada de petróleo
C_{tn}	30 832 USD	Precio de la tonelada de óxido de níquel
f	71,93 %	Eficiencia metalúrgica
μ_r	1,74 t/h	Cantidad promedio de mineral arrastrado por los gases de salida
l_n	1,114 %	Ley del níquel

Los resultados de los cálculos fueron:

$V^\circ = 0,095 \frac{Nm^3}{kg}$; el volumen de aire fue calculado considerándolo un 10 % menor que el estequiométrico.

$V^\circ_{gs} = 0,091 \frac{Nm^3}{kg}$ y al considerar una temperatura promedio de los gases (T_g) de 750 °C se tiene

que:

$$T = 273,15K$$

$$T_g = 273,15K + 750 = 1023,15K$$

$$V^\circ_{gs}(750^\circ C) = \frac{V^\circ_{gs} * T_g}{T} = \frac{0,091 * 1023,15}{273,15}$$

$$V_{gs}^{\circ}(750^{\circ}C) = 0,34 \frac{m^3}{kg_c}$$

Primero se determinó q_3 cuando la concentración de los elementos reductores en los gases de salida se encuentra en sus valores límites ($CO = 3,5 \%$, $H_2 = 2,5 \%$).

$q_3 = 2,54 \%$, este es el porcentaje del calor disponible que se pierde.

$$Q_3 = Q_1 * q_3 = 241,93 \frac{kcal}{kg_c}$$

El flujo neto de mineral alimentado al horno (Mna) se calcula de la siguiente forma:

$$Mna = Fm - [(Fm * hm) + (Fm * r) + (Fm * Pa)] \quad (3.19)$$

$$Mna = 17,94 \frac{t}{h}$$

La productividad anual de un horno (P) se obtiene mediante la ecuación:

$$P = Mna * fo * 24 * 365 \quad (3.20)$$

$$P = 140731,77 \frac{t}{año}$$

Para conocer a cuánto equivale la cantidad de calor de petróleo (Cpp) que se consume anualmente en el horno, se aplica la siguiente ecuación:

$$Cpp = \frac{Q_3 * IndCp * P}{Q_1 * 1000} \quad (3.21)$$

$$Cpp = 193,03 \frac{t_c}{año}$$

A continuación, se calcula q_3 suponiendo que está presente el sistema de control automático, en este caso la concentración de elementos reductores en los gases de salida se debe reducir en $1,5 \%$ ($CO = 2 \%$, $H_2 = 1 \%$) [8].

$$q_3 = 1,29 \%$$

$$Q_3 = 122,87 \frac{kcal}{kg_c}$$

$$C_{pp} = 98,03 \frac{t_c}{año}$$

Por diferencia se obtiene que con el sistema de control se ahorrarían $95 \frac{t_c}{año}$, lo que equivale a 59 831 USD.

Si la concentración de CO en los gases de salida es superior al 3,5 % hay que darles salida a los gases directamente a la atmósfera para evitar que se produzca una explosión en los electrofiltros; lo que produce pérdidas de mineral irrecuperables. Para un estimado de las pérdidas que se producen por esta vía, se asumió el comportamiento de un horno durante un mes, con 10 horas (Tha), al emanar sustancias contaminantes al espacio por alta concentración de CO [8].

Los cálculos se realizaron según la metodología que sigue:

Mineral perdido en los gases de salida al espacio

$$T_{mp} = Tha * \mu_r \quad (3.22)$$

Níquel en el mineral perdido

$$T_{nmp} = T_{mp} * l_n \quad (3.23)$$

Níquel no recuperado

$$N_{nr} = T_{nmp} * f \quad (3.24)$$

Dinero no recuperado por concepto de níquel

$$D_{nr} = C_m * N_{nr} \quad (3.25)$$

Al sustituir por los datos correspondientes, se obtienen los siguientes resultados:

$$T_{mp} = 17,4 t$$

$$T_{nmp} = 0,1938 t$$

$$N_{nr} = 0,1394 t$$

$$D_{nr} = 4297,98 USD$$

Al multiplicar 4297,98 USD por 12 meses, se obtuvo que las pérdidas por partículas con contenido de níquel en los gases ascienden a un promedio anual de 51 575,8 USD.

Al sumar 51 575,8 USD con 59 831 USD ($95 \frac{t_c}{año}$ ahorradas con el sistema de control), se ahorrarían un total de 111 406,8 USD anualmente, con posibilidades de que se eleve a 2 673 763,2 USD para los 24 hornos de la Unidad Básica de Producción Planta Hornos de Reducción.

3.9. Impacto tecnológico

El resultado tecnológico de la investigación consiste en la implementación de una nueva tecnología (un registro en el sistema de supervisión CITECT) para la apertura de las válvulas reguladoras de flujo de aire a H4 y H6 del horno 2, de la Unidad Básica de Producción Planta Hornos de Reducción en la empresa. Este registro constituye un aporte significativo para el control del subproceso; anteriormente estas variables no eran monitoreadas de manera continua. A su vez, facilita la toma de decisiones y la valoración casi inmediata de posibles cambios en el proceso, sin necesidad de afectar la producción. Estos resultados pueden ser generalizados en los demás hornos de reducción de la Empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara”, para aumentar la eficiencia metalúrgica.

3.10. Impacto medioambiental

En aras de contribuir con el programa de Desarrollo y Perfeccionamiento de la Industria Cubana del Níquel se deben introducir nuevas tecnologías para la disminución de las agresiones al ecosistema, y ofrecer resultados superiores para la sociedad y la economía, en comparación con las tradicionalmente usadas hasta el momento.

La automatización del subproceso de postcombustión a través de un modelo matemático de la planta, debe contribuir en alguna medida a la disminución de la degradación y el deterioro del ecosistema.

Las emisiones gaseosas y de polvo guardan una estrecha relación con la postcombustión. Si se logra un control efectivo de la misma, se deben reducir al máximo las emisiones por alta concentración de

monóxido de carbono en los gases de escape, equivalente a no expulsar a la atmósfera un mínimo de 400 toneladas de polvo anuales y se reduce considerablemente la cantidad de gases nocivos. De esta forma, disminuiría la propagación de enfermedades respiratorias en la población de Moa.

3.11. Impacto social

La inserción del modelo matemático dinámico en una estrategia de control para el subproceso de postcombustión del horno de reducción la Empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara”, disminuirá el consumo de combustible y las emisiones de gases y polvos a la atmósfera, proporcionará una buena predicción de las variables de salida operacionales ante diferentes situaciones, y permitirá operar la instalación sin la necesidad de estar expuestos a las altas temperaturas, ruido y polvo excesivo.

Al incrementar la calidad de la producción con el menor costo posible, garantizará mayores importaciones al país, lo que facilitará la adquisición de productos de primera necesidad, como alimentos y combustibles.

Conclusiones parciales

1. El comportamiento del perfil térmico en los hogares cuatro y seis del horno tiene un carácter multivariable y no lineal respecto al flujo de aire suministrado, en estado estacionario; con una apreciable influencia del flujo de mineral alimentado, caracterizada por un notable retraso de transporte.
2. La modelación paramétrica realizada con las estructuras *Output-Error* 231, *Box-Jenkins* 22221, y *Auto-Regressive eXogen* 441, arrojó errores de predicción inferiores a 11 °C, con funciones de residuos dentro de los intervalos de confiabilidad; que demuestran la necesidad de perfeccionar o implementar los modelos matemáticos en estas condiciones operacionales complejas.
3. El modelo NARX para el horno de la tecnología Caron capturó el comportamiento del sistema complejo y dinámico de la postcombustión, con una predicción aceptable de los datos históricos inferiores a 5 °C, y una generalización de 11 °C.

4. La modelación del subproceso de postcombustión, acoplada a una estrategia de control automático, incorporaría importantes aportes en lo económico, tecnológico, social, y ecológico que apoyaría los esfuerzos de la Industria Cubana del Níquel por disminuir sus costos de producción, y aumentar los aportes en divisas al Estado en beneficio de la sociedad.

Conclusiones

El significativo esfuerzo realizado en la investigación de las reacciones gas-sólido que ocurren durante las operaciones de procesamiento de materiales y el conocimiento de tales reactores es aún incompleto, en particular en el contexto de la reducción de lateritas, relacionado con el presente estudio.

1. Los modelos existentes en la literatura consultada no se ajustan al objeto de estudio de esta investigación, pues los hornos estudiados anteriormente presentan diferencias tecnológicas importantes.
2. Los modelos basados en RNA reflejan mejor las características dinámicas del subproceso de postcombustión, que los modelos lineales en función de transferencia.
3. Los modelos obtenidos pueden utilizarse para el diseño de estrategias de control, en aras de aumentar la eficacia y la eficiencia del proceso, y sirven de referencia para otras investigaciones en el procesamiento de reducción de minerales lateríticos, especialmente para el control del perfil térmico.
4. La implementación de los modelos posibilitaría la disminución del consumo de portadores energéticos con un ahorro de 95 toneladas de combustible anuales y evitaría la expulsión al ecosistema de unas 400 t/año de polvo y gases nocivos.

Recomendaciones

1. Generalizar el registro de la apertura de las válvulas reguladoras de flujo de aire a los hogares cuatro y seis en el CITECT, así como la medición del flujo de mineral a través del EROS para los restantes 23 hornos de reducción de la Empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara”, con el objetivo de estudiar el comportamiento de dichas variables y cómo influyen en el proceso.
2. Instalar flujómetros de alta tecnología, para la medición del flujo de combustible a las cámaras de combustión y el flujo de aire a los hogares cuatro y seis del horno, que permitan reflejar el comportamiento del perfil térmico ante variaciones en los flujos de aire y de combustible.
3. Diseñar una estrategia de control inteligente para el subproceso de postcombustión del horno a partir del modelo RNA, propuesto en la investigación. Una estrategia de control a explorar puede ser de la familia de los controladores adaptativos con modelo de referencia. Estos controladores transformarían el problema de estabilizar las dos salidas TH4 y TH6 para valores deseados fijos, en una especie de navegación controlada por la proximidad al modelo de referencia, y un sistema adaptativo que comandaría las entradas.
4. Identificar el subproceso de postcombustión con redes recurrentes (LSTM) para comparar los resultados obtenidos con el modelo NARX.

Referencias Bibliográficas

1. Fraser ED, Dougill AJ, Mabee WE, Reed M, McAlpine P. Bottom up and top down: Analysis of participatory processes for sustainability indicator identification as a pathway to community empowerment and sustainable environmental management. *Journal of Environmental Management* 2006;78 (2):114-27.
2. Reed MS, Stringer LC, Fazey I, Evely AC, Kruijssen JHJ. Five principles for the practice of knowledge exchange in environmental management. *Journal of Environmental Management* 2014;146 337-45.
3. Tseng SC, Hung SW. A strategic decision-making model considering the social costs of carbon dioxide emissions for sustainable supply chain management. *Journal of Environmental Management*. 2014;133 315-22.
4. Castellanos J, Casto R, García I. Elaboración de minerales oxidados de níquel por el esquema carbonato amoniacal. *Minería & Geología*. 1986;4(2):77-91.
5. Miranda J, Chaviano R, Miranda JR. Nuevas Interpretaciones químico-mineralógicas de las menas lateríticas y serpentínicas, a través del proceso pirometalúrgico, en la tecnología carbonato-amoniacoal. *Revista Cubana de Química*. 2002;14(2):42-50.
6. Alepuz H, Legrá A. Informe técnico del proyecto Eficiencia metalúrgica de la Empresa Comandante Ernesto Che Guevara. Moa, Cuba: Centro de Investigaciones del Níquel; 2005.
7. Chang AR. Una visión sobre las reservas estratégicas de eficiencia metalúrgica en la tecnología carbonato-amoniacoal. *Minería y Geología*. 1999;16(1):76-82.
8. Ramírez M. Control Borroso de la Postcombustión en un Horno de Múltiples Hogares [Tesis doctoral]. La Habana: Instituto Superior Politécnico José Antonio Echeverría; 2002.
9. Ramírez M. Modelado del proceso de post-combustión en un horno de reducción de níquel. *Revista de Metalurgia*. 2002;38(2):150-7.
10. Zayas F, Quintián H, Jove E, Casteleiro JL, Calvo JL. Diseño de controladores PID. Publicacións Sd, editor. Universidade da Coruña2020.
11. Góngora D, Van Caneghem J, Haeseldonckx D, Leyva E, Mendoza M, Dutta A. Post-combustion artificial neural network modeling of nickel-producing multiple hearth furnace. *International Journal of Chemical Reactor Engineering*. 2020;18(7):1-14.
12. Montero D, Columbié Á, Montero R, Trujillo R, Vázquez L. Modelo NARX de la postcombustión en un horno de reducción de mineral laterítico. *RIELAC*. 2022 43(3):1-14.
13. Montero D, Ramírez M, Gilbert A, Perdices S. Modelación matemática para el control de la postcombustión en un horno de reducción de níquel. *RIELAC*. 2015;XXXVI(3):21-34.
14. Aguado A. Temas de identificación y control adaptable. La Habana: Cuba: Instituto de Cibernética, Matemática y Física; 2000.

15. Retirado Y, Góngora E. Comportamiento de la humedad durante el secado solar del mineral laterítico. *Minería y Geología*. 2007;23(3):1-19.
16. Retirado Y, Góngora E, editors. Cinética del secado solar del mineral laterítico empleado en la industria del níquel en Moa. *Proceedings of the 5to Taller Internacional de Energía y Medio ambiente*; 2008.
17. Retirado Y, Góngora E. Comportamiento de la adherencia en menas lateríticas sometidas a secado solar natural. *Minería y Geología*. 2009;25(1):1-11.
18. Retirado Y, Lamorú M. Transferencia de calor en el secado solar a la intemperie de menas lateríticas ferroniquelíferas. *Minería y Geología*. 2011;27(1):1-21.
19. Retirado Y, Legrá A. Modelación matemática del área de exposición y volumen de las pilas de menas lateríticas expuestas a secado solar natural. *Minería y Geología*. 2011;28(2):30-46.
20. Retirado Y, Legrá A. Optimización del secado solar de la mena laterítica en la industria cubana del níquel. *Minería y Geología*. 2012;28(2):30-46.
21. Laborde R. Modelación y simulación del proceso de molienda del mineral laterítico, con composición sustancial variable. Tesis doctoral. Moa: Instituto Superior Minero Metalúrgico de Moa "Dr. Antonio Núñez Jiménez"; 2005.
22. Torres E, Retirado Y. Modelación matemática del transporte neumático del mineral laterítico en fase densa. *Minería y Geología*. 2007;23(1):1-31.
23. Góngora E. Modelación del proceso de enfriamiento del mineral laterítico en cilindros horizontales rotatorios. [Tesis doctoral]. Moa, Cuba: Instituto Superior Minero Metalúrgico de Moa "Dr. Antonio Núñez Jiménez"; 2014.
24. Zalazar C. Modelación matemática del proceso de secado de mineral laterítico en secadores rotatorios [Tesis doctoral]. Moa: Universidad de Moa; 2021.
25. Guzmán D, García C. Modelación y simulación del tanque de contacto y los enfriadores de licor en el proceso de lixiviación carbonato-amoniaco con minerales lateríticos cubanos. *Minería y Geología*. 2000;17(2):61-71.
26. Guzmán D. Modelación, simulación y control del tanque de contacto y los enfriadores de licor en el proceso de lixiviación carbonato-amoniaco. [Tesis doctoral]. Moa, Cuba: Instituto Superior Minero Metalúrgico de Moa "Dr. Antonio Núñez Jiménez"; 2001.
27. Guzmán D, Rodríguez MA. Proceso de lixiviación carbonato-amoniaco: control multivariable a través del arreglo inverso de Nyquist para el mezclado de mineral y licor. *Minería y Geología*. 2001;18(2):1-6.
28. Columbié ÁO, Rodríguez J. Modelo matemático del proceso de calcinación del carbonato básico de níquel en el horno tubular rotatorio. *Minería y Geología*. 2000;17(2):47-58.
29. Columbié ÁO. Modelación matemática del proceso de calcinación del carbonato básico de níquel en el horno tubular rotatorio. [Tesis doctoral]. Moa: Instituto Superior Minero Metalúrgico de Moa "Dr. Antonio Núñez Jiménez"; 2001.

30. Columbié ÁO, Guzmán D. Sobre la modelación matemática del proceso de calcinación del carbonato básico de níquel en el horno tubular rotatorio. *Minería y Geología*. 1999;9(1):27-9.
31. Columbié ÁO, Guzmán D. Sobre la solución del modelo matemático del proceso de calcinación del carbonato básico de níquel. *Minería y Geología*. 2004;1-2:89-94.
32. Ajayi OO, Sheehan ME. Design loading of free flowing and cohesive solids in flighted rotary dryers. *Chemical Engineering Science*. 2012;73(7):400-11.
33. Sheehan E, Britton F, Schneider A. A model for solids transport in flighted rotary dryers based on physical considerations. *Chemical Engineering Science*. 2005;60(15):4171-82.
34. Mujumdar S, Ranade V. Simulation of Rotary Cement Kilns Using a One-Dimensional Model *Chemical Engineering Research and Design*. 2006;84(3):165-77.
35. Mujumdar S, Arora A, Ranade V. Modeling of Rotary Cement Kilns: Applications to Reduction in Energy Consumption. *Ind Eng Chem Res*. 2006;45(7):2315-30.
36. Shariari K, Tarasiewicz S. Modelling of a clinker rotary kiln using operating functions concept. *The Canadian Journal of Chemical Engineering*. 2011 89(2):345-59.
37. Gnielinski V. New equations for heat and mass-transfer in turbulent pipe and channel flow. *International Chemical Engineering*. 1976;16(2):359-68.
38. Peinado D, De Vega M. Energy and exergy analysis in an asphalt plant's rotary dryer. *Applied Thermal Engineering*. 2011;31 (6-7):1039-49.
39. Tarhan S, Telci I. Product quality and energy consumption when drying peppermint by rotary drum dryer. *Industrial Crops and Products*. 2010;32(3):420-77.
40. Ramírez IM, Ramírez B. Efecto de la postcombustión sobre los principales índices técnico-económicos en un horno Herreshoff para la producción de níquel. *Minería y Geología* 2021;37(4):426-44.
41. Angulo H, Legrá A, Lamorú A, Gálvez E, Castillo J, editors. Post-combustion Effect on Nickel and Cobalt Extractions from the Caron Process. *Fourth International Conference on Inventive Material Science Applications*; 2021: Springer.
42. Torres G. Modelación matemática para predecir el comportamiento del extractable de níquel en los Hornos de Reducción. [Tesis de Maestría]. Santiago de Cuba, Cuba: Universidad de Oriente; 1999.
43. Arrebola A. Pruebas con muestra tecnológica de Punta Gorda en la planta Piloto de Nicaro. *Informe Técnico*. Nicaro, Cuba: Centro de investigaciones; 1972.
44. Rodríguez M. Prueba de la muestra 5 de Punta Gorda en la planta piloto de Nicaro. *Informe Técnico*. Archivo Planta Piloto de Nicaro. Nicaro, Cuba; 1976.
45. Alepuz H. Introducción del petróleo Aditivo en la Empresa Comandante Ernesto Che Guevara. *Informes Parciales*. Moa, Cuba: Centro de Investigaciones del Níquel; 1993.

46. Marisy M. Sistema de Control de la temperatura en el hogar 4 [Trabajo de Diploma]. Santiago de Cuba: Universidad de Oriente; 1977.
47. Angulo M. Identificación y control extremal de un horno de reducción. [Tesis doctoral]. Praga: ČVUT (Universidad Técnica Superior de Praga); 1982.
48. Selva A. Regulación del Perfil de Temperatura de un Horno de Reducción. [Tesis doctoral]. Santiago de Cuba: Universidad de Oriente; 1984.
49. Unión del Níquel C. Proyecto de Modernización – Planta de Hornos de Reducción. Nicaro, Cuba; 1996.
50. Marrero S. Algoritmos de control del proceso de reducción en hornos de soleras múltiples [Tesis doctoral]. Leningrado: Instituto de Minas de Leningrado; 1989.
51. Gupta G, Chakraborti N, Sundararajan T. Development of a Mathematical Model for Multihearth Roasters. Metallurgical Transactions. 1989;20B:925-35.
52. Nath N, Chakrabortiand N, Shekhar R. Reduction of Indian nickeliferrous ore in a fixed bed reactor with gas flowing vertically through the bed. Scandinavian Journal of Metallurgy. 1998;27(1):14-22.
53. Ramírez M. Identificación experimental del subproceso de postcombustión en un horno de reducción de níquel. Minería y Geología. 2001;18(2):61-6.
54. Ramírez M. Identificación de sistemas (Apuntes para una monografía). Santiago de Cuba: Universidad de Oriente; 2014.
55. Ljung L. System Identification: Theory for the User. New Jersey 1987.
56. Landau I, Zito G. Digital Control Systems. Design, Identification and Implementation. Springer-Verlag, editor. London 2006.
57. Salcedo J, Rivas R, Sotomayor JJ. Design of a Generalized Predictive Controller for Temperature Control in a Cement Rotary Kiln. IEEE Latin America Transactions. 2018;16(4):1015-21.
58. Salcedo J, Rivas R, Sotomayor J. Design of a Robust H2 State Feedback Temperature Controller for a Steel Slab Reheating Furnace. Appl Sci. 2020;10(1731):15.
59. Devashena T, Dhanalakshmi K. Simultaneous measurements for the interlink of electro thermo-mechano-electro characteristics in shape memory springs. ISA Transactions. 2022;125:571-9.
60. Stavropoulos P, Papacharalampopoulos A, Michail CK, Chryssolouris G. Robust Additive Manufacturing Performance through a Control Oriented Digital Twin. Metals. 2021;11(708):19.
61. Hebb D. The Organization of Behavior. New York: John Wiley and sons; 1949.
62. Rosenblatt F. The perceptron: a probabilistic model for information storage and retrieval in the brain. Psych Rev. 1958;65:386-408.

63. Marichal GN. Diseño de políticas de identificación y control de robots basadas en redes neuronales y sistemas neuro-fuzzy [Tesis doctoral]: Universidad de La Laguna; 1999.
64. De Armas M, Gómez J, Pérez C, Meriño L, Sepúlveda J. Inteligencia artificial aplicada al análisis de sistemas energéticos con Matlab. Koral IG, editor. Cartagena de Indias, Colombia 2007.
65. Patan K. Artificial neural networks for the modelling and fault diagnosis of technical processes. Springer, editor 2008.
66. Kruger U, Xie L. Advances in statistical monitoring of complex multivariate processes: with applications in industrial process control. Chichester WS, editor. Hoboken, N.J. 2012.
67. Bello R. Curso Introductorio a las Redes Neuronales Artificiales. Cuba: Universidad de Las Villas; 2003.
68. Nørgaard M. Neural Networks for Modelling and Control of Dynamic Systems. Verlag S, editor. London 2000.
69. Arafet P, Chang F, Domínguez H, Torres MA, León E. Métodos de Identificación dinámica. Santiago de Cuba: Universidad de Oriente; 2004.
70. Rumelhart DE, Hinton GE, Williams RJ. Learning Internal Representations by Error Propagation. David E. Rumelhart JLM, and the PDP research group, editor: Parallel distributed processing: Explorations in the microstructure of cognition; 1986.
71. Santos M. Un Enfoque Aplicado del Control Inteligente. RIAI. 2011;8:283-96.
72. Cavalcanti FM, Schmal M, Giudici R, Brito RM. A catalyst selection method for hydrogen production through Water-Gas Shift Reaction using artificial neural networks. Journal of Environmental Management 2019;237:585-94.
73. Hoseinian FS, Rezai B, Kowsari E. The nickel ion removal prediction model from aqueous solutions using a hybrid neural genetic algorithm. Journal of Environmental Management 2017;204:311-7.
74. Wanga J, Zhaia Y, Yaoa P, Maa M, Wanga H. Established prediction models of thermal conductivity of hybrid nanofluids based on artificial neural network (ANN) models in waste heat system. International Communications in Heat and Mass Transfer. 2020;110(104444):1-11.
75. Valinger D, Jurina T, Šain A, Matešić N, Panic M, Benković M, et al. Development of ANN models based on combined UV-vis-NIR spectra for rapid quantification of physical and chemical properties of industrial hemp extracts. Phytochemical Analysis. 2020:1-13.
76. Jin X, Shao J, Zhang X, An W, Malekian R. Modeling of nonlinear system based on deep learning framework. Nonlinear Dyn. 2016;84(3):1327-40.
77. Li K, Kou J, Zhang W. Deep neural network for unsteady aerodynamic and aeroelastic modeling across multiple mach numbers. Nonlinear Dyn. 2019;96(3):2157-77.

78. Vlachas PR, Byeon W, Wan ZY, Sapsis T, Koumoutsakos P. Data-driven forecasting of highdimensional chaotic systems with long short-term memory networks. *Proc R Soc AMath Phys Eng Sci.* 2018;474(2213).
79. Wang R, Kalnay E, Balachandran B. Neural machine-based forecasting of chaotic dynamics. *Nonlinear Dyn.* 2019;98:2903-17.
80. Purnomo LAA, Biyanto TR. Neural network model for profile temperature of nickel kiln. *AIP Conference Proceedings* 2088; 29 March 2019.
81. LimaFontes DO, Vasconcelos LGS, Brito RP. Blast furnace hot metal temperature and silicon content prediction using soft sensor based on fuzzy C -means and exogenous nonlinear autoregressive models. *Computers and Chemical Engineering* 2020;141:1-10.
82. Santana E, Montero D, Vega O. Identification of the Air Supply System for Combustion, With the Help of Artificial Neural Networks. *Biomed J Sci&Tech Res* 2018;10(2):7714-7.
83. Santana E, Montero D, Vega O, Rojas I. The Applied Artificial Intelligence to the Control Electronics Improving the Energy Efficiency of Ventilation Systems in the Industry. *Biomed J Sci & Tech Res* 2020;25(5):19527-37.
84. Gómez JV. Modern approaches to control of a multiple hearth furnace in kaolin production. Finland: Aalto University; 2019.
85. Ma Y, Stopic S, Gronen L, Milivojevic M, Obradovic S, Friedrich B. Neural Network Modeling for the Extraction of Rare Earth Elements from Eudialyte Concentrate by Dry Digestion and Leaching. *Metals.* 2018;8(267):1-22.
86. Drndarevic D, Milivojevic M. Neural networks en powder metallurgy. In: Drvengrad M, editor. 11th International Scientific Conference “Science and Higher Education in Function of Sustainable Development”; 24-25 May Užice, Serbia 2019.
87. Wanga G, Ledwoch A, Ramin M, Grosua R, Brintrup A. A generative neural network model for the quality prediction of work in progress products. *Applied Soft Computing Journal* 2019;85(105683):1-13.
88. Hannulaa J, Kerna M, Luukkanenb S, Roinec A, Van den Boogaarta KG, Reuter MA. Property-based modelling and simulation of mechanical separation processes using dynamic binning and neural networks. *Minerals Engineering* 2018;126:52-63.
89. Das A, Sinha S, Ganguly S. Development of a blast-induced vibration prediction model using an artificial neural network. *The Journal of the Southern African Institute of Mining and Metallurgy.* 2019;119:187-200.
90. Rahaman M, Mu W, Odqvist J. Machine learning to predict the martensite start temperature in steels. *Met Mater Trans A.* 2019;50 (5):2081-91.
91. Gholami A, Khoshdast H. Using artificial neural networks for the intelligent estimation of selectivity index and metallurgical responses of a sample coal bioflotation by rhamnolipid biosurfactants. *Energy Sources.* 2020;Part A: Recovery, Utilization, and Environmental Effects.

92. Marchand D, Jain A, Glensk A, Curtin W. Machine learning for metallurgy I. A neural-network potential for Al-Cu. *Physical review materials* 2020;4(103601):1-21.
93. Niquini FGF, Costa JFCL. Mass and Metallurgical Balance Forecast for a Zinc Processing Plant Using Artificial Neural Networks. *Nat Resour Res.* 2020;29:3569-80.
94. Yemelyanov V, Chernyi S, Yemelyanova N, Varadarajan V. Application of neural networks to forecast changes in the technical condition of critical production facilities. *Computers and Electrical Engineering.* 2021;93(107225):1-9.
95. Bolton G, Berezowsky R, Day M. *Hidrometallurgy: Nickel now and next century.* Holanda: La Haya; 1997.
96. Habashi F. *Handbook of Extractive Metallurgy.* In: Wiley-VCH, editor. II. Weinheim, Germany 1997.
97. Grupo Técnico E. *Manual de Operaciones Planta "Hornos de Reducción".* Moa, Cuba: Empresa Productora de Níquel y Cobalto "Cmte. Ernesto Che Guevara"; 2007.
98. Angulo H, Terencio P, Legra A, Videaux L. Análisis especiales en un horno de reducción de níquel a escala de Planta Piloto. *Tecnología Química.* 2017;XXXVII(3):484-99.
99. EROS G. *Manual de operación EROS.* In: CERCONI, editor. Nicaro, Holguín 1997.
100. Ljung L. *System identification: Theory for the user 2ed.* Prentice Hall information and System Sciences Series TK, editor. Sweden 1999.
101. Ljung L. *"System Identification - Theory for the User".* 2nd ed. New Jersey 1998.
102. Gustavsson I. *Survey of Applications of Identification in Chemical and Physical Processes.* *Automática.* 1975;11(1):3-24.
103. Söderstrom T, Stoica P. *System Identification.* International P-H, editor. Hertfordshire 1989.
104. Garcia CE, Morari M. *Internal Model Control 2-Design Procedure for Multivariable Systems.* *Ind Eng Chem Process Des Dev.* 1985(24):484-94.
105. Selva A. *Curso de posgrado sobre Modelación Matemática con Datos Experimentales.* Moa: Instituto Superior Minero Metalúrgico de Moa "Dr. Antonio Núñez Jiménez"; 2000.
106. Roffel B, Betlem B. *Process Dynamics and Control: Modeling for Control and Prediction.* 1ra ed. Sons JWa, editor. Chichester 2006.
107. Isermann R. *Identification of dynamic systems. An introduction with application.* Heidelberg SB, editor. Germany 2011.
108. ICP DAS C. *I-7000 DIO Manual.* In: Corporation S, editor. 2000.
109. Irizar M. *La inteligencia computacional en la identificación de sistemas.* *Ingeniería Electrónica, Automática y Comunicaciones.* 2005; XXVI,(1):35-41.

110. Arafet P. Monografía sobre identificación de sistemas. Santiago de Cuba, Cuba: Universidad de Oriente; 2004.
111. Taqvi SA, Tufa LD, Zabiri H, Maulud AS, Uddin F. Fault Detection in Distillation Column Using Narx Neural Network. *Neural Comput Appl.* 2020;32:3503-19.
112. Diaconescu E. The Use of Narx Neural Networks to Predict Chaotic Time Series. *Wseas Trans Comput Res.* 2008;3:182-91.
113. Paul RK, Sinha K. Forecasting Crop Yield: Arimax and Narx Model. *RASHI* 2016;1:77-85.
114. Yu X, Chen Z, Qi L. Comparative Study of Sarima and Narx Models in Predicting the Incidence of Schistosomiasis in China. *Math Biosci Eng MBE.* 2019;16:2266-76.
115. Boussaada Z, Curea O, Remaci A, Camblong H, Mrabet N. A Nonlinear Autoregressive Exogenous (Narx) Neural Network Model for the Prediction of the Daily Direct Solar Radiation. *Energies* 2018;11(3):620.
116. Ghahari S, Queiroz C, Labi S, McNeil S. Cluster Forecasting of Corruption Using Nonlinear Autoregressive Models with Exogenous Variables (NARX)—An Artificial Neural Network Analysis. *Sustainability* 2021;13(20):11366.
117. Yu T, Zhu H. Hyper-Parameter Optimization: A Review of Algorithms and Applications. In: *arXiv*, editor. 2020.
118. Devijver PA, Kittler J. *Pattern Recognition: A Statistical Approach.* Hall P, editor. Londres 1982.
119. Raschka S. Model Evaluation, Model Selection, and Algorithm Selection in Machine Learning. In: [cs.LG] av, editor.: University of Wisconsin–Madison; 2020.
120. Quade M, Abel M, Nathan J, Brunton S. Sparse identification of nonlinear dynamics for rapid model recovery. *Chaos* 2018; 28(063116):1-10.
121. Akaike H. A new look at the statistical model identification. *IEEE Transactions on Automatic Control.* 1974;19(6):716-23.
122. Schwarz G. Estimating the dimension of a model. *The Annals of Statistics.* 1978;6(2):461-4.
123. Hurvich CM, Tsai CL. Regression and time series model selection in small samples. *Biometrika.* 1989;76(2):297-307.
124. Yuanlin G, Hua-Liang W, Balikhin M. Nonlinear predictive model selection and model averaging using information criteria. *Systems Science & Control Engineering.* 2018;6(1):319-28.
125. Benardos PG, Vosniakos GC. Optimizing Feedforward Artificial Neural Network Architecture. *Engineering Applications of Artificial Intelligence.* 2007;20(3):365-82.
126. Nørgaard M. *Neural Network Based System Identification Toolbox Version 1.1.* Technical report Denmark: Technical University of Denmark, Automation Do, Modelling DoM; 2000. Report No.: Report 97-E-851.

127. Milanés D. Arquitecturas de redes neuronales para la clasificación de tareas de imaginación motora [Tesis doctoral]. Santiago de Cuba: Universidad de Oriente; 2022.
128. Montero D. Modeling and simulation for the control of post-combustion in the conditions of the nickel reduction process. *Int Rob Auto J.* 2019;5(1):24-6.
129. Estrada I, Peña J, Guarnizo C. Estimación de modelos lineales para el control predictivo de pequeñas centrales hidroeléctricas. *Revista Soluciones de Postgrado EIA.* 2012(9):63-78.
130. Montero D. Identificación experimental del subproceso de postcombustión en un horno de reducción de níquel. *ENERMOA*; Moa, Cuba: Instituto Superior Minero Metalúrgico "Dr Antonio Núñez Jiménez"; 2012.
131. Montero D, Góngora E, Ramírez M. Identification OF Post-Combustion Sub-Process Using Artificial Neural Networks. *Biomed J Sci & Tech Res* 2019;21(4):16031-9.
132. Nojek S, Britos P, Rossi B, García Martínez R. Pronóstico de ventas: Comparación de predicción entre redes neuronales y método estadístico. *Reportes Técnicos en Ingeniería del Software.* 2003;5(1):1-12.
133. Trembobia B. Pruebas Termotécnicas para instalaciones de calderas. Moscú; 1991.
134. Montero D. Statistical Model of The Postcombustion Subprocess in an Oven of Multiple Homes. *Adv in Rob & Mech Engin.* 2019;2(2):120-5.

Anexos

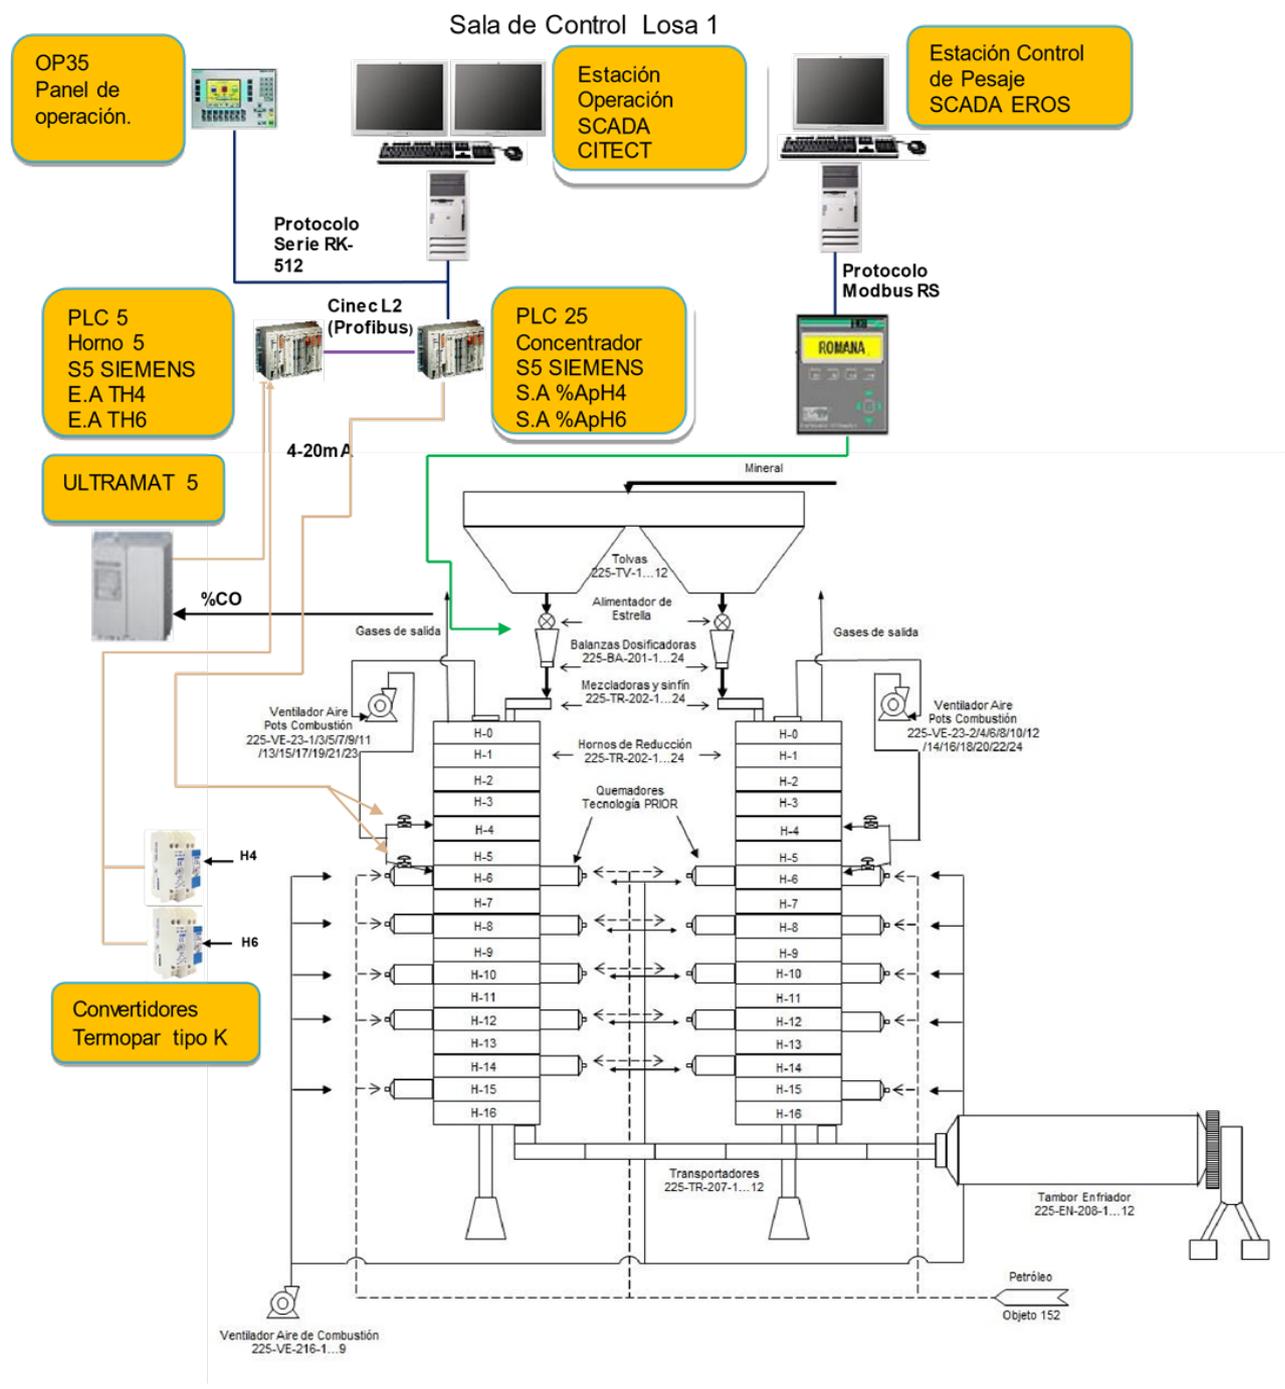
Anexo 1:

1. Vista lateral derecha de la Unidad Básica de Producción Planta Hornos de Reducción



Anexo 2:

2. Sistema de Supervisión y Control de una línea de hornos



Anexo 3:

3. Instrumentación vinculada al subproceso de postcombustión

VÁLVULAS DE MARIPOSA

La válvula de mariposa es de $\frac{1}{4}$ de vuelta y controla la circulación por medio de un disco circular, con el eje de su orificio en ángulos rectos al sentido de la circulación (figura A.1.1). La figura A.1.2 muestra sus características.

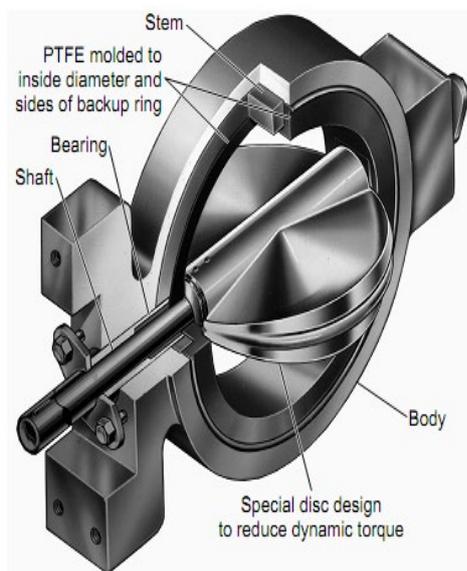


Figura A.1.1-Válvula de mariposa

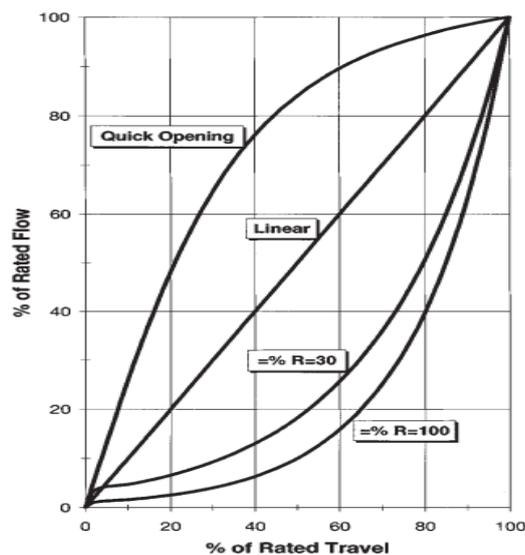


Figura A.1.2-Diferentes características de las válvulas

Recomendada para: servicio con apertura total o cierre total, estrangulación, accionamiento frecuente, cuando se requiere corte positivo para gases o líquidos, cuando solo se permite un mínimo de fluido atrapado en la tubería, baja caída de presión a través de la válvula.

Aplicaciones: servicio general, líquidos, gases, pastas semilíquidas, líquidos con sólidos en suspensión.

Ventajas: ligera de peso, compacta, bajo costo, requiere poco mantenimiento, número mínimo de piezas móviles, no tiene bolas o cavidades, alta capacidad y circulación en línea recta.

Anexo 3 (Continuación 1):

POSICIONADOR ELECTRONEUMÁTICO SIPART PS2.



Figura A.2.1-Posicionador electroneumático SIPART PS2



Figura A.2.2-Posicionador electroneumático SIPART PS2 EExd en envolvente antideflagrante

Los posicionadores electroneumáticos se utilizan en sistemas electrónicos de automatización para el control de válvulas y elementos finales de control con accionamientos de empuje o de giro. El posicionador electroneumático SIPART PS2 es un aparato de campo digital con un microprocesador de alta integración, destacándose marcadamente de los posicionadores convencionales.

Los posicionadores SIPART PS2 se caracterizan por varias ventajas decisivas:

- Gran facilidad de montaje y una puesta en servicio automática (calibración automática del cero y del alcance)
- Una excelente calidad de regulación que se obtiene gracias al método de adaptación en línea.
- Consumo de aire insignificante en servicio estacionario.
- Función de "cierre estanco" (proporciona una fuerza de actuación máxima sobre el asiento de la válvula).
- Un sinnúmero de funciones pueden activarse por simple configuración (características y límites).

Anexo 3 (Continuación 2):

TERMOPARES TIPO K CROMEL-ALUMEL

Un termopar es un dispositivo de dos alambres hechos de metales o aleaciones diferentes con uno de sus extremos unido mediante soldadura. La figura A.3.1 muestra varios tipos de termopares ofrecidos por *Omega Engineering*.

El termopar tipo K Cromel-Alumel es muy usado en atmósfera oxidante, donde haya exceso de oxígeno libre. Ambos materiales poseen conductividad térmica baja y, nuevos son fuertes y resistentes. La fuerza termoeléctrica es alta y aproximadamente uniforme con amplio rango de temperatura (alrededor de $41,5\mu\text{v} / ^\circ\text{C}$ en el rango usual: 600 a 900 $^\circ\text{C}$).

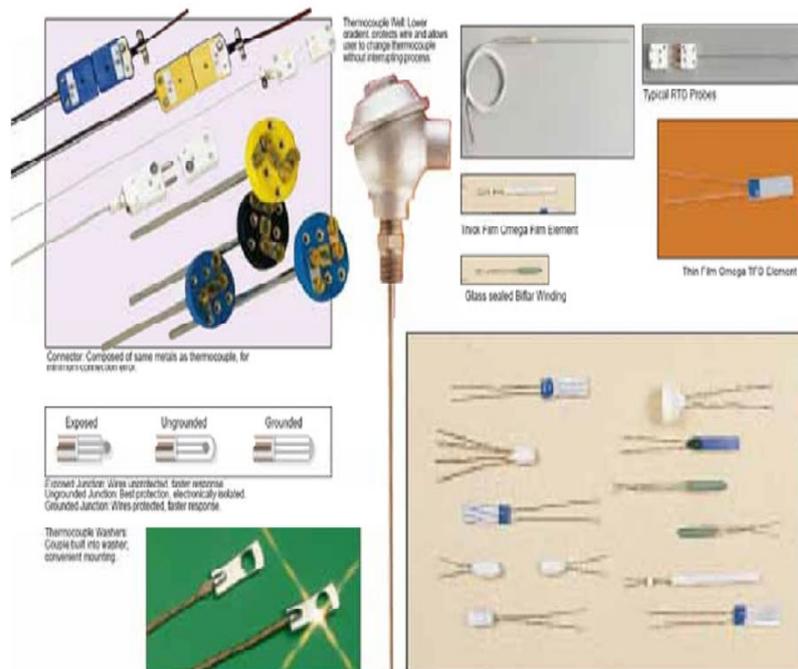


Figura A.3.1- Varios Tipos de Termopares

Anexo 3 (Continuación 3):

AUTÓMATAS PROGRAMABLES S5 SIEMENS.

El autómata S5 (figura A.4.1) es un sistema de mando programable de la familia SIMATIC S5. Ha sido desarrollado expresamente para realizar tareas de automatización a baja potencia. No es un “aparato compacto”, sino compuesto por varios módulos que se pueden agrupar en función de la tarea de automatización a resolver.



Figura A.4.1- PLC S5 de SIEMENS

Ventajas:

- Menor tiempo empleado en la elaboración de proyectos, no es necesario dibujar esquemas o simplificar.
- Posibilidad de introducir modificaciones sin cambiar el cableado.
- Menor espacio ocupado por el cuadro eléctrico.
- Menor costo en el montaje.
- Mantenimiento más barato.
- Aumento de fiabilidad del sistema, elimina los contactos eléctricos físicos y móviles.
- Permite la auto detección de averías.
- Control de varias máquinas con un autómata.

Anexo 3 (Continuación 4):

Analizador de gases ULTRAMAT 5



Figura A.5.1- ULTRAMAT 5

El ULTRAMAT 5 (figura A.5.1) es un analizador de gas por radiación infrarroja no dispersiva de alta selectividad. El analizador trabaja según el procedimiento del doble haz infrarrojo modulado. Este instrumento es apropiado para la medida de gases, cuyas bandas de absorción se encuentren en el margen de longitud de onda de 1 a 10 μm , por ejemplo, CO, CO₂, NO, SO₂, NH₃, CH₄ y otros hidrocarburos. Posee también cámaras de filtrado llenas de gas, filtros ópticos, cámaras receptoras, acoplamiento óptico-variable para minimizar la perturbación. A continuación, se representan los elementos principales del principio de medida del ULTRAMAT 5.

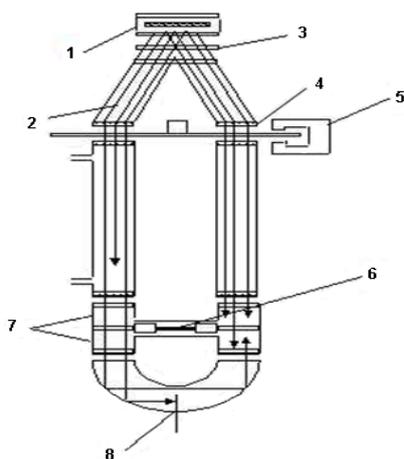


Figura A.5.1- Principio de medida

1. Emisor de radiación
2. Divisor de haz
3. Filtro IR
4. Obturador rotativo
5. Accionamiento de corrientes
6. Microdetector de caudal
7. Cámara receptora
8. Acoplador óptico, ajustable

Anexo 4:**4. Características de las materias primas durante la realización de experimentos activos.**Tabla I Características del mineral y el *fuel-oil*.

<i>Características del mineral</i>	<i>Valor</i>	<i>Características del Fuel-oil recibido</i>	<i>Unidad de medida</i>	<i>Valor</i>
% Ni	1,13	Viscosidad a 50 °C	cSt	469,07
% Fe	40,5	Densidad API	API	12
% Co	0,109	Punto de inflamación	°C	97
% Ext Ni	76,8	Carbón Conradson	%	8,71
% Ext Co	55,4	Ceniza	%	0,2
% SiO ₂	2,85	Impureza Mecánica	%	0,02
Granulometría	7,41(+100)	Asfaltenos	%	4,62
Granulometría	6,17(+200)	Valor calórico	Kcal/kg	10 205,8
Granulometría	86,42 (-200)	Densidad	g/cm ³	0,9855

Anexo 5:

5. Análisis estadístico descriptivo del perfil térmico del horno en 2015.

En la tabla II aparecen los valores promedios (μ) y las desviaciones estándar (s) para cada una de las variables que se miden en el horno durante los meses de 2015.

En la tabla III del anexo 5 (Continuación 1) se presenta la estadística descriptiva del perfil de H4 y H6, donde se observa que los valores de Curtosis y Coeficiente de asimetría permiten afirmar que las variables dependientes (TH4 y TH6) se comportan como distribuciones normales (figuras A.6.1 y A.6.2). Además, ambas temperaturas oscilaron alrededor de los 700 °C, lo que favoreció el desarrollo del subproceso de postcombustión [134].

Tabla II Media (μ) y desviación estándar (s) de las variables del horno en 2015.

<i>Variables</i>	<i>meses de 2015</i>	
	μ	s
ApH4	42,7	24,7
ApH6	24,2	10,2
TH0	427,2	25,2
TH2	534,1	34,7
TH4	720,2	76,9
TH6	717,8	68,8
TH7	557,7	36,7
TH9	671,5	28,8
TH11	726,5	24,1
TH13	711,0	24,2
TH14	730,5	27,2
TH15	767,3	31,9
PH0	7,4	2,6
PH16	2,1	1,3
TC6N	1333,8	172,0
TC6S	1359,2	94,2
TC8N	1352,2	106,8
TC8S	1352,0	111,0
TC10N	1084,0	159,2
TC10S	858,0	73,7
TC15N	1348,3	144,9
TC15S	1344,7	143,9
CO	1,3	1,4

Anexo 5 (Continuación 1):

Tabla III Resumen del análisis estadístico descriptivo de la muestra en 2015.

<i>Funciones estadísticas</i>	<i>Tres meses (mayo a julio)</i>	
	<i>TH4</i>	<i>TH6</i>
Media	720,2	717,8
Error típico	0,3	0,3
Mediana	734,9	726,9
Moda	481,0	503,5
Desviación estándar	76,9	68,8
Varianza de la muestra	5 918,1	4736,7
Curtosis	0,7	1,1
Coefficiente de asimetría	-0,8	-0,7
Rango	475,8	428,3
Mínimo	480,9	503,2
Máximo	956,7	931,5
Suma	46 200 017,5	46 041 099,1
Cuenta	64 146	64 146
Nivel de confianza (95,0 %)	0,6	0,5

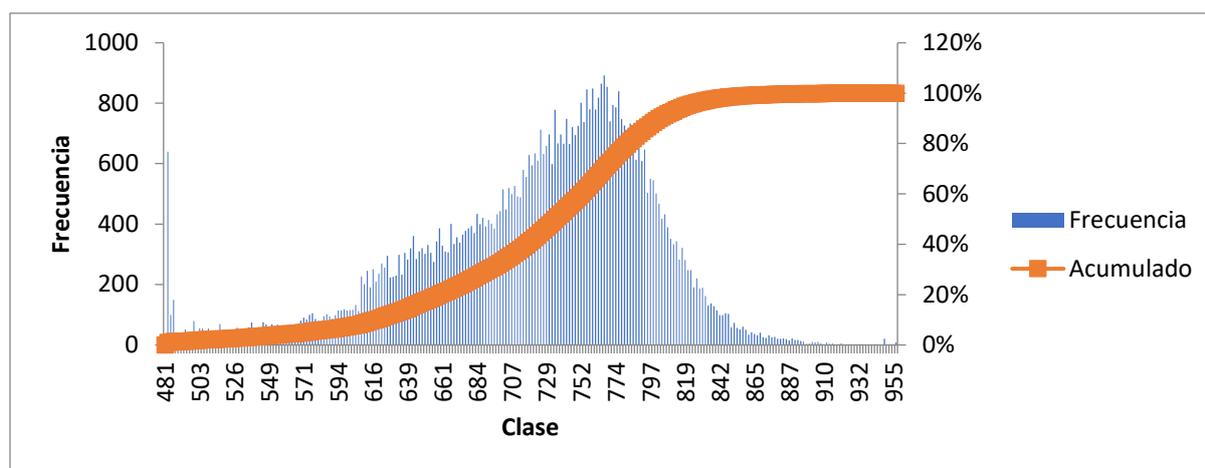


Figura A.6.1- Histograma de la temperatura del hogar cuatro (TH4) (mayo-julio 2015)

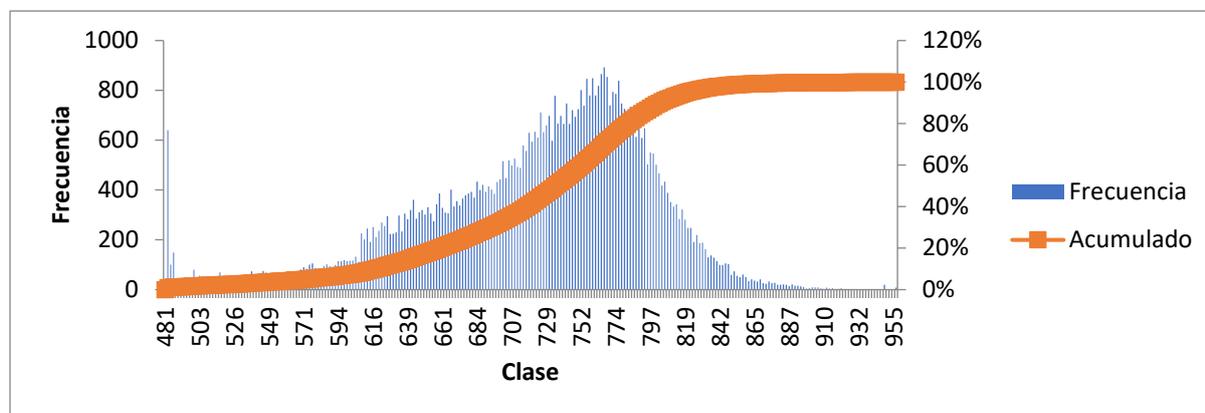


Figura A.6.2- Histograma de la temperatura del hogar seis (TH6) (mayo-julio 2015)

Anexo 5 (Continuación 2):

Los resultados del análisis mediante métodos descriptivos de series temporales se muestran en las tablas IV y V, donde aparecen las autocorrelaciones estimadas entre los valores de TH4 y TH6 en diferentes retrasos. También se reflejan los límites de probabilidad del 95 % alrededor de 0. Si los límites de probabilidad para un retraso particular no contienen el coeficiente estimado, existe una correlación estadísticamente significativa con ese retraso en el nivel de confianza del 95 %. En estos casos los 24 coeficientes de autocorrelación son estadísticamente significativos al nivel de confianza del 95 %.

Tabla IV Autocorrelaciones estimadas para TH4.

Retraso	Autocorrelación	Error Estándar	Límite en 95 %	
			Bajo	Alto
1	0,993226	0,00692095	-0,0135648	0,0135648
2	0,975665	0,0119334	-0,023389	0,023389
3	0,951535	0,0152839	-0,029956	0,029956
4	0,924331	0,017898	-0,0350794	0,0350794
5	0,896625	0,0200546	-0,0393064	0,0393064
6	0,870123	0,0218907	-0,0429051	0,0429051
7	0,845787	0,023489	-0,0460377	0,0460377
8	0,823995	0,0249051	-0,0488132	0,0488132
9	0,804679	0,0261784	-0,0513088	0,0513088
10	0,787535	0,0273375	-0,0535807	0,0535807
11	0,772208	0,0284034	-0,0556698	0,0556698
12	0,758373	0,0293919	-0,0576071	0,0576071
13	0,745805	0,0303147	-0,0594157	0,0594157
14	0,73436	0,0311812	-0,0611141	0,0611141
15	0,723921	0,0319989	-0,0627167	0,0627167
16	0,714382	0,032774	-0,0642359	0,0642359
17	0,705619	0,0335115	-0,0656815	0,0656815
18	0,697527	0,0342158	-0,0670618	0,0670618
19	0,69001	0,0348903	-0,0683838	0,0683838
20	0,682947	0,0355379	-0,0696531	0,0696531
21	0,676214	0,0361611	-0,0708746	0,0708746
22	0,669723	0,0367618	-0,0720519	0,0720519
23	0,663491	0,0373417	-0,0731884	0,0731884
24	0,657623	0,0379021	-0,074287	0,074287

Anexo 5 (Continuación 3):

Tabla V Autocorrelaciones estimadas para TH6.

Retraso	Autocorrelación	Error Estándar	<i>Límite en 95 %</i>	
			Bajo	Alto
1	0,987102	0,00692095	-0,0135648	0,0135648
2	0,953768	0,0118846	-0,0232934	0,0232934
3	0,908649	0,0151126	-0,0296201	0,0296201
4	0,858936	0,0175353	-0,0343685	0,0343685
5	0,809691	0,0194464	-0,0381144	0,0381144
6	0,763853	0,0209993	-0,0411579	0,0411579
7	0,722716	0,0222905	-0,0436886	0,0436886
8	0,686614	0,023386	-0,0458357	0,0458357
9	0,655258	0,0243324	-0,0476908	0,0476908
10	0,628039	0,0251634	-0,0493195	0,0493195
11	0,604333	0,0259034	-0,0507698	0,0507698
12	0,583697	0,0265702	-0,0520766	0,0520766
13	0,565789	0,0271774	-0,0532669	0,0532669
14	0,550138	0,0277359	-0,0543614	0,0543614
15	0,536333	0,0282537	-0,0553764	0,0553764
16	0,524183	0,0287373	-0,0563241	0,0563241
17	0,513449	0,0291916	-0,0572147	0,0572147
18	0,503908	0,0296211	-0,0580563	0,0580563
19	0,495388	0,0300289	-0,0588556	0,0588556
20	0,487608	0,0304178	-0,0596179	0,0596179
21	0,480195	0,0307899	-0,0603473	0,0603473
22	0,472879	0,0311466	-0,0610463	0,0610463
23	0,465551	0,0314886	-0,0617167	0,0617167
24	0,458265	0,0318166	-0,0623595	0,0623595

Anexo 6:

6. Vista en el CITECT de los experimentos 1 y 2 con señales binarias pseudoaleatorias.



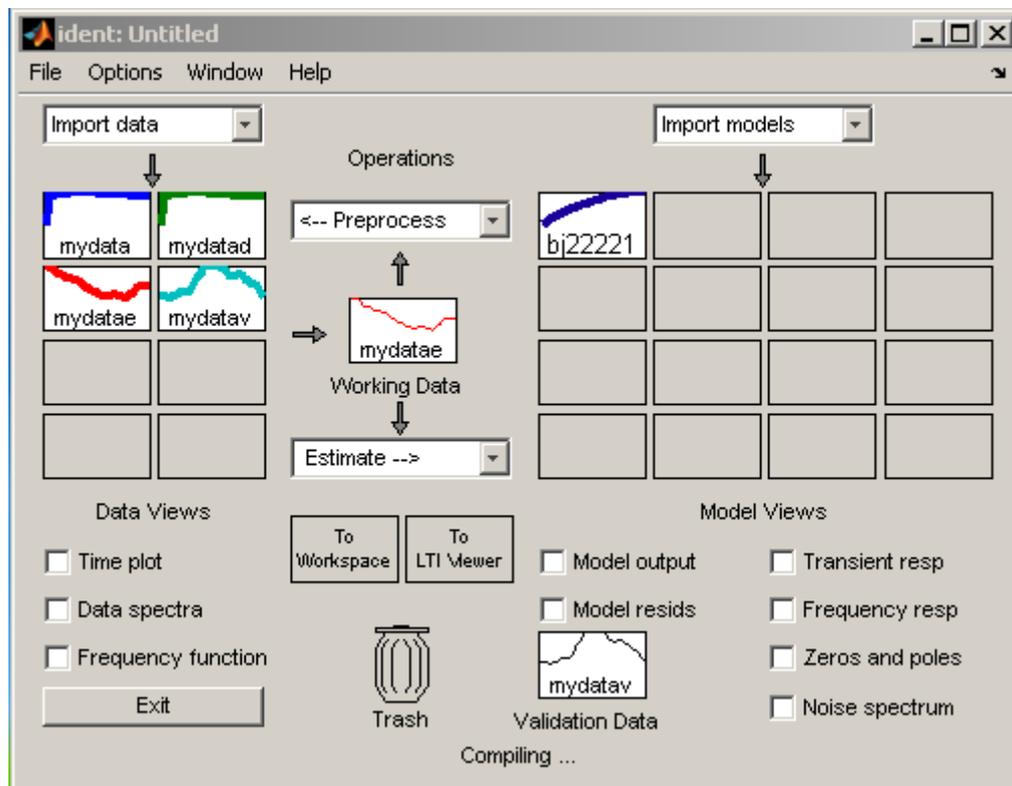
Figura A.7.1- Variación del flujo de aire en H4 (Exp # 1)



Figura A.7.2-Variación del flujo de aire en H6 (Exp # 2)

Anexo 7:

7. Toolbox de identificación del MATLAB®



Anexo 8:

8. Código para el modelo NARX utilizando el toolbox “NNSYSD” de MATLAB®.

```
% Para el entrenamiento se utiliza la función 'general'y'generall', utilizada para
entrenar los controladores que utilizan el modelo inverso del proceso.
clear
N2=length(U); % Se toma el tamaño de los datos
N1=floor(N2/2); % División en dos de los datos
Ye = Y(1:N1)'; % Datos de entrenamiento para H4 (AbH4)
Y1e = Y1(1:N1)'; % Datos de entrenamiento para H6 (AbH6)
Ue = U(1:N1)'; % Datos de entrenamiento para H4 (TH4)
U1e = U1(1:N1)'; % Datos de entrenamiento para H4 (TH6)
Yv = Y(N1+1:N2)'; % Datos de validación para H4 (AbH4)
Y1v = Y1(N1+1:N2)'; % Datos de validación para H6 (AbH6)
Uv = U(N1+1:N2)'; % Datos de validación para H4 (TH4)
U1v = U1(N1+1:N2)'; % Datos de validación para H6 (TH6)
%-----Entrenamiento del modelo inverso del controlador de H4 -----
NetDefi = ['HHHHH';'L----']; %estructura de la red
NN = [2 2 1]; %coeficientes de la estructura paramétrica
[W1i,W2i,PI_vector,iteration,lambda]=general(NetDefi,NN,[],[],[],Ye,Ue);
[Yhat,PI] = invsim(NetDefi,NN,W1i,W2i,Yv,Uv);
figure(3)
semilogy(PI_vector); grid;
xlabel('Iteración');
ylabel('Criterio');
title('Entrenamiento del modelo inverso de la red para H4')
figure(4)
plot(Yhat(1:1000),'r'), hold on , plot(Uv(1:1000),'b');
xlabel('Muestras');
title('Predicción de la red (rojo)y señal de control(azul)para H4')
save inverseH4 W1i W2i NetDefi NN % parámetros para el control inverso directo
de H4 (invcon).
save inverse3H4 W1i W2i NetDefi NN % parámetros para el control por modelo
interno de H4 (imccon).
NNi=NN;
W1c=W1i;
W2c=W2i;
NetDefc=NetDefi;
save inverse2H4 W1i W2i NetDefi NNi % parámetros PID feedback + neural feedforward
control de H4 (ffcon).
save initoptH4 W1c W2c NetDefc NN % parámetros para el control óptimo de H4
(optcon).

%-----Entrenamiento del modelo inverso del controlador de H6 ---
NetDefi1 = ['HHHHH';'L----']; %estructura de la red
NN1 = [2 2 1]; %coeficientes de la estructura paramétrica
[W1i1,W2i1,PI_vector1,iteration,lambda]=generall(NetDefi1,NN1,[],[],[],Y1e,U1e);
[Yhat1,PI] = invsim1(NetDefi1,NN1,W1i1,W2i1,Y1v,U1v);
figure(5)
save inverseH6 W1i1 W2i1 NetDefi1 NN1 % parámetros para el control inverso
directo de H4 (invcon).
save inverse3H6 W1i1 W2i1 NetDefi1 NN1 % parámetros para el control por modelo
interno de H4 (imccon).

NNi1=NN1;
W1c1=W1i1;
```

Anexo 8 (Continuación 1):

```
W2c1=W2i1;
NetDefc1=NetDefi1;
save inverse2H6 W1i1 W2i1 NetDefi1 NNi1 % parámetros PID feedback + neural
feedforward control de H4 (ffcon).
save initoptH6 W1c1 W2c1 NetDefc1 NNi1 % parámetros para el control óptimo de
H4 (optcon).
figure(7)
semilogy(PI_vector1); grid;
xlabel('Iteración');
ylabel('Criterio');
title('Entrenamiento del modelo inverso de la red para H6')
figure(8)
plot(Yhat1(1:1000), 'r'), hold on , plot(U1v(1:1000), 'b');
xlabel('Muestras');
title('Predicción de la red (rojo) y señal de control (azul) para H6')
```

Anexo 9:

9. Código para el modelo NARX utilizando “Deep Learning Toolbox” de MATLAB®

```
% Vsimin - input time series.
% Vsimout - feedback time series.
rng(17)
load DATOS
X = tonndata(Vsimin,false,false);
T = tonndata(Vsimout,false,false);
for hiddenLayerSize = 1:30
% Choose a Training Function
% For a list of all training functions type: help nntrain
% 'trainlm' is usually fastest.
% 'trainbr' takes longer but may be better for challenging problems.
% 'trainscg' uses less memory. Suitable in low memory situations.
trainFcn = 'trainlm'; % Levenberg-Marquardt backpropagation.
% Create a Nonlinear Autoregressive Network with External Input
inputDelays = 1:5;
feedbackDelays = 1:5;
net = narxnet(inputDelays,feedbackDelays,hiddenLayerSize,'open',trainFcn);
testArray = zeros(16, 1);
for i = 1:16
% Choose Input and Feedback Pre/Post-Processing Functions
% Settings for feedback input are automatically applied to feedback output
% For a list of all processing functions type: help nnprocess
% Customize input parameters at: net.inputs[94].processParam
% Customize output parameters at: net.outputs{i}.processParam
net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'};
net.inputs{2}.processFcns = {'removeconstantrows','mapminmax'};

% Prepare the Data for Training and Simulation
% The function PREPARETS prepares timeseries data for a particular network,
% shifting time by the minimum amount to fill input states and layer
% states. Using PREPARETS allows you to keep your original time series data
% unchanged, while easily customizing it for networks with differing
% numbers of delays, with open loop or closed loop feedback modes.
[x,xi,ai,t] = preparets(net,X,{},T);

% Setup Division of Data for Training, Validation, Testing
% For a list of all data division functions type: help nndivision
net.divideFcn = 'dividerand'; % Divide data randomly
net.divideMode = 'time'; % Divide up every sample
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

% Choose a Performance Function
% For a list of all performance functions type: help nnperformance
net.performFcn = 'mse'; % Mean Squared Error

% Choose Plot Functions
% For a list of all plot functions type: help nnplot
net.plotFcns = {'plotperform','plottrainstate','ploterrhist','plotregression',
'plotresponse','ploterrcorr','plotinerrcorr'};
```

Anexo 9 (Continuación 1):

```
% Train the Network
[net,tr] = train(net,x,t,xi,ai);
tr.best_tperf;
% Test the Network
y = net(x,xi,ai);
e = gsubtract(t,y);
performance = perform(net,t,y)

% Recalculate Training, Validation and Test Performance
trainTargets = gmultiply(t,tr.trainMask);
valTargets = gmultiply(t,tr.valMask);
testTargets = gmultiply(t,tr.testMask);
trainPerformance = perform(net,trainTargets,y)
valPerformance = perform(net,valTargets,y)
testPerformance = perform(net,testTargets,y);
testArray(i, 1) = testPerformance;
end
s = strcat ('testArray',sprintf('%2d',hiddenLayerSize));
save (s, 'testArray');
end
% View the Network
%view(net)

% Plots
% Uncomment these lines to enable various plots.
%figure, plotperform(tr)
%figure, plottrainstate(tr)
%figure, ploterrhist(e)
%figure, plotregression(t,y)
%figure, plotresponse(t,y)
%figure, ploterrcorr(e)
%figure, plotinerrcorr(x,e)

% Closed Loop Network
% Use this network to do multi-step prediction.
% The function CLOSELOOP replaces the feedback input with a direct
% connection from the output layer.
netc = closeloop(net);
netc.name = [net.name ' - Closed Loop'];
%view(netc)
[xc,xic,aic,tc] = preparets(netc,X,{},T);
yc = netc(xc,xic,aic);
closedLoopPerformance = perform(net,tc,yc)

% Multi-step Prediction
% Sometimes it is useful to simulate a network in open-loop form for as
% long as there is known output data, and then switch to closed-loop form
% to perform multistep prediction while providing only the external input.
% Here all but 5 timesteps of the input series and target series are used
% to simulate the network in open-loop form, taking advantage of the higher
% accuracy that providing the target series produces:
numTimesteps = size(x,2);
knownOutputTimesteps = 1:(numTimesteps-5);
predictOutputTimesteps = (numTimesteps-4):numTimesteps;
X1 = X(:,knownOutputTimesteps);
T1 = T(:,knownOutputTimesteps);
[x1,xio,aio] = preparets(net,X1,{},T1);
[y1,xfo,afo] = net(x1,xio,aio);
```

Anexo 9 (Continuación 2):

```
% Next the the network and its final states will be converted to
% closed-loop form to make five predictions with only the five inputs
% provided.
x2 = X(1,predictOutputTimesteps);
[netc,xic,aic] = closeloop(net,xfo,afo);
[y2,xfc,afc] = netc(x2,xic,aic);
multiStepPerformance = perform(net,T(1,predictOutputTimesteps),y2)
% Alternate predictions can be made for different values of x2, or further
% predictions can be made by continuing simulation with additional external
% inputs and the last closed-loop states xfc and afc.

% Step-Ahead Prediction Network
% For some applications it helps to get the prediction a timestep early.
% The original network returns predicted y(t+1) at the same time it is
% given y(t+1). For some applications such as decision making, it would
% help to have predicted y(t+1) once y(t) is available, but before the
% actual y(t+1) occurs. The network can be made to return its output a
% timestep early by removing one delay so that its minimal tap delay is now
% 0 instead of 1. The new network returns the same outputs as the original
% network, but outputs are shifted left one timestep.
nets = removedelay(net);
nets.name = [net.name ' - Predict One Step Ahead'];
%view(nets)
[xs,xis,ais,ts] = preparets(nets,X,{},T);
ys = nets(xs,xis,ais);
stepAheadPerformance = perform(nets,ts,ys)

% Deployment
% Change the (false) values to (true) to enable the following code blocks.
% See the help for each generation function for more information.
if (false)
    % Generate Matlab function for neural network for application
    % deployment in Matlab scripts or with Matlab Compiler and Builder
    % tools, or simply to examine the calculations your trained neural
    % network performs.
    genFunction(net,'myNeuralNetworkFunction');
    y = myNeuralNetworkFunction(x,xi,ai);
end
if (false)
    % Generate a matrix-only Matlab function for neural network code
    % generation with Matlab Coder tools.
    genFunction(net,'myNeuralNetworkFunction','MatrixOnly','yes');
    x1 = cell2mat(x(1,:));
    x2 = cell2mat(x(2,:));
    xi1 = cell2mat(xi(1,:));
    xi2 = cell2mat(xi(2,:));
    y = myNeuralNetworkFunction(x1,x2,xi1,xi2);
end
if (false)
    % Generate a Simulink diagram for simulation or deployment with.
    % Simulink Coder tools.
    gensim(net);
end
```

Anexo 10:

10. Producción científica del autor sobre el tema de la tesis

Artículos científicos

1. **Deynier Montero G, et al.** Identification of the Air Supply System for Combustion, With the Help of Artificial Neural Networks. *Biomed J Sci&Tech Res* 10(2)-2018. BJSTR. MS.ID.001929. DOI: 10.26717/ BJSTR.2018.10.001929.
2. **Gongora DM.** Modeling and simulation for the control of post-combustion in the conditions of the nickel reduction process. *Int Rob Auto J.* 2019;5(1):24–26. DOI: 10.15406/iratj.2019.05.00167
3. **Deynier Montero Góngora.** Statistical Model of The Postcombustion Subprocess in an Oven of Multiple Hearth Furnace. *Adv in Rob &Mech Engin* 2(2)- 2019. ARME.MS.ID.000133. DOI: 10.32474/ARME.2019.02.000133.
4. **Deynier Montero G, et al.** Identification OF Post-Combustion Sub-Process Using Artificial Neural Networks. *Biomed J Sci & Tech Res* 21(4)-2019. BJSTR.MS.ID.003633.
5. **Deynier Montero Góngora, et al.** The Applied Artificial Intelligence to the Control Electronics Improving the Energy Efficiency of Ventilation Systems in the Industry. *Biomed J Sci & Tech Res* 25(5)-2020. BJSTR.MS.ID.004273.

Eventos

6. **Montero, D;** Ramírez, M. Identificación experimental del subproceso de postcombustión en un horno de Reducción de Níquel. En: Fórum tecnológico especial de energía. Moa. 2012, ISBN: 978-959-16-2067-5
7. Ramírez, M; **Montero, D;** Díaz, E. Identificación con redes neuronales en un Horno de Reducción de Níquel. En: XI Simposio Internacional de automatización, Informática. La Habana, 2013.

Anexo 10 (Continuación 1):

8. **Montero, D;** Ramírez, M; Rodríguez, L. Modelación y Simulación para el control de la postcombustión en las condiciones del proceso de reducción de la Empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara”. En: VII Conferencia internacional de aprovechamiento de recursos minerales. Moa. 2013. ISBN: 978-959-16-2244-0.
9. **Montero, D;** Ramírez, M; Góngora E. Modelación matemática de la postcombustión de un horno industrial para disminuir el consumo energético. En: Taller “La cooperación científica y tecnológica para el desarrollo energético sostenible de la provincia Holguín”. EXPOCIENCIA Holguín. 2017.
10. **Montero, D;** Cruz, E; Vega, O. Modelación del sistema de suministro de aire para la combustión, con ayuda de redes neuronales artificiales. En: VII Conferencia Internacional Ciencia y Tecnología por un Desarrollo Sostenible CYTDES, Camagüey. 2017. ISBN: 978-959-16-3337-8; En: II Taller Científico de Eficiencia de la Empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara”. Moa. Octubre, 2017.
11. **Montero, D;** Santana, E; Vega, O. Modelación de la postcombustión y del sistema de ventilación en hornos de reducción para mejorar la eficiencia energética en la industria del Níquel. En: III Congreso de MANTENERG, componente de 3ra Convención Internacional CUBAINDUSTRIA. La Habana, 2018. ISSN-1607-6281.
12. Santana, E; Vega, O; **Montero, D.** Alternativas de control de los ventiladores en banco de ensayos para flujo de aire”. En: XIII Taller Internacional Cuba Solar Las Tunas, 2018. ISBN 978-959-7113-53-9
13. **Montero, D;** Santana, E; Vega, O. Modelación de la postcombustión y del sistema de ventilación en hornos de reducción para mejorar la eficiencia energética en la industria del Níquel. En: Fórum Municipal y Provincial de Ciencia y Técnica, Moa 2017; EXPOCIENCIA Holguín, 2018.

Anexo 10 (Continuación 2):

14. **Montero, D;** Santana, E; Vega, O. Modelación de la postcombustión en un horno de múltiples hogares En: VIII Simposio Internacional “La Energía Eléctrica y Mecánica por un desarrollo sostenible”. Cayo Santa María, 2019.
15. **Deynier Montero Góngora.** Mathematical modeling of processes through experimental identification and artificial intelligence techniques for the improvement of energy and metallurgical efficiency. En: 5th International Conference and Expo on Ceramics and Composite Materials. London, UK, 2019.
16. Santana, E; **Montero, D;** Vega, O; Rojas, I. Modelación del sistema de ventilación en hornos de reducción para mejorar la eficiencia energética en la industria del Níquel. En: VIII Simposio Internacional “La Energía Eléctrica y Mecánica por un desarrollo sostenible”. Cayo Santa María, 2019.
17. **Montero, D;** Ramírez, M. Post-combustion artificial neural network modeling of nickel-producing multiple hearth furnace. ISBN 978-5-94211-915-7(Volume 1), Pages 248-250. En XVI International Forum-Contest of Students and Young Researchers “Topical Issues of Rational Use of Natural Resources”. Saint-Petersburg Mining University, Russia, 2020.
18. **Deynier Montero Góngora.** Modelación de la postcombustión en un horno de múltiples hogares utilizando redes neuronales artificiales. ISBN: 978-959-16-4770-2. X Taller internacional de Electromecánica ELECTROMECA'22. CINAREM 22. Moa, 2022.
19. **Montero, D;** Columbié, A; Montero, R; Trujillo, R. Modelación dinámica para contribuir a la eficiencia energética de la reducción de mineral laterítico. Taller: “Respuestas de programas y proyectos de demandas CTI de sectores estratégicos: energía y alimentos”. EXPOCIENCIA 2022.

Anexo 10 (Continuación 3):

Tesis tutoradas sobre el tema

1. Rodríguez, E. Modelación del sistema de suministro de aire para la combustión, con ayuda de redes neuronales artificiales. Tesis de Ingeniería. ISMMM. 2017.
2. Naval, U. G. Modelación del subproceso de postcombustión en un horno de reducción de níquel de la Empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara”. Universidad de Moa. 2020.

Participación en proyectos

1. **Reducción del consumo de energía eléctrica en la Planta Hornos de Reducción de la Empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara” en Moa**, proyecto asociado a programa nacional; en coordinación con la Universidad de Camagüey. Diciembre/2015-2018. El profesor participó como coordinador de la entidad ejecutora ISMM, Moa.
2. **Diagnóstico tecnológico, energético y organizacional a la Planta Hornos de Reducción.** Investigación Aplicada. Proyecto Empresarial UMoa-ECG. 05-06/2021