



INSTITUTO SUPERIOR MINERO METALÚRGICO DE MOA
“DR. ANTONIO NÚÑEZ JIMÉNEZ”
FACULTAD METALURGIA-ELECTROMECAÁNICA

Tesis presentada en opción al título de Master en Ciencias Técnicas

**MODELACIÓN DE LA POSTCOMBUSTIÓN EN UN HORNO DE MÚLTIPLES
HOGARES UTILIZANDO REDES NEURONALES ARTIFICIALES**

DEYNIER MONTERO GÓNGORA

Moa, 2016



INSTITUTO SUPERIOR MINERO METALÚRGICO DE MOA
“DR. ANTONIO NÚÑEZ JIMÉNEZ”
FACULTAD METALURGIA-ELECTROMECAÁNICA

Tesis presentada en opción al título de Master en Ciencias Técnicas

**MODELACIÓN DE LA POSTCOMBUSTIÓN EN UN HORNO DE MÚLTIPLES
HOGARES UTILIZANDO REDES NEURONALES ARTIFICIALES**

Autor: Ing. Deynier Montero Góngora

Tutores: Prof. Tit., Ing. Mercedes Ramírez Mendoza, Dr. C.
Prof. Aux, Ing. Ever Góngora Leyva, Dr. C.

Moa, 2016

Declaración de Autoridad

Autores de este trabajo de Diploma certificamos su propiedad intelectual a favor del **Instituto Superior Minero Metalúrgico “Dr. Antonio Núñez Jiménez”**, el cual podrá hacer uso del mismo con la finalidad que estime conveniente.

Firma del maestrante

Firma del Tutor

Firma del Tutor

Pensamiento

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

Job 28:28

Dedicatoria

- ✓ A Dios por su fidelidad y todo lo que representa para mí.
- ✓ A mi Madre por su inquebrantable amor y continuo apoyo en la cimentación de mi estructura moral y profesional; sin ella nada de esto sería posible.
- ✓ A mi Papá por todo el esfuerzo y sacrificio dedicado.
- ✓ A mi abuelo Pachito por ser mi apoyo incondicional, mi bastón.
- ✓ A mi abuela Celandia por el lugar tan especial que ocupa en mi corazón.
- ✓ A mis tíos William, Delvis y Ángel por estar siempre pendientes de mí.
- ✓ A mis tías Iliana, Odalis, China, Deysita, Damaris y Jaque por el amor, comprensión y sacrificio durante estos años.
- ✓ A mis hermanos Deynel, Dénise y Elizabeth.
- ✓ A todos mis primos y amigos.
- ✓ A todos mis hermanos de la fe.
- ✓ A la memoria de mis abuelos (Gaspar y Mayda).

Agradecimientos

Luego de culminado este trabajo llega quizás la parte más difícil, los agradecimientos, pues son tantas las personas que han influido en mi formación académica y social que sería injusto omitir alguna de estas:

- ✓ Muy especial a ese que todo lo puede (Dios).
- ✓ A mis padres Denny Montero Argüelles y Margiolis Góngora Pérez por sus excelentes y oportunos consejos.
- ✓ A mis tutores Mercedes Ramírez Mendoza y Ever Góngora Leyva por sus preocupaciones y constante dedicación.
- ✓ A los profesores del Departamento de Ingeniería Eléctrica y del claustro de la maestría de Electromecánica.
- ✓ A los profesores Reineris Montero Laurencio y Aliet Lamorú Reyes por sus valiosas contribuciones.
- ✓ A los compañeros de la Empresa Productora de Níquel y Cobalto “Comandante Che Guevara” que me facilitaron el acceso a la información y el desarrollo de la componente experimental, especialmente al Ing. Néstor William Jiménez.

Resumen

En los hornos de múltiples hogares se generan procesos multivariantes complejos, y su modelación contiene un alto índice de incertidumbre. En la presente investigación se abordó la temática de redes neuronales artificiales, aplicada al subproceso de postcombustión de un horno de reducción de mineral que opera según la tecnología Caron, en la Empresa Productora de Níquel y Cobalto “Comandante Che Guevara”. Se identificaron las principales variables que caracterizan el proceso y se tomaron datos que comprenden un período de tres meses de explotación de la instalación, a los cuales se les realizó un análisis de regresión paso a paso hacia atrás. Este análisis permitió determinar que el coeficiente de correlación lineal para la temperatura del hogar cuatro fue de 0,79 y 0,65 para la temperatura en el hogar seis. Se realizaron experimentos con secuencias binarias pseudoaleatorias de amplitud modulada sobre el flujo de mineral y las aperturas de las válvulas reguladoras de flujo de aire a los hogares cuatro y seis, para comprobar el efecto en la temperatura de estos hogares. Las técnicas de inteligencia artificial posibilitaron la creación de una red neuronal artificial del tipo perceptron multicapa, capaz de predecir la temperatura del hogar cuatro con un rango de error de -8 a 5 % y de -4 a 1 % para la temperatura del hogar seis.

Abstract

In many multihearth furnaces complex multivariable processes are generated, and modeling contains a high level of uncertainty. In this research the subject of artificial neural networks was addressed, applied to a thread postcombustion ore reduction furnace, with Caron technology, the company producing Nickel and Cobalt "Comandante Che Guevara". The main variables that characterize the process were identified and data comprising a period of three months of operation of the facility, to which underwent a regression analysis step backwards was taken. This analysis revealed that the linear correlation coefficient for four-furnace temperature was 0.79 and 0.65 for six home temperature. Pseudorandom binary sequences experiments amplitude modulated on the flow of mineral and openings throttles air flow to multihearth four six were conducted to check the effect on the temperature of these multihearth. Artificial intelligence techniques made possible the creation of an artificial neural network Multilayer Perceptron, able to predict the temperature of four with a home error range of -8 to 5 % and -4 to 1 % home for temperature-six.

Índice	
Introducción.....	1
Capítulo 1. Marco teórico-conceptual de la identificación de procesos	6
Introducción	6
1.1 Modelos de transferencia de calor y masa en procesos industriales.....	6
1.2 Proceso de reducción de níquel en hornos de reducción de mineral	7
1.3 Modelado matemático de sistemas físicos	9
1.4 Generalidades de las redes neuronales artificiales	11
1.4.1 Identificación de sistemas dinámicos con redes neuronales artificiales	13
Conclusiones	15
Capítulo 2. Materiales y métodos para la identificación del subproceso de postcombustión	16
Introducción	16
2.1 Descripción del reactor	16
2.2 Influencia de la temperatura en el proceso de reducción	18
2.3 Estado actual de la Automatización del subproceso de postcombustión.....	19
2.4 Análisis estadístico de los datos	20
2.5 Diseño del Experimento de Identificación a escala industrial	21
2.5.1 Selección de la señal de entrada para el proceso de identificación	22
2.5.2 Modificaciones realizadas en el CITECT.....	23
2.6 Nociones de modelado mediante redes neuronales artificiales	24
Conclusiones	29
Capítulo 3. Resultados experimentales y caracterización del subproceso de postcombustión, con ayuda de redes neuronales artificiales	30
Introducción	30
3.1 Resultados del análisis estadístico de los datos.....	30
3.2 Descripción de la instalación para la postcombustión	36
3.3 Experimentos previos con entrada escalón	38
3.4 Condiciones generales para la modelación	42
3.5.1 Experimento # 1: Variación de la apertura de la válvula del hogar cuatro.	43
3.5.2 Experimento # 2: Variación de la apertura de la válvula del hogar seis	46
3.5.3 Experimento # 3: Variación del flujo de mineral	49
3.6 Implementación de las redes neuronales artificiales	52
3.7 Valoración socio-ambiental	52
Conclusiones	54
Conclusiones generales	55
Recomendaciones.....	56
Bibliografía	57
Anexos	63
Anexo 1. Perfi térmico típico del horno	63
Anexo 2. Pantalla CICODE donde se generaron las señales de excitación	64

Introducción

El control automático desempeña una función trascendental en el avance de la ciencia y la tecnología, siendo parte importante e integral de los procesos modernos. Es esencial en el control de procesos petroquímicos, biofarmacéuticos, energéticos y metalúrgicos.

Dentro de las estrategias de control avanzado que se investigan para la automatización de procesos complejos se encuentran: el control adaptable, control predictivo basado en modelos, control robusto, control inteligente, entre otros. El control inteligente descansa en varias técnicas como: lógica difusa, algoritmos evolutivos, redes neuronales artificiales, etc.

Las redes neuronales artificiales pueden ser usadas con efectividad y precisión para la modelación de sistemas con dinámicas complejas, especialmente para procesos no lineales que varían en el tiempo. El interés creciente en las redes neuronales artificiales se debe a su gran versatilidad y al continuo avance en los algoritmos de entrenamiento de redes y en el hardware (Ljung & Sjöberg, 1992; Isermann, Ayoubi, Konrad, & Reiss, 1993; Sjöberg, 1995; Ljung, 1999; Valverde, 2007; Santos, 2011).

Las empresas productoras de níquel se caracterizan por presentar procesos continuos de gran complejidad; que requieren de la automatización para lograr mayor eficiencia en sus producciones. La Empresa Productora de Níquel y Cobalto “Comandante Ernesto Che Guevara”, ubicada en Moa, provincia de Holguín, opera según el esquema de lixiviación carbonato-amoniaco del mineral reducido. Esta empresa cuenta con una planta de hornos de reducción de múltiples hogares, que constituye una etapa clave dentro del proceso productivo.

Los hornos de reducción son cilindros metálicos de grandes dimensiones, donde se realiza básicamente la reducción de óxido de níquel y cobalto a sus correspondientes formas metálicas (Castellanos, 1986). En estos equipos se requiere mantener un perfil de temperatura y de gases reductores (monóxido de carbono e hidrógeno), por cada hogar, su incumplimiento produce pérdidas notables debido a la formación de estructuras cristalinas de espinelas de hierro, olivinos y piroxenos que atrapan al níquel y al cobalto en forma de óxidos y en menor grado en estado metálico, y a la

aparición de altos contenidos de hierro metálico en el mineral reducido. Esto trae como consecuencia que disminuya la extracción de níquel y cobalto en el proceso de lixiviación (Miranda, Chaviano, & Miranda, 2002).

Una vez garantizado el perfil térmico requerido por el horno, se introduce aire secundario en los hogares cuatro y seis (postcombustión), con el propósito de garantizar la combustión completa del monóxido de carbono residual y de otros gases combustibles que provienen de la combustión incompleta en los hogares inferiores. En esta reacción de tipo exotérmica se genera una cantidad de calor que contribuye al precalentamiento y secado del mineral.

Por otra parte, es habitual encontrar en el control de procesos, sistemas de varias entradas y salidas. Un ejemplo de ello es el subproceso de postcombustión, caracterizado por varias variables como: el flujo y la temperatura del aire en los hogares cuatro y seis; el flujo y la temperatura del mineral; el flujo, la temperatura y composición química de la mezcla de gases; y la temperatura ambiente. Esto hace que se considere dicho subproceso como un sistema multivariable o sistema de múltiples entradas múltiples salidas (MIMO por sus siglas en inglés). Un fenómeno característico de este tipo de sistema es la interacción entre sus variables, de tal forma que una variable de entrada afecta a varias variables de salida y recíprocamente una salida es afectada por varias entradas, lo cual dificulta en gran medida el diseño de los sistemas de control (Smith & Corripio, 2006).

En el mundo existen pocas plantas metalúrgicas que utilicen hornos de múltiples hogares destinados a la reducción de minerales lateríticos, razón por la cual, existen escasas publicaciones sobre estos equipos y por ende insuficiente conocimiento de los procesos térmicos, químicos y físicos que se ponen de manifiesto. Además los métodos de cálculos tradicionales no garantizan la evaluación certera del proceso, debido a la incertidumbre existente.

La empresa donde se realiza la investigación comenzó a producir en el año 1986 y se basó en la planta similar construida en Nicaro, donde los problemas desde el punto de vista de la automatización estaban relacionados con el control de la temperatura en el hogar cuatro (Ramírez, 2002a).

Para el control de la postcombustión se utilizan controladores PID (Proporcional-Integral-Derivativo) clásicos ajustados por prueba y error, los cuales forman parte de lazos de control individuales, donde se manipula el flujo de aire de un mismo conducto que se divide en dos ramas, los cuales entran en conflicto. Por este motivo, normalmente el lazo de control del hogar cuatro funciona en automático y en el hogar seis de forma manual, como consecuencia el proceso físico químico que tiene lugar en estos hogares no se realiza de manera eficiente; observándose oscilaciones de la temperatura, que afectan los procesos térmicos y aerodinámicos que tienen lugar en el horno.

Para diseñar una estrategia de control efectiva para el subproceso de postcombustión, se requiere de un modelo matemático que describa la dinámica del proceso.

La literatura consultada muestra modelos matemáticos lineales para los hornos de la empresa “Comandante René Ramos Latour” de Nicaro, que operaban bajo diferentes condiciones de explotación (Ramírez, 2001). Dichos modelos se lograron mediante la identificación experimental, para valores de ajuste cuadrático medio entre 0,72 y 6,1. Además se definieron como variables de entrada: el flujo de aire a los hogares cuatro y seis, y como variables de salida: la temperatura correspondiente a estos hogares. Montero (2012), obtuvo modelos matemáticos dinámicos, con ajuste entre 62 y 72 % , que caracterizan los hornos de reducción de la Empresa Productora de Níquel y Cobalto “Comandante Che Guevara”; donde se seleccionaron como variables de entrada: el flujo de mineral alimentado al horno; flujo de aire a los hogares cuatro y seis. Como variables de salida: temperatura de estos hogares y concentración de monóxido de carbono residual.

Si bien los modelos matemáticos antes mencionados permitieron profundizar en el comportamiento dinámico del subproceso de postcombustión, los mismos solo arrojaron conclusiones para determinados puntos de operación, dado su carácter lineal; no permitiendo el diseño de estrategias de control avanzado como lo requiere un proceso de tal complejidad.

Se dice entonces que el **problema de la investigación** es la inexistencia de un modelo matemático que favorezca la implementación de una estrategia de control eficiente para la temperatura del subproceso de postcombustión, en los hornos de reducción de mineral de la Empresa Productora de Níquel y Cobalto “Comandante Che Guevara”.

El **objetivo** del trabajo es obtener un modelo neuronal artificial que represente el comportamiento dinámico del subproceso de postcombustión, utilizando MATLAB como herramienta de cálculo.

El **objeto** lo constituye el subproceso de postcombustión en hornos de reducción de mineral, que operan según la tecnología Caron.

El **campo** de la investigación es la modelación matemática del objeto de estudio mediante técnicas de identificación experimental basadas en el uso de redes neuronales artificiales.

Como **hipótesis** se plantea que si se obtiene un modelo neuronal artificial del subproceso de postcombustión; entonces es posible predecir el comportamiento de la temperatura en los hogares cuatro y seis con respecto a cambios en el flujo de aire a estos hogares y el flujo de mineral alimentado al horno, como base para establecer adecuados algoritmos de control.

Las tareas de la investigación son las siguientes:

1. Caracterización del proceso de reducción de níquel de la Empresa Productora de Níquel y Cobalto “Comandante Che Guevara” y en particular del subproceso de postcombustión.
2. Análisis del comportamiento estadístico de las variables a utilizar en el diseño de la red neuronal artificial.
3. Realización de los experimentos correspondientes para la obtención de datos.
4. Diseño, entrenamiento y validación de la red neuronal artificial seleccionada.
5. Análisis de los resultados obtenidos.

Métodos y técnicas empleados en la investigación:

- Método de investigación documental y bibliográfica para la sistematización del conjunto de conocimientos y teorías relacionadas con el objeto de estudio.
- Método experimental para la caracterización del subproceso de postcombustión del horno de reducción de mineral.
- Técnicas computacionales existentes para la creación, entrenamiento e implementación de la red neuronal artificial.

De acuerdo con la hipótesis y el objetivo propuesto, se establece **como aporte de la investigación:**

Obtención de un modelo basado en técnicas de inteligencia artificial (redes neuronales artificiales) en la identificación del subproceso de postcombustión del horno de reducción de mineral, en la Empresa Productora de Níquel y Cobalto “Comandante Che Guevara”.

Capítulo 1. Marco teórico-conceptual de la identificación de procesos

Introducción

Los sistemas automatizados están en constante desarrollo y los requisitos de desempeño de los mismos son cada vez más exigentes, por ello los métodos del llamado control convencional no siempre resultan adecuados. Por otro lado, las relaciones entrada - salida de los procesos pueden ser inciertas y también pueden ser modificadas por perturbaciones externas desconocidas. Todo esto conduce a la necesidad de aplicar nuevos enfoques para resolver tales problemas y una vía es utilizar técnicas de inteligencia artificial.

El objetivo de este capítulo es presentar un análisis de la literatura revisada sobre la aplicación de redes neuronales artificiales para la identificación de procesos, tomando en consideración que esta técnica de inteligencia artificial ha sido seleccionada para identificar el proceso objeto de investigación.

1.1 Modelos de transferencia de calor y masa en procesos industriales

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.

Las estrategias de modelación en la tecnología Caron han estado basadas en: procesos de secado natural (Retirado, 2004, 2012; Retirado & Góngora, 2007, 2008, 2009; Retirado & Lamorú, 2011; Retirado & Legrá, 2011, 2012); molienda (Laborde, 2005); transporte neumático de la mena laterítica (Torres, 2003; Torres & Retirado, 2007); enfriamiento del mineral laterítico en cilindros horizontales rotatorios (Góngora, 2014); enfriamiento y mezcla del licor con el mineral reducido en el tanque de contacto (Guzmán & García, 2000; Guzmán, 2001; Guzmán & Rodríguez, 2001); y calcinación del Carbonato Básico de Níquel (Columbié & Rodríguez, 2000; Columbié, 2001; Columbié & Guzmán, 1999, 2004). La mayoría de estos modelos utilizan ecuaciones diferenciales, que resuelven por los métodos de separación de variables, Runge Kutta y diferencias finitas.

Los modelos para un proceso en particular son únicos, por eso se desarrollan modelos genéricos, como los que describen el comportamiento de un secador rotatorio (Ajayi & Sheehan, 2012) a contracorriente a partir de ajustes empíricos y seudofísicos (Sheehan, Britton, & Schneider, 2005), constituyen una herramienta computacional para simular el comportamiento del equipo (Mujumdar & Ranade, Simulation of Rotary Cement Kilns Using a One-Dimensional Model, 2006), suponen que los parámetros principales son independientes del tiempo, la temperatura y la posición (Mujumdar, Arora, & Ranade, 2006), lo consideran como un sistema de parámetros distribuidos (Shariari & Tarasiewicz, 2011) y aplican los conceptos de función de operación en la modelación de estos procesos.

En la obtención de modelos matemáticos se utilizan además, el método de elementos finitos (ANSYS) para predecir la distribución de temperaturas en un horno rotatorio (Gnielinski, 1976), el método de la dinámica de fluidos computarizada para explorar la eficiencia energética de un horno (Mujumdar, Arora, & Ranade, 2006), los análisis energéticos y exergéticos para evaluar las pérdidas termodinámicas (Peinado & De Vega, 2011) y el consumo específico de energía en secadores (Tarhan & Telci, 2010).

1.2 Proceso de reducción de níquel en hornos de reducción de mineral

La reducción del mineral mediante el uso de agentes reductores procedentes del *fuel-oil* es un fenómeno físico-químico y heterogéneo, debido a que la materia que lo compone se encuentra en diferentes estados de agregación. Las porciones físicamente distintas de un sistema heterogéneo se conocen con el nombre de fase y se encuentran separadas por límites definidos, en este caso el mineral constituye una fase sólida y los gases producto de la combustión constituyen la gaseosa (Castellanos, 1986).

Dicho proceso ocurre en un horno, donde la reducción de mineral laterítico comprende tres etapas. Del hogar cero al cuatro, el mineral sufre un proceso de calentamiento y deshidratación, le sigue una zona de transición (Reducción Parcial + Disociación (hogares cinco al nueve), mientras que la reducción comienza a partir del hogar 10 (Chang, 1999). Se precisa también que el exceso de energía en la zona de

calentamiento descompone parte del *fuel-oil* provocando 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 poder ser suministrados al sistema de recuperación de polvo. Además, 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.

La introducción de aire a los hogares cuatro y seis provoca las reacciones químicas exotérmicas mostradas en las ecuaciones (1.1) y (1.2). El calor liberado se utiliza en el calentamiento de los hogares superiores (cuatro, tres, dos, uno, cero) (Ramírez, 2001):



A través del estudio bibliográfico se encontró un modelo matemático del subproceso de postcombustión en un horno de reducción (Angulo, 1982), el cual se obtuvo empleando el método de los multiplicadores de Gauss; este modelo es estático por tanto no es de utilidad para el estudio del comportamiento dinámico del subproceso.

Valiosos aportes al tema del modelado dinámico del proceso de reducción se muestran en (Marrero, 1989; Gupta, Chakraborti, & Sundararajan, 1989; Nath, Chakrabortiand, & Shekhar, 1998; Torres, 1999), sin embargo, no se tiene en cuenta la introducción de aire secundario al horno; de manera que tampoco se adaptan para el fin previsto.

El mecanismo y estado que definen el proceso de reducción de níquel, aun no se ha estudiado lo suficiente; ello está relacionado con la complejidad de estos procesos y con la influencia de factores tales como: la naturaleza y propiedades de las fases que interaccionan y las condiciones térmicas del proceso (Torres, 1999).

1.3 Modelado matemático de sistemas físicos

Para obtener modelos matemáticos de un sistema se han utilizado distintos enfoques:

Vía Analítica. Consiste en desarrollar un modelo basado en las relaciones físico-químicas del proceso por identificar, planteando ecuaciones de balance de masa, de energía, etc. 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 (Aguado, 2000).

Vía Experimental. Este enfoque resulta generalmente el más directo y el que produce resultados a más corto plazo. Las señales utilizadas con más frecuencia son los escalones y las llamadas secuencias binarias pseudoaleatorias. 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 (Aguado, 2000).

La obtención de un modelo que describa el subproceso de postcombustión desde el punto de vista analítico sería en extremo complicado, pues los procesos físico-químicos involucrados en el horno conducirían a sistemas de ecuaciones diferenciales en derivadas parciales, consecuentemente no lineales y variables en el tiempo (Ramírez, 2002b); por ello para el desarrollo de esta investigación se optó por la vía experimental.

La identificación de sistemas se define como la obtención de la estructura y los parámetros de un modelo matemático generalmente dinámico, que reproduce con suficiente exactitud, las características dinámicas del proceso objeto de estudio, para los fines deseados del control automático (Arafet, 2004; Caldas, Jiménez, Mejía, Hernández, & Avilés, 2012).

El proceso de identificación de un proceso por la vía experimental consta de los siguientes pasos (Ljung, 1999):

1. Obtención de datos de entrada - salida. Para ello se debe excitar el sistema mediante la aplicación de una señal de entrada y registrar la evolución de sus entradas y salidas durante un intervalo de tiempo.
2. Tratamiento previo de los datos registrados. Los datos registrados están generalmente acompañados de ruidos indeseados u otro tipo de imperfecciones, que son necesarios corregir antes de iniciar la identificación del modelo. Se trata, por tanto, de “preparar” los datos para facilitar y mejorar el proceso de identificación (Añez & Scarano, 2015).
3. Elección de la estructura del modelo. Si el modelo que se desea obtener es un modelo paramétrico, el primer paso es determinar la estructura deseada para dicho modelo (Estrada, Peña, & Guarnizo, 2012). Este punto se facilita si se tiene un cierto conocimiento sobre las leyes físicas que rigen el proceso.
4. Obtención de los parámetros del modelo. A continuación se procede a la estimación de los parámetros de la estructura que mejor ajustan la respuesta del modelo a los datos de entrada-salida obtenidos experimentalmente.
5. Validación del modelo. Consiste en determinar si el modelo obtenido satisface el grado de exactitud requerido para la aplicación en cuestión. Si se llega a la conclusión de que el modelo no es válido, se deben revisar los siguientes aspectos como posibles causas:
 - a) El conjunto de datos de entrada-salida no proporciona suficiente información sobre la dinámica del sistema.
 - b) La estructura escogida no es capaz de proporcionar una buena descripción del modelo.
 - c) El criterio de ajuste de parámetros seleccionado no es el más adecuado.

Es preciso conocer que, el tipo de modelo, la precisión requerida del mismo 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 el espacio de estados, mientras que en otros casos, es suficiente contar con un modelo simple que sea capaz de reproducir con fidelidad algunas características esenciales del proceso como son la ganancia, el tiempo de retardo y las constantes de tiempo dominantes.

En dependencia del método o 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 utilizar tanto modelos continuos como discretos, (Landau & Zito, 2006).

Independientemente del objetivo de la identificación o del enfoque y métodos utilizados, es necesario tener siempre en cuenta que existe una distancia considerable entre un modelo matemático, por sofisticado que este sea, y el proceso real. La experiencia y el sentido común recomiendan hacer un uso cauteloso del modelo resultante de una identificación y tener siempre presente que la realidad es mucho más compleja que cualquier modelo (Aguado, 2000).

Para la identificación experimental del subproceso de postcombustión del horno es viable utilizar diferentes modelos: estadísticos, funciones de transferencia, espacio de estado, polinomiales, espectrales, borrosos, neuronales, etc. Se seleccionaron los modelos neuronales artificiales porque constituyen una de las técnicas de inteligencia artificial que ha despertado mayor interés en los últimos años, debido a su capacidad de resolver problemas, cuya solución por métodos convencionales resulta extremadamente difícil (Aguado, 2000).

1.4 Generalidades de las redes neuronales artificiales

Uno de los momentos fundamentales en el desarrollo de las redes neuronales artificiales se remonta hasta 1949 cuando D.O. Hebb propuso una ley de aprendizaje que se considera como el punto de partida de los algoritmos de entrenamiento de las redes, mientras que la primera estructura de red neuronal fue propuesta por Frank Rosenblatt en 1958. Desde entonces el interés suscitado por las redes ha crecido considerablemente, proponiéndose nuevos modelos que han venido a superar las limitaciones de las redes anteriores, dándoles mayores capacidades (Marichal, 1999).

Las redes neuronales artificiales tienen su origen en la observación de los sistemas neuronales de los organismos vivos, sin embargo, éstas no son un fiel reflejo de dichas redes biológicas (de Armas, Gómez, Pérez, Meriño, & Sepúlveda, 2007).

Como características más relevantes de las redes se citan las siguientes:

1. La capacidad de aprendizaje. La naturaleza no lineal de las mismas les permite exhibir comportamientos verdaderamente complejos. Esta característica junto con algoritmos que extraen un mayor rendimiento de tales sistemas, les confiere esa capacidad.
2. La posibilidad de procesamiento paralelo, aspecto que aprovechado en la implementación lleva a aumentar considerablemente la velocidad de procesamiento.
3. La significativa tolerancia a fallos, dado que un fallo en unas pocas conexiones locales, rara vez contribuye significativamente al funcionamiento global de la red. Esta propiedad las hace convenientes en ciertas aplicaciones, donde, una avería constituya un serio peligro.

Estas características, entre otras, hacen de las redes neuronales artificiales una herramienta fundamental en varios campos del conocimiento.

Las redes neuronales artificiales generalmente han sido implementadas mediante la programación sobre computadoras digitales, sin embargo ya son implementadas en hardware, ya sea 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 mismas, siendo ésta un área de investigación muy activa (Patan, 2008).

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 redes neuronales (Kruger & Xie, 2012).

Las redes neuronales artificiales se clasifican en tres clases en función de su arquitectura y forma de procesar las señales (Marichal, 1999; Bello, 2003):

La primera clase de redes se conoce con el nombre de **redes neuronales artificiales estáticas**. En esta clase se encuentran la Red Perceptron Multicapas, la Red de Funciones de Base Radial, Red Neuronal Probabilística (PNN), etc. Todas ellas tienen como característica común el no poseer memoria, es decir, sólo son capaces de transformar un conjunto de entradas en un conjunto de salidas, de tal manera que una vez establecidos todos los parámetros de la red, las salidas únicamente dependen de las entradas. En general la relación deseada de entradas y

salidas se determina en este caso externamente mediante alguna forma de ajuste de los parámetros del sistema supervisado. Este tipo de redes se han empleado con éxito en muchos problemas de clasificación, como funciones lógicas, así como en el campo de la aproximación funcional.

Las **redes neuronales artificiales dinámicas** son la segunda clase de redes, las que a diferencia de las anteriores permiten establecer una relación entre salidas y entradas y/o salidas y entradas previas. Esto añade cierta memoria a estas redes. Matemáticamente, esta memoria se traduce en la aparición de ecuaciones diferenciales o ecuaciones en diferencia, que forman parte del modelo de las mismas. Como ejemplos de este tipo de redes se encuentran la red de Hopfield, la red de retardos en el tiempo (*Time Delay Neural Network*), la red de tiempo discreto (*Time Discrete Neural Network*), etc. Las redes neuronales artificiales dinámicas son útiles en problemas de modelado de dinámicas directa e inversa de sistemas complejos, tales como robots, cohetes, naves espaciales, etc., así como en la obtención de modelos de circuitos secuenciales y en la conversión de texto a voz.

Por último se destacan las denominadas **redes auto-organizativas**, en las cuales los nodos vecinos dentro de la red neuronal compiten en actividad por medio de las interacciones mutuas laterales, y evolucionan adaptativamente hacia detectores específicos de las diferentes señales de entrada. El aprendizaje en este caso se denomina aprendizaje competitivo, no supervisado o auto-organizativo. Estas se han aplicado con éxito en problemas de reconocimiento de patrones, control de procesos e incluso en el procesamiento de información semántica.

De estos tipos de topologías de redes se escogen las redes neuronales artificiales dinámicas; debido que para lograr el control del subproceso de postcombustión del horno, se requiere establecer relaciones entre salidas y entradas y/o salidas y entradas previas en diferentes instantes de tiempo.

1.4.1 Identificación de sistemas dinámicos con redes neuronales artificiales

El proceso de identificación implica cuatro etapas. La primera es la planeación del experimento para adquirir los datos con que se alimentará la red; la segunda es la selección de la configuración de la red; la tercera es la estimación de los parámetros

del modelo (mediante la aplicación de algoritmos de aprendizaje), y la última es la validación (Norgaard, 2000; de Armas, Gómez, Pérez, Meriño, & Sepúlveda, 2007).

Los requerimientos para una red neuronal son menores en comparación con los procedimientos clásicos de identificación. Al comparar ambos procedimientos desde el punto de vista de entrada y estructura, se observa que el usuario debe especificar los datos de entrada - salida del proceso idénticamente en ambos tipos de procedimientos (Arafet, Chang, Domínguez, Torres, & León, 2004).

En cuanto a la estructura, en los procedimientos clásicos el usuario debe especificar la característica de la estructura de la relación entre las entradas y las salidas, a veces muy complejas, mientras que para la identificación usando las redes sólo se debe especificar la topología de la red. Lo que se le pide a la red en este caso, es que internamente consiga un modelo capaz de reproducir unos valores numéricos que se asemejen a los valores de algún sistema físico (Aguado, 2000).

Uno de los aportes más importantes en la identificación con redes neuronales artificiales fue publicado en 1990, cuando Narendra y Parthasarathy demostraron que las mismas son muy potentes para la identificación de sistemas no lineales, y además son útiles para su control (Levin & Narendra, 1993).

Debido a sus capacidades de aproximación así como a sus inherentes características de adaptabilidad, las redes neuronales artificiales presentan una importante alternativa en el modelado de sistemas no lineales. Gracias a esto se ha generado un gran interés en la utilización de modelos de redes neuronales artificiales para la identificación de sistemas dinámicos con no-linealidades desconocidas (Valverde, 2007).

Las razones fundamentales por las que una red neuronal sirve para identificar son su adaptabilidad, robustez y paralelismo, especialmente cuando el proceso a modelar es una caja negra o si se conoce muy poco sobre su dinámica; debido a que se ajustan a la información de entrada – salida para el entrenamiento, la cual es asumida como ejemplos en su proceso de aprendizaje (Rairán, Millán, & Guzmán, 2006; Mohandas & Suresh, 2006).

A través del empleo de una red neuronal del tipo *cascade – forward backpropagation* de cuatro capas, se identificó el proceso de enfriamiento del mineral reducido en la Planta de Hornos de Reducción de la Empresa Productora de Níquel y Cobalto “Comandante Che Guevara” (Spencer, 2009). El coeficiente de correlación alcanza valores de: 0,92 en su entrenamiento, 0,93 en su validación y hasta de un 0,74 en su generalización. Este es un ejemplo de la capacidad que poseen las redes neuronales artificiales para el aprendizaje de relaciones complejas, a partir de un conjunto de ejemplos.

La utilización de una red *feedforward* para la identificación de un péndulo invertido servo accionado, que constituye un sistema multivariable, se expone en (Sutradhar, Sengupta, & Challa, 2010). En este trabajo se demostró que las redes neuronales artificiales permiten aproximar no linealidades, con funciones de activación sigmoideal-lineal en las capas oculta y de salida respectivamente, con un número variable de neuronas.

La introducción de un mecanismo novedoso de actualización de pesos para la modificación del algoritmo *backpropagation*, presenta un acercamiento a la identificación dinámica de sistemas multivariables no lineales (robots), usando redes neuronales artificiales *feedforward* de múltiples capas (Farzaneh, Ali, & Rajnikant, 2006).

El uso de una red neuronal con algoritmo *backpropagation* para la identificación inversa de plantas dinámicas no lineales, demuestra que los resultados de simulación del método propuesto identifican eficazmente el sistema dinámico no lineal (Ming, 2007). A través de los modelos inversos se logran mejorar la precisión, la velocidad de respuesta y el error estático.

Conclusiones

1. Para la identificación del subproceso de postcombustión se propone la vía experimental, por la complejidad que desde el punto de vista analítico representan los procesos físico-químicos involucrados en el horno.
2. La bibliografía consultada confirma la identificación de procesos complejos, con ayuda de redes neuronales artificiales.

Capítulo 2. Materiales y métodos para la identificación del subproceso de postcombustión

Introducción

El proceso tecnológico de la Empresa Productora de Níquel y Cobalto “Comandante Che Guevara” está basado en el proceso Caron (Bolton, Berezowsky, & Day, 1997). La reducción de mineral 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, cuya interacción en el proceso tecnológico, determina los valores de la cantidad de níquel extractable, como principal indicador de calidad del producto final.

En este capítulo se hace un esbozo de los aspectos relacionados con el proceso de reducción, haciendo énfasis en el subproceso de postcombustión que ocurre en el horno de múltiples hogares; con el objetivo de establecer el procedimiento para el análisis estadístico de los datos y la obtención de los modelos neuronales del subproceso mediante técnicas de identificación experimental.

2.1 Descripción del reactor

Los hornos tipo Herreshoff (Habashi, 1997), están compuestos por un cilindro metálico, en posición vertical, revestido interiormente con ladrillos de chamota o alta alúmina, protegido exteriormente por una carcasa metálica, instalaciones para la agitación, alimentación y descarga del mineral y cámaras de combustión. Están formados interiormente por 17 hogares o soleras que tienen forma de bóvedas esféricas (ver figura 2.1).

El horno dispone de un eje central rotatorio al cual se le articulan 68 brazos, cuatro por cada hogar. Cada brazo posee, en dependencia del hogar, de ocho a 12 paletas o dientes inclinados. En dependencia de la zona del horno, serán de retención o de barrido y en dependencia de los hogares pares o impares, van a permitir la descarga de un hogar a otro en forma de zigzag. En los hogares pares, la descarga se realiza a través de 30 orificios localizados equidistantes en la periferia, en los hogares impares por un orificio localizado en el centro alrededor del eje central.




Figura 2.1. Diagrama esquemático del horno de reducción visto desde el SCADA (CITECT).

Las cámaras de combustión están equipadas con quemadores de petróleo de alta presión, que se ubican dos por cada hogar en: hogar seis, hogar ocho, hogar 10, hogar 12; excepto los hogares 14 y 15 que solo poseen una cámara.

En cada cámara: el distribuidor de petróleo consta de una válvula principal, un filtro para separar las impurezas, una válvula solenoide, un termómetro, un manómetro, un flujómetro con *by-pass*, un regulador de presión y el quemador (Tavío, 1999).

Los quemadores trabajan con:

- Petróleo proveniente de la unidad reguladora calentadora, que lo recibe de la estación de almacenaje y lo transfiere acompañado de una tubería satélite de vapor, para mantener la temperatura de 100 a 130 °C y una presión de 105 a 112 kPa .
- Aire atmosférico a una presión de 13,5 a 14,5 kPa y un flujo de 0,405 m³/s suministrado por ventiladores centrífugos.
- El aire atmosférico, al mismo tiempo que enfría la superficie de la cámara, es calentado en una camisa, que esta posee, desde 58 a 120 °C y es ramificado en dos vías: directa al quemador con el objetivo de atomizar el petróleo y

directo a la cámara de aire de pleno del plato, para evitar el retroceso de la llama desde la cámara al quemador.

Otras especificaciones del horno son:

- Volumen [387 m³]
- Productividad [18 t/h]
- Volumen de aire de postcombustión [2 000 m³/h]
- Presión positiva en el hogar 16 [19,62 a 39,24 Pa]
- Temperatura de los gases a la salida [350 a 400 °C]
- Volumen de gases salientes [15 000 m³/h]
- Diámetro interior [6,048 m]
- Diámetro exterior [6,780 m]
- Espesor del revestimiento [0,342 m]
- Espesor del revestimiento del eje [0,075 m]
- Altura total el horno [23,5 m]
- Altura de la parte cilíndrica [18,89 m]
- Velocidad de rotación del eje central [0,023 rad/s]

2.2 Influencia de la temperatura en el proceso de reducción

La temperatura es un parámetro fundamental en los procesos pirometalúrgicos, debido a que facilita el debilitamiento de las estructuras cristalinas del mineral y por consiguiente el desarrollo de las reacciones de reducción. Los valores de temperatura se ofrecen en grados Celsius para facilitar la comprensión de los mismos desde el punto de vista práctico.

Durante la operación se debe mantener cierto perfil prescrito, aumentando de la parte superior a la inferior, a fin de garantizar un calentamiento gradual del mineral.

En el **Anexo 1** se muestra el perfil típico del horno.

Especial atención se presta a los valores de temperatura de los hogares cuatro, 10 y 15.

La estabilidad de la temperatura en el hogar cuatro es extremadamente importante por la influencia que tiene sobre la temperatura en los demás hogares del horno. De existir valores de temperatura por debajo del normado, ocurre un desplazamiento de

las zonas térmicas del horno, lo cual trae consigo afectaciones en la extracción del níquel y cobalto (Ramírez, 2002a).

2.3 Estado actual de la Automatización del subproceso de postcombustión

En la Unidad Básica de Producción Planta “Hornos de Reducción” se encuentra instalado un Sistema de Supervisión y Control “CITECT” (Manual de Operaciones, 2007), según se muestra en la figura 2.2. Cada horno tiene asignado un autómata, que es el encargado de recepcionar todas las señales de las diferentes variables del proceso.




Figura 2.2. Sistema de automatización en el horno.

Este autómata intercambia información con otro autómata ubicado en el panel de control, el cual es el encargado de 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 con una pantalla digital que se denomina OP-35 mediante el cual es posible ejecutar la parada o arranque de los motores eléctricos acoplados a los diferentes equipos

tecnológicos, así como abrir o cerrar válvulas automáticas y ON-OFF. Esta operación también se realiza desde las computadoras.

Actualmente está instalado además el Sistema de Supervisión y Control “EROS” (EROS, 1997), el cual permite la medición del flujo de mineral alimentado al horno, variable fundamental para el estudio y análisis del subproceso de postcombustión.

En la tabla 2.1 se describe la instrumentación vinculada al subproceso de postcombustión.

Tabla 2.1. Instrumentación del subproceso de postcombustión.

Nom.	Denominación	Rango	Tipo	Marca	Observaciones
Tp	Termopar con convertidor (4 a 20 mA)	0 a 1 000 °C	K Cromel-Alumel	Thermibel	Mide la temperatura en los hogares cuatro y seis
Vc	Válvula de control con actuador de giro	0,2 a 1,0 kgf/cm ²	Mariposa		Regula flujo de aire hacia los hogares cuatro y seis
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

2.4 Análisis estadístico de los datos

La presentación de los datos le permite a cualquier investigador una fácil interpretación de los mismos. Esta presentación se puede realizar de dos formas:

- 1. Tablas de frecuencias:** Consiste en agrupar los datos en clases o categorías con sus respectivas frecuencias. Es aplicable a cualquier tipo de variable.
- 2. Gráficos:** ejemplo (Histograma). Es la representación de los datos por rectángulos que tienen su base en un eje horizontal y su área proporcional a la frecuencia del intervalo de clase. Se utilizan fundamentalmente para variables continuas.

Análisis de regresión

A través de un análisis de regresión paso a paso hacia atrás, se determinan las principales variables que influyen en las variables dependientes del proceso, así como el coeficiente de correlación lineal.

2.5 Diseño del Experimento de Identificación a escala industrial

El diseño de un experimento de identificación incluye diversas variantes, tales como: ¿Cuáles señales medir?, ¿Cuándo medir?, ¿Cuáles señales manipular? y ¿Cómo manipular? Se debe considerar también como condicionar las señales una vez muestreadas, como (eventualmente) refinar los datos obtenidos, por ejemplo, removiendo tendencias (Ljung, 1999).

El procesamiento de los datos experimentales es realizado fuera de línea (*off line*) con ayuda de softwares profesionales. Por tanto es recomendable proyectar el experimento cuidadosamente de forma tal que al generar los datos, estos sean lo suficientemente informativos. Los experimentos deben ser realizados cuando el proceso está en un modo de operación próximo al deseado.

En muchos casos, se deben realizar experimentos preliminares para alcanzar el conocimiento del proceso que es necesario para proyectar experimentos apropiados. En estos casos, es preferible usar el análisis de la respuesta al paso escalón o el análisis de correlación de datos de un experimento; debido a lo sencillo de esos métodos (Guzmán, 2001; Ljung, 2012). Los experimentos preliminares deberán indicar:

- constante de tiempo dominante;
- amplitud permitida de la entrada;
- presencia de no linealidades y variación temporal del proceso;
- niveles de ruido; y
- retrasos puros.

Esas informaciones entonces son usadas para el proyecto de experimentos de identificación. El proyecto de un experimento debe considerar los siguientes tópicos:

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

- tasa de muestreo;
- duración del experimento
- identificación en lazo abierto o cerrado.

Si el proceso a ser identificado es no-lineal y se busca un modelo lineal para representarlo, entonces el experimento debe ser realizado en torno al punto nominal de operación de la planta.

El rango de operación que el modelo debe cubrir determina 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 dado valor de referencia, requiere un experimento con una amplitud de entrada lo suficientemente baja, para que la linealización no sea violada. Algunas veces la validación indica que el modelo obtenido no es preciso. Por ejemplo:

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

En este caso, un nuevo experimento es la única forma de obtener un modelo más preciso.

2.5.1 Selección de la señal de entrada para el proceso de identificación

Como señal de entrada para excitar al proceso se utilizaron señales binarias pseudoaleatorias de amplitud modulada (figura 2.3).

En esta señal no solo se modula la frecuencia de excitación, como es el caso de las señales binarias pseudoaleatorias, sino también la amplitud, y cubre un rango de frecuencias mayor que la señal binaria pseudoaleatoria, aunque existen más parámetros de diseño a tomar en cuenta tales como el rango y la distribución de amplitudes de la señal de entrada.

En este caso al diseño clásico de una señal binaria pseudoaleatoria, siguiendo el criterio ofrecido por Roffel & Betlem (2006), se añadió un generador de números aleatorios para seleccionar valores de amplitud 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, esto no representa un problema para una secuencia de prueba de suficiente longitud.




Figura 2.3. Señal binaria pseudoaleatoria de Amplitud Modulada.

Fuente: (Isermann, 2011)

U_{min} a U_{max} ; rango de amplitud de entrada.

2.5.2 Modificaciones realizadas en el CITECT

Los lazos de control de temperatura en los hogares cuatro y seis del horno cinco (que fue el escogido para los ensayos) utilizaban reguladores autónomos SIPART DR-20, que recibían las señales procedentes de los termopares de cada uno de los hogares mencionados y actuaban sobre los posicionadores PS1 de las válvulas de mariposa, todo a través del autómatas programable. Para poder aplicar las secuencias binarias se eliminaron los reguladores autónomos y se hicieron conexiones a tres hilos entre el autómatas y los posicionadores de las válvulas, para actuar directamente sobre éstos desde el autómatas.

Para enviar las señales de excitación descritas en el epígrafe anterior al autómatas se utilizó el CICODE, que permite programar desde el sistema de control de adquisición de datos toda la información de entrada, para de esta forma actuar sobre el flujo de aire a los hogares cuatro y seis. Toda la lógica asociada a la generación de la señal de entrada y a la ejecución del experimento fue programada dentro de él. En el Anexo 2 se ofrece una vista de la pantalla de programación del CICODE.

Luego de concluido el experimento se exportan los datos del registrador del CITECT correspondientes al período de prueba hacia un fichero Excel, para su posterior procesamiento con el Toolbox de Identificación de Sistemas “NNSYSD” de MATLAB.

2.6 Obtención de la red neuronal artificial

La red perceptron multicapa o MLP, es probablemente el tipo de red más utilizado. La principal razón para esto es su habilidad para modelar complejas relaciones funcionales de forma simple. Esto ha sido probado a través de numerosas aplicaciones prácticas (Norgaard, 2000).

Una vez realizado el experimento y considerando que los datos experimentales describen el sistema en su región de operación y que la selección de la frecuencia de muestreo es apropiada, se dispone del siguiente vector:

$$\mathbf{Z}^n = \{[\mathbf{u}(t), \mathbf{y}(t)] | t = 1, \dots, N\} \quad 2.1$$

Donde: $\mathbf{u}(t)$ es la señal de control; $\mathbf{y}(t)$ es la señal de salida medida; y t es el tiempo de muestreo, entonces se pasa a la selección de la estructura del modelo.

Selección de la estructura del modelo

La selección de la estructura del modelo para casos no lineales es más complejo que para casos lineales. No solo es necesario definir los regresores (NN) sino que también hay que tener en cuenta la arquitectura de la red. La idea es seleccionar los regresores basado en la inspiración de la identificación de sistemas lineales y entonces determinar la mejor arquitectura de la red, tomando los regresores como entradas. La estructura seleccionada se muestra en la figura 2.4.




Figura 2.4. Estructura de la red para el modelo directo del proceso.

Se seleccionó el modelo autoregresivo no lineal (NNARX)

Vector de regresión:

$$\varphi(t) = [y(t-1) \dots y(t-n_a) \dots u(t-n_k) \dots u(t-n_b-n_k+1)]^T \quad 2.2$$

Predictor:

$$\hat{y}(t|\theta) = \hat{y}(t|t-1, \theta) = g(\varphi(t), \theta) \quad 2.3$$

Donde el vector $\varphi(t)$ contiene a los regresores, n_a (número de salidas pasadas); n_b (número de entradas pasadas); y n_k (retardo del sistema); θ (pesos de las conexiones); y g es la función realizada por la red neuronal.

Estimación del modelo

El procedimiento de estimación de un modelo neuronal a partir de datos de entrada - salida consiste en un algoritmo de entrenamiento de la red con la estructura regresora, con el fin de encontrar una combinación de pesos y sesgos óptima. Por sus características y potencialidades fue escogido el algoritmo Levenberg-Marquardt. Para su realización es necesario dividir los datos experimentales en dos partes, una para el entrenamiento (utilizada en este paso) y otra para la validación.

Para el proceso de entrenamiento se recomienda realizar una normalización de los datos, con el objetivo de llevar su media a cero y la varianza a uno (Aguado, 2000; Haykin, 1999). El *Toolbox* de Identificación de Sistemas “NNSYSD” brinda esta posibilidad mediante el comando `dscales` (antes del entrenamiento) y `wrescale` (antes de la validación). A continuación se muestra la implementación en MATLAB:

```
NetDeff = ['# neuronas en capa oculta'; '# neuronas en capa de  
salida'];  
NN = [na nb nk];  
trparms = settrain;  
trparms = settrain(trparms, 'maxiter', #, 'D', #);  
[W1, W2, PI_vector, iteration] = nnarx(NetDeff, NN, [], [], trparms, yls,  
uls);
```

Argumentos de entrada

NetDeff: Arquitectura de la red: está constituida por un número determinado de neuronas en la capa oculta y capa de salida respectivamente, con funciones de activación por cada capa.

NN = [n_a n_b n_k]: n_a (número de salidas pasadas), n_b (número de entradas pasadas) y n_k (retardo del sistema).

W1: Pesos y sesgos de las conexiones entre las neuronas de entrada y la capa oculta (se inicializa por defecto al igual que W2 de forma aleatoria).

W2: Pesos y sesgos de las conexiones entre la capa oculta y la capa de salida.

trparms: Estructura de datos que contiene la inicialización de los parámetros necesarios para el algoritmo de entrenamiento, como el número de iteraciones ('maxiter' definido en 500), y la cota de error ('D' definida por defecto en 0,001).

y1s, u1s: Datos de salida y entrada para el entrenamiento respectivamente.

Variables de salida

W1f y W2f: Matrices de los pesos y sesgos después del entrenamiento.

PI_vector: Vector que contiene la evaluación del criterio del error después de cada iteración.

Iteration: número de iteraciones o épocas.

Validación del modelo

Luego de ser entrenada la red, lo siguiente sería validarla, a partir de la matriz de pesos y sesgos obtenidos en el paso anterior, para ello se utilizan datos que no fueron usados en su entrenamiento. El empleo del algoritmo de entrenamiento Levenberg-Marquardt implica bajos errores de predicción en la etapa de entrenamiento y estos tienden a aumentar en la validación, por lo que la obtención de un buen modelo depende principalmente de cómo se comporten los errores de predicción para estos datos nuevos. Comúnmente se dice que en este paso se comprueba lo que red aprendió. Vale señalar que la red obtenida es validada primeramente para los datos de entrenamiento y luego para los de validación. Seguidamente se muestra el código en MATLAB para llevar a cabo esta operación:

```
[yhat, NSSE] = nnvalid('nnarx', NetDeff, NN, W1f, W2f, Y1, U1);  
[yhat, NSSE] = nnvalid('nnarx', NetDeff, NN, W1f, W2f, Y2, U2);
```

Argumentos de entrada

nnarx: Función para obtener una red neuronal a partir de un modelo ARX.

Y2, U2: Datos de salida y entrada para la validación respectivamente.

Nota: Los demás parámetros son los mismos que para el entrenamiento.

Variables de salida

yhat: Predicción de la red un paso adelante.

NSSE: Suma normalizada del cuadrado de los errores.

Con la función **nnvalid** se obtienen los gráficos:

- ✓ Salida deseada contra predicción de la red.
- ✓ Error de predicción (y-yhat).
- ✓ Función de autocorrelación del error de predicción y la correlación cruzada entre el error de predicción y la entrada.
- ✓ Histograma que muestra la distribución de los errores de predicción.
- ✓ Coeficientes del modelo lineal extraídos.

En la figura 2.5 se presenta el algoritmo general o diagrama de bloques, en los cuales se utilizan diferentes métodos y técnicas para lograr el resultado final de la investigación.




Figura 2.5. Algoritmo empleado en la investigación.

Conclusiones

1. Se describió el diseño experimental con secuencias binarias pseudoaleatorias de amplitud modulada, con la intención de que los datos se utilicen tanto para obtener modelos lineales como modelos no lineales; que permitan diseñar y probar estrategias de control avanzado.
2. Se mostró la estructura que da acceso a todas las propiedades de la red neuronal y que permite a su vez modificar las entradas, capas, conexiones, etc.

Capítulo 3. Resultados experimentales y caracterización del subproceso de postcombustión, con ayuda de redes neuronales artificiales

Introducción

Toda modelación experimental exige la ejecución de ensayos para lograr la adecuación del modelo elaborado al objeto industrial.

El objetivo del capítulo es: caracterizar con ayuda redes neuronales artificiales el comportamiento del subproceso de postcombustión, a través de los resultados experimentales obtenidos de la instalación.

3.1 Resultados del análisis estadístico de los datos

Como herramienta auxiliar para seleccionar las variables a utilizar en el control se realizó un análisis estadístico a partir de un conjunto de datos de operación, medidos adecuadamente y de forma continua.

El análisis estadístico se realizó con el objetivo de determinar las variables que presentan mayor influencia en el comportamiento de la temperatura de los hogares cuatro y seis del horno.

Para dicho análisis se tomaron datos de operación del horno cinco durante los meses de mayo a julio del año 2015 y se procesaron con los softwares Microsoft Excel y Statgraphics Plus 5.1.

Estos datos se obtuvieron a partir de los reportes que emite el Sistema Supervisor CITECT.

En la tabla 3.1 aparecen los valores promedio representados por (X) y las desviaciones estándar por (S) para cada una de las variables que se miden en el horno, que son:

- ✓ ApH4, ApH6 [Apertura de la 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, 14 y 15 respectivamente (°C)].
- ✓ PH0, PH16 [Presión en los hogares cero y 16 (Pa)].

- ✓ TC6S, TC8N, TC8S, TC10N, TC10S, TC12N, TC12S, TC15S [Temperatura de las cámaras de combustión, hogares seis, ocho, 12 y 15, lado norte y sur (°C)].
- ✓ CO [Concentración de monóxido de carbono residual (%)].

En los meses antes señalados no estaba instalado el medidor de flujo de aire de postcombustión, por lo que se tomaban las aperturas de las válvulas reguladoras de flujo de aire a los hogares cuatro y seis, como medidas proporcionales al flujo de aire.

El mineral procesado durante este período fue de muy buenas características, con un alto contenido de hierro.

Tabla 3.1. Comportamiento de las variables del horno para tres meses de trabajo.

Variables	Mes					
	Mayo		Junio		Julio	
	X	S	X	S	X	S
ApH4	46,20	27,07	35,22	22,60	46,87	22,36
ApH6	24,14	10,91	24,36	10,81	25,68	12,99
TH0	435,92	25,28	424,29	26,20	421,71	24,65
TH2	538,77	35,79	535,318	34,31	528,04	36,11
TH4	718,21	82,33	731,01	76,97	709,43	77,96
TH6	726,31	62,51	723,51	67,47	702,24	80,32
TH7	557,10	35,25	569,73	40,42	548,37	39,52
TH9	682,73	28,50	673,22	33,62	658,39	35,77
TH11	725,42	28,72	721,52	37,18	728,61	37,23
TH13	710,53	30,67	705,47	40,35	713,08	33,96
TH14	728,53	37,28	721,14	50,95	735,59	33,73
TH15	764,81	45,81	756,48	68,92	770,39	39,61
PH0	100,85	31,98	74,75	21,48	65,43	28,35
PH16	22,37	24,63	17,27	24,33	17,07	25,02
TC6S	1357,47	118,75	1338,48	170,03	1355,61	118,27
TC8N	1356,82	116,82	1328,40	180,16	1346,16	135,09
TC8S	1348,29	131,98	1328,24	183,11	1352,52	135,96
TC10N	983,54	183,60	1101,14	208,34	1128,98	191,89
TC10S	860,59	57,34	867,01	115,01	839,86	89,27
TC12S	1355,72	110,81	1312,23	232,58	1353,23	115,43
TC12N	1357,21	132,89	1320,75	190,95	1351,29	145,93
TC15S	1358,36	123,31	1280,77	320,61	1350,90	135,13
CO	1,91	1,36	1,04	1,44	1,12	1,44

Se realizó un análisis estadístico descriptivo de la tendencia general del perfil térmico de los hogares cuatro y seis durante estos tres meses de trabajo, cuyos resultados

se presentan en la tabla 3.2. Para este caso se observa que los valores de Curtosis y del Coeficiente de asimetría, permiten afirmar que las variables dependientes (temperatura de los hogares cuatro y seis) se comportan como distribuciones normales.

Tabla 3.2. Resumen del análisis estadístico descriptivo de la muestra para tres meses.

Funciones estadísticas	Mes					
	Mayo		Junio		Julio	
	TH4	TH6	TH4	TH6	TH4	TH6
Media	718,2	726,3	731	723,5	709,4	702,2
Error típico	0,6	0,4	0,5	0,5	0,5	0,5
Mediana	734,9	734,8	748,7	734,7	717,2	710,9
Moda	498,9	597,9	610,9	607,9	430,9	454,9
Desviación estándar	82,3	62,5	76,9	67,5	77,9	80,3
Varianza de la muestra	6778,8	3907,9	5923,7	4552,7	6077	6450,9
Curtosis	2,1	1,4	1,9	2,9	1,9	2,2
Coeficiente de asimetría	-1,2	-0,6	-1,1	-1,0	-0,9	-0,7
Rango	593,1	582,1	690,9	624,1	580,7	706,7
Mínimo	319,9	473,4	418,3	425,5	352,0	291,8
Máximo	912,9	1055,5	1109,1	1049,6	932,8	998,5
Suma	1499413 2	1516322 0	1580206 6	1564004 5	1536064 5	1520496 0
Cuenta	20877	20877	21617	21617	21652	21652
Nivel de confianza (95,0 %)	1,1	0,9	1,0	0,9	1,0	1,0

Se presentan además los histogramas de frecuencia para TH4 y TH6 durante los tres meses de trabajo en las figuras 3.1, 3.2, 3.3, 3.4, 3.5 y 3.6.




Figura 3.1. Histograma de la temperatura del hogar cuatro (TH4). Mayo 2015




Figura 3.2. Histograma de la temperatura del hogar seis (TH6). Mayo 2015




Figura 3.3. Histograma de la temperatura del hogar cuatro (TH4). Junio 2015




Figura 3.4. Histograma de la temperatura del hogar seis (TH6). Junio 2015




Figura 3.5. Histograma de la temperatura del hogar cuatro (TH4). Julio 2015




Figura 3.6. Histograma de la temperatura del hogar seis (TH6). Julio 2015

Con los datos del mes de mayo se realizó un análisis de regresión paso a paso hacia atrás, para determinar las variables independientes que más influyen en TH4 y TH6 (ver ecuaciones 3.1 y 3.2).

$$TH4 = -166,898 + 0,271143TC8S - 0,542596 \cdot TH0 + 0,129507 \cdot TH13 + 1,44636 \cdot TH2 - 0,84256 \cdot ApH4 - 0,105043 \cdot TH6 \quad (3.1)$$

$$TH6 = 171,589 + 0,332765 \cdot TC6S + 0,836962 \cdot TH13 - 1,12725 \cdot TH14 + 0,655806 \cdot TH15 - 0,133769 \cdot TH4 - 0,244847 \cdot ApH4 + 0,643314 \cdot ApH6 + 0,937937 \cdot TH7 - 0,88278 \cdot TH9 \quad (3.2)$$

En la tabla 3.3, el estadístico R^2 indica que el modelo 3.1 explica un 0,62 de la variabilidad en la temperatura del hogar cuatro, mientras que el modelo 3.2 explica un 0,42 de la variabilidad en la temperatura del hogar seis. El estadístico R^2 ajustado, que es más conveniente para comparar modelos con diferentes números de variables independientes, es 0,62 para TH4 y 0,42 para TH6. El error estándar de la estimación muestra la desviación típica de los residuos, que es 50,62 para TH4 y 47,35 para TH6.

Tabla 3.3. Resumen del análisis de regresión para TH4 y TH6.

Estadísticas de la regresión	Variables	
	TH4	TH6
Coefficiente de correlación múltiple	0,79	0,65
Coefficiente de determinación R^2	0,62	0,42
R^2 ajustado	0,62	0,42
Error típico	50,62	47,35

Las tablas 3.4 y 3.5 muestran el análisis de varianza para las variables dependientes TH4 y TH6. Se resalta que los porcentajes son inferiores a 0,01, por lo que existe relación estadísticamente significativa entre las variables para un nivel de confianza del 99 %.

Tabla 3.4. Análisis de varianza para la temperatura en el hogar cuatro.

Fuente	Suma de Cuadrados	Grados de Libertad	Cuadrado Medio	Comp. Var.	Porcentaje
Modelo	$8,80424 \cdot 10^7$	6	$1,46737 \cdot 10^7$	5 727,11	0,0000
Residuo	$5,34722 \cdot 10^7$	20 870	2 562,15	231,765	

Tabla 3.5. Análisis de varianza para la temperatura en el hogar seis.

Fuente	Suma de Cuadrados	Grados de Libertad	Cuadrado Medio	Comp. Var.	Porcentaje
Modelo	$3,47949 \cdot 10^7$	9	$3,8661 \cdot 10^6$	1 724,26	0,0000
Residuo	$4,67876 \cdot 10^7$	20 867	2 242,18		

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 la temperatura de los hogares cuatro y seis del horno en el rango establecido, el sistema se consideró como una caja negra cuyas variables son (ver figura 3.7):

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), [%].
- Fm (Flujo de mineral alimentado al horno), [t/h].

Variables de salida,

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




Figura 3.7. Subproceso de postcombustión visto como caja negra.

Las principales perturbaciones que afectan a este proceso son:

- la temperatura del mineral;
- el flujo, la temperatura y composición química de la mezcla de gases;
- la presión en el interior del horno;
- la temperatura y humedad relativa del medioambiente.

3.2 Descripción de la instalación para la postcombustión

El sistema de postcombustión está constituido básicamente por un ventilador centrífugo (tabla 3.6) 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 los hogares cuatro y seis, con sistema de regulación de flujo a través de válvulas de mariposa.

Tabla 3.6. Datos técnicos del ventilador de postcombustión.

Tipo de ventilador	PHD-685/100-100S
Velocidad del rotor	233,4 rad/s
Densidad	855 kg/m ³
Motor	11kW
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 el hogar cuatro, donde se ramifica en dos conductos de igual diámetro, uno va al hogar cuatro y el otro al hogar seis. Ver figura 3.8.

En la figura 3.9 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 $6\,796\text{ m}^3/\text{h}$, con una presión de 3 kPa .




Figura 3.8. Esquema de la instalación de la postcombustión.




Figura 3.9. Características del ventilador de postcombustión.

Fuente: Tomado de <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 3.7 el flujo de aire a los hogares cuatro y seis después de la bifurcación, en función de la apertura de las válvulas.

Tabla 3.7. Flujo de aire equivalente en función de la apertura de válvulas.

Apertura de la válvula a los hogares cuatro y seis (%)	Flujo de aire a los hogares cuatro y seis (m ³ /h)
10	679,60
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	616,40
100	6 7960

3.3 Experimentos previos con entrada escalón

Los experimentos se realizaron en el horno cinco de la Unidad Básica de Producción Planta “Hornos de Reducción” de la Empresa Productora de Níquel y Cobalto “Comandante Che Guevara”.

Para determinar las constantes de tiempo predominantes del subproceso de postcombustión y teniendo en cuenta la existencia de perturbaciones repentinas, se deben realizar los experimentos con función escalón (Ogata, 2010):

Prueba A: Se aplicó un escalón positivo (+20 %) a la apertura de la válvula del hogar cuatro que se encontraba inicialmente en un 33 % . Se mantuvo constante la válvula del hogar seis en 35 % y el flujo de mineral en 18,2 t/h . El valor inicial de la temperatura del hogar cuatro era 701 °C y luego del cambio se estableció en 802 °C , ver figura 3.10.

Prueba B: Se le aplicó un escalón positivo (+22 %) a la apertura de la válvula del hogar seis que se encontraba inicialmente en un 39 % . Se mantuvo constante la apertura de la válvula del hogar cuatro en 31 % y el flujo de mineral en 18,2 t/h . Luego del cambio, la temperatura del hogar seis alcanzó el nuevo estado estacionario en 845 °C , ver figura 3.11.




Figura 3.10. Respuesta de las temperaturas de los hogares cuatro y seis ante un escalón en la apertura de válvula del hogar cuatro.




Figura 3.11. Respuesta de las temperaturas de los hogares cuatro y seis ante un escalón en la apertura de válvula del hogar seis.

En la prueba B se aprecia en mayor medida el carácter multivariable del proceso ya que al incrementar la apertura de la válvula reguladora de flujo de aire al hogar seis, la temperatura correspondiente a este hogar aumenta y la temperatura del hogar cuatro desciende, debido al incremento de la combustión de gases en el hogar seis y consecuentemente la cantidad de monóxido de carbono que llega al hogar cuatro es menor.

Por otro lado, se tomaron los valores de amplitud en los escalones en los hogares cuatro y seis de 20 y 22 % respectivamente, buscando que el cambio en la dinámica del proceso fuera apreciable y además tratar de no llevar el sistema a niveles críticos. A partir de las respuestas observadas en las figuras 3.10 y 3.11, se determinó una constante de tiempo de 600 s para el hogar cuatro y de 660 s para el hogar seis, ante cambios en las aperturas de válvulas reguladoras de flujo de aire directo hacia los hogares.

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

Prueba C: para un flujo de mineral alimentado al horno de 18,2 t/h y manteniendo constante la apertura de la válvula del hogar seis en 25 %, se aplicaron escalones positivos (+20 %) a la apertura de la válvula del hogar cuatro desde 0 hasta 100 %, dejando transcurrir la constante de tiempo de 10 minutos en cada porciento de apertura de válvula, antes de provocar el siguiente cambio (ver figura 3.12).




Figura 3.12. Relación entre las temperaturas de los hogares cuatro y seis con la apertura de la válvula reguladora de flujo de aire al hogar cuatro, en estado estacionario.

Se considera que a partir del 40 % de la apertura de la válvula del hogar cuatro, la temperatura de este hogar aumenta debido a que la cantidad de aire es suficiente para la postcombustión de los gases, mientras que el flujo de mineral desciende y

arrastra moléculas de oxígeno hacia el hogar seis; que reaccionan con los gases reductores y por consiguiente aumenta la temperatura del hogar seis.

Prueba D: Con un flujo de mineral alimentado al horno de 18,2 t/h y manteniendo constante la apertura de la válvula del hogar cuatro en 55 % , se aplicaron escalones positivos (+20 %) a la apertura de la válvula del hogar seis desde 0 hasta 90 % , dejando transcurrir la constante de tiempo de 11 minutos en cada porciento de apertura de válvula alcanzado, antes de provocar el siguiente cambio (ver figura 3.13).




Figura 3.13. Relación entre las temperaturas de los hogares cuatro y seis con la apertura de la válvula reguladora de flujo de aire al hogar seis, en estado estacionario.

En el rango de apertura de la válvula del hogar seis de 0 a 40 % , 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. 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 del hogar seis. A partir del 40 % de apertura, la temperatura del hogar seis aumenta porque se quema el monóxido de carbono en este hogar y por consiguiente se aprecia una disminución de la temperatura del hogar cuatro, debido a que la cantidad de gases reductores que llegan a este hogar no es suficiente para la reacción química.

El comportamiento térmico de los hogares cuatro y seis 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 (Ramírez, 2002a).

3.4 Condiciones generales para la modelación

Para realizar una modelación se deben establecer determinadas fronteras o condiciones sobre las cuales se realiza. En el caso de estudio estas condiciones se definen como:

- El horno seleccionado tiene buenas condiciones técnicas, con una mayor sensibilidad en la respuesta de las temperaturas de los hogares cuatro y seis ante variaciones en las aperturas de las válvulas reguladoras de flujo de aire a estos hogares. Posee siete cámaras de combustión (seis sur, ocho norte, ocho sur, 10 norte, 10 sur, 12 norte, 12 sur y 15 sur); 67 brazos en el eje central y tiene todas las bóvedas en buen estado.
- La instrumentación a emplear posee condiciones óptimas (se garantiza el mantenimiento a los sensores y elementos de acción final antes del inicio de los experimentos). Ver (tabla 2.1).
- La composición química del mineral y las características del petróleo suministrado a la Planta “Hornos de Reducción” durante la realización de los experimentos se muestran en la tabla 3.8, siendo sus parámetros típicos durante el año.

Tabla 3.8. Características de las materias primas.

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

- Para los experimentos con flujo de aire, se generó primero una señal binaria pseudoaleatoria de quinto orden con un período de conmutación de 60 s (10 veces menor que las constantes de tiempo estimadas para TH4 y TH6). En este caso se obtuvo una longitud de la secuencia de 31 períodos. Se seleccionó un período de muestreo de 3 s , 20 veces menor que el período de conmutación de la señal de excitación. Luego se generó una secuencia de valores aleatorios con la ayuda del comando *rand* del MATLAB, en el rango de amplitud de la apertura de la válvula al hogar cuatro (10 a 60 %) y de la apertura de la válvula al hogar seis (20 a 70 %), los cuales se añadieron a los estados de la secuencia binaria pseudoaleatoria antes generada (Montero, Ramírez, Gilbert, & Campos, 2015).

Bajo estas consideraciones se obtuvo una señal modulada en amplitud y frecuencia, cuya secuencia tiene un tiempo de duración de 1 860 s.

- Para los experimentos con el flujo de mineral se generó primero una señal binaria pseudoaleatoria de tercer orden, con un período de conmutación de 300 s. En este caso se obtuvo una longitud de la secuencia de siete períodos y se seleccionó un período de muestreo de 3 s . Luego se generó una secuencia de valores aleatorios en el rango de amplitud en que trabaja el dispositivo de pesaje (16 a 19 t/h), los cuales se añadieron a los estados de la secuencia binaria pseudoaleatoria antes generada (Montero, Ramírez, Gilbert, & Campos, 2015).

3.5.1 Experimento # 1: Variación de la apertura de la válvula del hogar cuatro

Durante el experimento se aplicaron dos réplicas de la secuencia binaria pseudoaleatoria de amplitud modulada y se tomaron 1 240 datos correspondientes a las variables TH4, TH6 y ApH4. En este caso la apertura experimentó una variación de 12 a 57 % de su recorrido total, la apertura de la válvula del hogar seis se mantuvo constante en 40 % y el flujo de mineral alimentado al horno fue de 18,2 t/h . En la figura 3.14 se observan las mediciones de las variables de entrada y de salida.




Figura 3.14. Datos de entrada y salida del experimento # 1.

En la práctica se comprobó que un número pequeño de neuronas en la capa oculta es suficiente para obtener un buen modelo neuronal del proceso. A medida que se aumenta el número de neuronas en dicha capa los modelos no difieren mucho, aunque se evidencian leves mejorías en la función de autocorrelación de errores y niveles de confianza similares. Además de que esto implica un volumen de cálculo mayor por parte de la red.

La arquitectura de la red propuesta está compuesta por siete neuronas en la capa oculta y una en la capa de salida, cuyas funciones de activación son tangente hiperbólica (H) y lineal (L) respectivamente (ver figura 3.15).




Figura 3.15. Arquitectura de la red neuronal directa.

Para TH4, la estructura regresora es (NNARX) 221 y aunque se realizaron múltiples pruebas; los mejores resultados se obtuvieron con esta estructura.

Luego de realizar varios entrenamientos de la red, la cota de error la alcanzó en 80 iteraciones. Los valores de pesos y sesgos obtenidos de las conexiones de las neuronas de entrada a la capa oculta, fueron:

$$W1f = \begin{bmatrix} -0,0112 & -0,0072 & -0,0014 & 0,0024 & -3,2191 \\ 0,0128 & -0,0019 & -0,0003 & -0,0015 & -9,4984 \\ -0,009 & 0,0041 & -0,0012 & -0,0006 & 3,9953 \\ 0,0092 & -0,0044 & -0,002 & 0,0035 & -3,9911 \\ 0,0017 & 0,0027 & 0,0041 & 0,0233 & -4,5275 \\ 0,009 & -0,006 & -0,0045 & -0,0018 & 2,4971 \\ -0,0157 & 0,0038 & -0,0013 & 0,0021 & 8,603 \end{bmatrix} \quad 3.3$$

Los correspondientes a las conexiones entre la capa oculta y la capa de salida fueron:

$$W2f = [34,54 \quad 43,30 \quad -29,25 \quad 30,54 \quad -7,72 \quad -30,08 \quad -38,16 \quad 802,59] \quad 3.4$$

La prueba de validación para la temperatura del hogar cuatro se muestra en la figura 3.16; donde se cometen errores de predicción de - 2 a 5 % .




Figura 3.16. Salida de la red vs. Salida real y predicción del error para TH4 (Experimento #1).

La estructura regresora para TH6 fue (NNARX) 341 y la cota de error la alcanzó en 354 iteraciones. Los valores de pesos y sesgos se muestran en 3.5 y 3.6.

$$W1f = \begin{bmatrix} -1,8 & 0,8 & 0,9 & -0,01 & -0,002 & 0,01 & 0,002 & 38,09 \\ 0,1 & -0,08 & 0,5 & -0,001 & 0,002 & 0,02 & -0,001 & -375,6 \\ 0,2 & -0,2 & 0,2 & -0,0008 & 0,0003 & 0,0007 & 0,00009 & -110,3 \\ 0,3 & -0,5 & -0,4 & -0,0004 & -0,001 & -0,02 & 0,003 & 412,6 \\ 0,3 & 0,7 & -1,03 & 0,01 & -0,01 & 0,02 & -0,009 & -9,6 \end{bmatrix} \quad 3.5$$

$$W2f = [-0,47 \quad -2,15 \quad 8,96 \quad -1,31 \quad 2,07 \quad 759,42] \quad 3.6$$

La figura 3.17 muestra la prueba de validación para la temperatura del hogar seis; donde se cometen errores de predicción de - 0,5 a 0,6 % .




Figura 3.17. Salida de la red vs. Salida real y predicción del error para TH6 (Experimento #1).

3.5.2 Experimento # 2: Variación de la apertura de la válvula del hogar seis

Durante el experimento se aplicaron dos réplicas de la secuencia binaria pseudoaleatoria de amplitud modulada y se tomaron 1 240 datos correspondientes a las variables TH4, TH6 y ApH6. En este caso la apertura experimentó una variación de 20 a 68 % de su recorrido total, la apertura de la válvula del hogar cuatro se mantuvo constante en 25 % y el flujo de mineral alimentado al horno fue de 18,2 t/h . En la figura 3.18 se observan las mediciones de las variables de entrada y de salida.




Figura 3.18. Respuesta temporal variando ApH6 (Experimento #2).

Para TH6, la estructura regresora fue (NNARX) 221 y la cota de error la alcanzó en 88 iteraciones. En 3.7 y 3.8 se presentan los valores de pesos y sesgos.

$$W1f = \begin{bmatrix} -0,05 & -0,01 & 0,01 & 0,004 & 43,63 \\ -0,04 & -0,08 & -0,04 & 0,006 & 93,33 \\ 0,04 & 0,04 & -0,02 & 0,01 & -66,26 \\ 0,04 & 0,03 & -0,01 & -0,004 & -46,54 \\ 0,03 & 0,02 & 0,05 & -0,02 & -42,46 \\ -0,08 & -0,03 & -0,007 & -0,01 & 89,3 \\ 0,08 & -0,06 & 0,01 & 0,0005 & -15,27 \end{bmatrix} \quad 3.7$$

$$W2f = [-9,66 \quad -4,69 \quad 6,22 \quad 10,11 \quad -3,07 \quad 7,49 \quad 20,33 \quad 764,77] \quad 3.8$$

Tras seguir el mismo procedimiento descrito para el primer experimento, se cometen errores de predicción de $-1,2$ a $0,9$ % para la temperatura del hogar seis. Ver figura 3.19.




Figura 3.19. Salida de la red vs. Salida real y predicción del error para TH6 (Experimento #2).

La estructura regresora para TH4 fue 221 y la cota de error la alcanzó en 215 iteraciones. Los valores de pesos y sesgos se muestran en 3.9 y 3.10.

$$W1f = \begin{bmatrix} -0,009 & 0,004 & 0,0004 & 0,0002 & 3,17 \\ -0,02 & 0,004 & 0,002 & 0,0008 & 8,69 \\ -0,009 & 0,004 & -0,002 & 0,003 & 2,99 \\ 0,009 & -0,005 & -0,0009 & 0,001 & -3,3 \\ -0,003 & -0,0002 & -0,02 & -0,004 & 2,93 \\ -0,007 & 0,002 & 0,0007 & -0,001 & 3,68 \\ -0,01 & 0,003 & 0,003 & -0,0004 & 6,8 \end{bmatrix} \quad 3.9$$

$$W2f = [-28,82 \quad -45,56 \quad -29,06 \quad 29,35 \quad -8,12 \quad -24,57 \quad -37,99 \quad 733,36] \quad 3.10$$

En la figura 3.20 se muestra la prueba de validación para la temperatura del hogar cuatro, donde se cometen errores de predicción de - 4 a 4 % .




Figura 3.20. Salida de la red vs. Salida real y predicción del error para TH4 (Experimento #2).

3.5.3 Experimento # 3: Variación del flujo de mineral

Durante el experimento se aplicaron dos réplicas de la secuencia binaria pseudoaleatoria de amplitud modulada y se tomaron 1 103 datos correspondientes a las variables TH4, TH6 y Fm. En la figura 3.21 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 de los hogares cuatro y seis se mantuvieron constantes en 20 y 30 % , respectivamente.




Figura 3.21. Respuesta temporal variando Fm (Experimento #3).

La estructura regresora para TH4 fue (NNARX) 331 y la cota de error la alcanzó en 135 iteraciones. Los valores de pesos y sesgos se muestran en 3.11 y 3.12.

$$W1f = \begin{bmatrix} 0,02 & -0,01 & 0,003 & 0,05 & 0,03 & -0,08 & -5,79 \\ -0,02 & 0,02 & -0,007 & 0,10 & -0,07 & -0,02 & 5,91 \\ -0,02 & 0,02 & -0,009 & -0,11 & 0,006 & 0,13 & 5,59 \\ 0,01 & -0,002 & 0,01 & -0,05 & 0,03 & 0,01 & -6,14 \\ 0,03 & -0,002 & -0,002 & 0,01 & -0,03 & 0,33 & -11,18 \\ -0,008 & 0,006 & -0,005 & 0,007 & -0,06 & 0,06 & 5,20 \\ -0,007 & 0,009 & -0,01 & 0,02 & 0,07 & 0,24 & 2,83 \end{bmatrix} \quad 3.11$$

$$W2f = [16,42 \quad -21,48 \quad -21,78 \quad 18,81 \quad 22,30 \quad -10,66 \quad -13,63 \quad 752,90] \quad 3.12$$

La estructura regresora para TH6 fue 221 y la cota de error la alcanzó en 141 iteraciones. Los valores de pesos y sesgos se presentan en 3.13 y 3.14.

$$W1f = \begin{bmatrix} -0,02 & -0,007 & -0,08 & -0,18 & 26,88 \\ 0,05 & 0,05 & -0,04 & -0,47 & -62,24 \\ 0,03 & 0,006 & 0,08 & 0,18 & -26,79 \\ 0,08 & 0,009 & 0,32 & 0,17 & -80,44 \\ -0,11 & 0,08 & 0,07 & 0,05 & 19,07 \\ -0,06 & 0,02 & -0,31 & 0,03 & 41,38 \\ -0,009 & -0,04 & -0,14 & -0,22 & 41,88 \end{bmatrix} \quad 3.13$$

$$W2f = [-4,52 \quad 2,77 \quad 4,56 \quad -4,32 \quad -12,33 \quad -8,14 \quad -5,11 \quad 772,49] \quad 3.14$$

En las figuras 3.22 y 3.23 se muestran los resultados durante la validación para las salidas observadas, donde se aprecian errores de predicción más bajos para la temperatura del hogar seis respecto a la temperatura del hogar cuatro.




Figura 3.22. Salida de la red vs. Salida real y predicción del error para TH4 (Experimento #3).




Figura 3.23. Salida de la red vs. Salida real y predicción del error para TH6 (Experimento #3).

Finalmente, como resultado de los tres experimentos con señales binarias pseudoaleatorias de amplitud modulada; se muestran los modelos independientes que trabajando al unísono, conforman el modelo general basado en redes neuronales artificiales para el subproceso de postcombustión del horno de reducción de mineral (figura 3.24). Las señales verticales son consideradas también como entradas de los tres modelos, pero varían en el tiempo.




Figura 3.24. Estructura del modelo general de los tres experimentos.

3.6 Implementación de las redes neuronales artificiales

Para la identificación y posterior estrategia de control del subproceso de postcombustión del horno de reducción de mineral; se proponen los siguientes modos de implementación de las redes neuronales artificiales obtenidas:

- 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 secuencialmente las operaciones.
- Realización 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 red neuronal artificial. Son los llamados chips neuronales con inserción en PLC (Procesador Lógico Programable). Estos funcionan a alta velocidad permitiendo el proceso en tiempo real.

La comercialización de productos software es la forma más extendida para simular redes neuronales artificiales. La diferencia entre los distintos productos de software radica en aspectos tales como el tipo y el número de arquitecturas de red que soporta, velocidad de procesamiento, interfaz gráfica y exportación de código C para el desarrollo automático de aplicaciones.

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

3.7 Valoración socio-ambiental

Aunque el título de este epígrafe se refiere a una valoración socio-ambiental, el concepto de medio ambiente ha ido evolucionando (GEST, 1999). En sus inicios se identificaba con el medio natural (biofísico fundamentalmente), en la actualidad existe la opinión generalizada de que medio ambiente es algo mucho más amplio y complicado. Se enfatiza la relación entre la sociedad y la naturaleza, ya que esta última le sirve de base a la primera para su actividad existencial. O sea, se aprecia al medio ambiente no sólo desde una posición puramente natural, sino más integral, al tenerse en cuenta la actividad social y su entorno.

Dentro de la Empresa Productora de Níquel y Cobalto “Comandante Che Guevara”, la Unidad Básica de Producción Planta “Hornos de Reducción” es la que mayor incidencia tiene sobre la degradación del medio ambiente en la zona, debido a la contaminación atmosférica que provoca por desprendimiento de polvo y gases.

Producto de la circulación del aire, estas sustancias nocivas recorren grandes distancias, lo que conlleva no sólo a la contaminación del área donde está enclavada la empresa sino además afecta territorios aledaños a la misma.

En aras de contribuir con el programa de Desarrollo y Perfeccionamiento de la Industria del Níquel Cubana se deben introducir nuevas tecnologías, para la disminución de las agresiones al ecosistema, ofreciendo 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, lo que es equivalente a no expulsar a la atmósfera toneladas de polvo anuales y se reduce considerablemente la cantidad de gases nocivos expulsados.

Por otra parte, las labores de explotación de los hornos de reducción están asociadas a un trabajo físico con altos gastos de energía por parte de los operadores y ayudantes. Consiste entre otras tareas en la manipulación frecuente del petróleo y el aire en las cámaras de combustión donde se alcanzan temperaturas de 1 400 °C , la limpieza de los quemadores, varias veces durante el turno de 8 h , la manipulación de válvulas, el arranque de motores y otros equipos auxiliares.

Además es un trabajo con alta carga psíquica para el operador al tener que estar constantemente vigilando la variación de todos los parámetros de explotación de los equipos. En caso de oscilación de los mismos está obligado a recorrer grandes distancias o a subir y bajar varios niveles para restablecer el parámetro.

Si se tiene en cuenta que el ambiente donde se desarrolla sus actividades presenta una alta concentración de polvo y gases tóxicos, se entiende fácilmente que es una labor sumamente agotadora, por lo que no podrá realizar las tareas de control manual satisfactoriamente en ocasiones.

Conclusiones

1. Se comprobó el carácter multivariable y no lineal del comportamiento del perfil térmico de los hogares cuatro y seis, respecto al flujo de aire suministrado a estos hogares, en estado estacionario.
2. El proceso de ensayo y error permitió seleccionar las estructuras de redes neuronales artificiales que mejor caracterizan el subproceso de postcombustión del horno de múltiples hogares.
3. El control de la postcombustión es de primordial importancia para mejorar la calidad ambiental de la localidad y contribuye además a aliviar el trabajo de los operadores de la planta.

Conclusiones generales

1. Se demostró a través del análisis estadístico que entre las variables que más inciden en la temperatura de los hogares cuatro y seis están las aperturas de las válvulas reguladoras de flujo de aire a dichos hogares.
2. La implementación en el horno cinco de un registro en el sistema supervisorio CITECT para la apertura de las válvulas de los hogares cuatro y seis, así como la programación de secuencias binarias pseudoaleatorias de amplitud modulada en el autómata; permitió la realización de experimentos en tiempo continuo.
3. Para la identificación del subproceso de postcombustión; la red neuronal artificial del tipo perceptrón multicapa, constituida por siete neuronas en la capa oculta y una en la capa de salida, con funciones de activación tangente hiperbólica (H) y lineal (L) respectivamente y algoritmo de entrenamiento Levenberg-Marquardt, ha sido seleccionada por su capacidad de aproximar funciones no lineales.
4. El modelo neuronal artificial propuesto ha sido capaz de predecir la temperatura del hogar cuatro con un rango de error de - 2 a 5 % y de - 0,5 a 0,6 % para la temperatura del hogar seis; con la apertura de la válvula del hogar cuatro entre 12 y 57 %, la apertura de la válvula del hogar seis en 40 % y el flujo de mineral alimentado al horno de 18,2 t/h .

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 demás hornos de reducción de la Empresa Productora de Níquel y Cobalto “Comandante Che Guevara”.
2. Instalar flujómetros de alta tecnología para la medición del flujo de aire a los hogares cuatro y seis del horno, que permitan experimentar el comportamiento del perfil térmico ante variaciones en el flujo de aire.
3. Que a partir de los modelos neuronales artificiales obtenidos se investiguen estrategias de control avanzado para el subproceso de postcombustión.

Bibliografía

- Aguado, A. (2000). *Temas de Identificación y Control Adaptable*. Instituto de Cibernética, Matemática y Física, La Habana.
- Ajayi, O., & Sheehan, E. (2012). Design loading of free flowing and cohesive solids in flighted rotary dryers. *Chemical Engineering Science*, 73, 400-411.
- Angulo, M. (1982). *Identificación y Control Extremal de un horno de reducción*. Tesis doctoral, Universidad Técnica Superior de Praga, Facultad de Electrotécnica, Praga.
- Añez, G., & Scarano, M. (2015). Modelado experimental del nivel de un tanque de agua en una planta piloto. *Telematique*, 14(1), 58-78.
- Arafet, P. (2004). Monografía sobre identificación de sistemas. Santiago de Cuba.
- Arafet, P., Chang, F., Domínguez, H., Torres, M. A., & León, E. (2004). *Métodos de Identificación dinámica*. Universidad de Oriente, Control automático.
- Bello, R. (2003). *Curso Introductorio a las Redes Neuronales Artificiales*. Universidad de Las Villas, Cuba.
- Bolton, G., Berezowsky, R., & Day, M. (1997). Hidrometallurgy: Nickel now and next century. La Haya, Holanda.
- Caldas, O., Jiménez, S., Mejía, E., Hernández, J., & Avilés, O. (2012). Identificación paramétrica en lazo cerrado de sistema de accionamiento neumático para cilindro de doble efecto. *Revista Facultad de Ingeniería UPCT*, 21(33), 9-19.
- Castellanos, J. (1986). Elaboración de minerales oxidados de níquel por el esquema carbonato-amoniaco. *Minería y Geología*, 4(2), 77-80.
- Chang, A. R. (1999). Una visión sobre las reservas estratégicas de eficiencia metalúrgica en la tecnología carbonato-amoniaco. *Minería y Geología*, 16(1), 76-82.
- Columbié, Á. (2001). *Modelación matemática del proceso de calcinación del carbonato básico de níquel en el horno tubular rotatorio*. Tesis doctoral, Instituto Superior Minero Metalúrgico de Moa "Dr. Antonio Núñez Jiménez", Moa.
- Columbié, Á. O., & Guzmán, D. (1999). Sobre la modelación matemática del proceso de calcinación del carbonato básico de níquel en el horno tubular rotatorio. *Minería y Geología*, 9(1), 27-29.
- Columbié, Á. O., & Guzmán, D. (2004). Sobre la solución del modelo matemático del proceso de calcinación del carbonato básico de níquel. *Minería y Geología*(1-2), 89-94.

Bibliografía

- Columbié, Á. O., & Rodríguez, J. (2000). Modelo matemático del proceso de calcinación del carbonato básico de níquel en el horno tubular rotatorio. *Minería y Geología*, 17(2), 47-58.
- de Armas, M., Gómez, J., Pérez, C., Meriño, L., & Sepúlveda, J. (2007). *Inteligencia artificial aplicada al análisis de sistemas energéticos con Matlab*. Cartagena de Indias – Colombia: Industrias Gráficas Koral.
- EROS, G. (1997). *Manual de operación EROS*. Nicaro, Holguín.
- Estrada, I., Peña, J., & Guarnizo, C. (2012). Estimación de modelos lineales para el control predictivo de pequeñas centrales hidroeléctricas. *Revista Soluciones de Postgrado EIA*(9), 63-78.
- Farzaneh, A., Ali, T., & Rajnikant, V. (2006). *Stable Identification of Nonlinear Systems Using Neural Networks: Theory and Experiments* (Vol. 11).
- GEST, G. d. (1999). *Colectivo de autores, Tecnología y Sociedad*. La Habana: Félix Varela.
- Gnielinski, V. (1976). New equations for heat and mass-transfer in turbulent pipe and channel flow. *International Chemical Engineering*, 16(2), 359-368.
- Góngora, E. (2014). *Modelación del proceso de enfriamiento del mineral laterítico en cilindros horizontales rotatorios*. Tesis doctoral, ISMMM, Ingeniería Mecánica, Moa.
- Gupta, G., Chakraborti, N., & Sundararajan, T. (1989). Development of a Mathematical Model for Multihearth Roasters. *Metallurgical Transactions*, 20B, 925-935.
- Guzmán, D. (2001). *Modelación, simulación y control del tanque de contacto y los enfriadores de licor en el proceso de lixiviación carbonato-amoniaco*. Tesis doctoral, ISMM, Ingeniería Eléctrica, Moa.
- Guzmán, D., & García, C. (2000). 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*, 17(2), 61-71.
- Guzmán, D., & Rodríguez, M. A. (2001). Proceso de lixiviación carbonato-amoniaco: control multivariable a través dle arreglo inverso de Nyquist para el mezclado de mineral y licor . *Minería y Geología*, 18(2), 1-6.
- Habashi, F. (1997). *Handbook of Extractive Metallurgy* (Vol. II). Germany, Weinheim: Wiley-VCH.
- Haykin, S. (1999). *Neural networks a Comprehensive Foundation* (Second ed.). USA: Prentice Hall.

Bibliografía

- Isermann, R. (2011). *Identification of dynamic systems. An introduction with application*. Springer Berlin Heidelberg.
- Isermann, R., Ayoubi, M., Konrad, H., & Reiss, T. (1993). *tools, Model based detection of tool wear and breakage for machine*.
- Kruger, U., & Xie, L. (2012). *Advances in statistical monitoring of complex multivariate processes: with applications in industrial process control*. J. Wiley and Sons.
- Laborde, R. (2005). *Modelación y simulación del proceso de molienda del mineral laterítico, con composición sustancial variable*. Tesis doctoral, Instituto Superior Minero Metalúrgico de Moa "Dr. Antonio Núñez Jiménez".
- Landau, I., & Zito, G. (2006). *Digital Control Systems. Design, Identification and Implementation*. London: Springer-Verlag.
- Levin, U. A., & Narendra, S. K. (1993). Control of nonlinear dynamical systems using neural networks: controllability and stabilization. *IEEE Transactions on neural networks*, 4(2), 192-206.
- Ljung, L. (1999). *System identification: Theory for the user* (Second ed.). Sweden: Prentice Hall information and System Sciences Series, Thomas Kailath.
- Ljung, L. (2012). *System Identification Toolbox. User's Guide*. New Jersey: Prentice-Hall.
- Ljung, L., & Sjöberg, J. (1992). *IEEE Workshop on Neural Networks for Signal Processing*. CIEEE Service Center, 445 Hoes Lane, Piscataway, NJ 08854-4150.
- Manual de Operaciones. (2007). *Planta "Hornos de Reducción"*. Cmte. Ernesto Che Guevara, Moa.
- Marichal, G. N. (1999). *Diseño de políticas de identificación y control de robots basadas en redes neuronales y sistemas neuro-fuzzy*, . Tesis de doctorado, Universidad de la Laguna.
- Marrero, S. (1989). *Algoritmos de control del proceso de reducción en hornos de soleras múltiples*. Tesis doctoral, Instituto de Minas de Leningrado, Leningrado.
- Ming, G. (2007). *Inverse Model Identification of nonlinear dynamic system using neuronal network*. Proceedings of the Sixth International Conference on Machine Learning and Cybernetics, School of Electrical and Information Engineering, Lanzhou university of Technology, Lanzhou 730050, China P.R. , Hong Kong.
- Miranda, J., Chaviano, R., & Miranda, J. R. (2002). Nuevas Interpretaciones químico-mineralógicas de las menas lateríticas y serpentínicas, a través del proceso

Bibliografía

- pirometalúrgico, en la tecnología carbonato-amoniaco. *Revista Cubana de Química*, 14(2), 42 – 50.
- Mohandas, K., & Suresh, P. (2006). *Simulation of Inverted Pendulum Using Neural Networks for Identification*. European University of Lefke. North Cyprus.
- Montero, D. (2012). Identificación experimental del subproceso de postcombustión en un horno de reducción de níquel. Moa, Cuba: ENERMOA.
- Montero, D., Ramírez, M., Gilbert, A., & Campos, S. (2015). Modelación matemática para el control de la postcombustión en un horno de reducción de níquel. *RIELAC*, 36(3), 21-34.
- Mujumdar, S., & Ranade, V. (2006). Simulation of Rotary Cement Kilns Using a One-Dimensional Model . *Chemical Engineering Research and Design*, 84(3), 165-177.
- Mujumdar, S., Arora, A., & Ranade, V. (2006). Modeling of Rotary Cement Kilns: Applications to Reduction in Energy Consumption". *Ind. Eng. Chem. Res.*, 45(7), 2315-2330.
- Nath, N., Chakraborti, N., & Shekhar, R. (1998). Reduction of Indian nickeliferous ore in a fixed bed reactor with gas flowing vertically through the bed. *Scandinavian Journal of Metallurgy*, 27(1), 14-22.
- Norgaard, M. (2000). *Neural Networks for Modelling and Control of Dynamic Systems*. London: Springer – Verlag.
- Ogata, K. (2010). *Modern Control Engineering*. (5ta ed.). New Jersey, USA: Prentice-Hall.
- Patan, K. (2008). *Artificial neural networks for the modelling and fault diagnosis of technical processes*. Springer.
- Peinado, D., & De Vega, M. (2011). Energy and exergy analysis in an asphalt plant's rotary dryer. *Applied Thermal Engineering*, 31 (6–7), 1039-1049.
- Rairán, J., Millán, F., & Guzmán, J. (2006). Control de procesos por medio de dos configuraciones de redes neuronales. Una revisión. *Tecnura*, 10(19), 4–17.
- Ramírez, M. (2001). Identificación experimental del subproceso de postcombustión en un horno de reducción de níquel. *Minería y Geología*, 18(2), 61-66.
- Ramírez, M. (2002). *Control borroso multivariable de la postcombustión en un horno de reducción de múltiples hogares*. Tesis doctoral, Instituto Superior Politécnico José Antonio Echeverría, Ciudad de La Habana.
- Ramírez, M. (2002). Modelado del proceso de postcombustión en un horno de reducción de níquel. *Revista de Metalurgia*, 38(2), 150-157.

Bibliografía


- Retirado, R. (2004). *Modelación Físico-Matemática del proceso de enfriamiento del mineral en cilindros rotatorios de la planta Hornos de Reducción perteneciente a la empresa "Comandante Ernesto Che Guevara"*. Tesis de Ingeniería, Instituto Superior Minero Metalúrgico de Moa "Dr. Antonio Núñez Jiménez", Moa.
- Retirado, R. (2012). *Modelación matemática del proceso de secado natural de las menas lateríticas*. Tesis doctoral, Instituto Superior Minero Metalúrgico de Moa "Dr. Antonio Núñez Jiménez", Moa.
- Retirado, Y., & Góngora, E. (2007). Comportamiento de la humedad durante el secado solar del mineral laterítico. *Minería y Geología*, 23(3), 1-19.
- Retirado, Y., & Góngora, E. (2008). Cinética del secado solar del mineral laterítico empleado en la industria del níquel en Moa. *In Proceedings of the 5to Taller Internacional de Energía y Medio ambiente*.
- Retirado, Y., & Góngora, E. (2009). Comportamiento de la adherencia en menas lateríticas sometidas a secado solar natural. *Minería y Geología*, 25(1), 1-11.
- Retirado, Y., & Lamorú, M. (2011). Transferencia de calor en el secado solar a la interperie de menas lateríticas ferroniquelíferas. *Minería y Geología*, 27(1), 1-21.
- Retirado, Y., & Legrá, A. (2011). Modelación matemática del área de exposición y volumen de las pilas de menas lateríticas expuestas a secado solar natural. *Minería y Geología*, 28(2), 30-46.
- Retirado, Y., & Legrá, A. (2012). Optimización del secado solar de la mena laterítica en la industria cubana del níquel. *Minería y Geología*, 28(2), 30-46.
- Roffel, B., & Betlem, B. (2006). *Process Dynamics and Control: Modeling for Control and Prediction* (1ra ed.). Chichester: John Wiley and Sons.
- Santos, M. (2011). Un Enfoque Aplicado del Control Inteligente. *RIAI*, 8, 283–296.
- Shariari, K., & Tarasiewicz, S. (2011). Modelling of a clinker rotary kiln using operating functions concept. *The Canadian Journal of Chemical Engineering*, 89(2), 345-359.
- Sheehan, E., Britton, F., & Schneider, A. (2005). A model for solids transport in flighted rotary dryers based on physical considerations. *Chemical Engineering Science*, 60(15), 4171-4182.
- Sjöberg, J. (1995). *Non-Linear System Identification with Neural Networks*. Ph. D. Thesis, Linköping University.
- Smith, C. A., & Corripio, A. (2006). *Principles and Practice of Automatic Process Control* (3ra ed.). New Jersey: John Wiley and Sons.

Bibliografía

- Spencer, R. (2009). *Identificación del proceso de enfriamiento del mineral en el proceso CARON, con ayuda de Redes Neuronales Artificiales*. Tesis de maestría, ISMM.
- Sutradhar, A., Sengupta, A., & Challa, R. (2010). *Identification of Servo-driven Inverted Pendulum System using Neural Network*. Annual IEEE India Conference, Department of Electrical Engineering, Bengal Engineering & Science University,.
- Tarhan, S., & Telci, I. (2010). Product quality and energy consumption when drying peppermint by rotary drum dryer. *Industrial Crops and Products*, 32(3), 420-477.
- Tavío, G. (1999). Optimización de la reducción de níquel en los hornos de reducción equipados con cámaras PRIOR. *XVI Conferencia de Química*. Santiago de Cuba.
- Torres, E. (2003). *Modelación matemática y simulación del transporte neumático del mineral laterítico*. Tesis doctoral, Instituto Superior Minero Metalúrgico de Moa "Dr. Antonio Núñez Jiménez", Moa.
- Torres, E., & Retirado, Y. (2007). Modelación matemática del transporte neumático del mineral laterítico en fase densa. *Minería y Geología*, 23(1), 1-31.
- Torres, G. (1999). *Modelación matemática para predecir el comportamiento del extractable de níquel en los Hornos de Reducción*. Tesis de Maestría, Universidad de Oriente, Control automático.
- Valverde, R. y. (2007). Identificación de sistemas dinámicos utilizando redes neuronales RBF. *RIAI*, 4(2), 32 - 42.

Anexos

Anexo 1. Perfi térmico típico del horno



Anexos

Anexo 2. Pantalla CICODE donde se generaron las señales de excitación

Experimento Valvula H6 y H7

Valvula Reg. H4		Test Valvula Reg. H4	Valvula Reg. H6		Test Valvula Reg. H6
Valor (%)	Tiempo(m)	Valor actual	Valor (%)	Tiempo(m)	Valor actual
40	4	51	15	4	40
54	1	Tiempo 1	57	1	INICIAR
37	2	PARAR	22	2	PARADO
21	1	INICIADO	39	1	REGISTRO
51	1		19	1	
22	2		50	2	
45	2		26	2	
69	5		16	5	
21	3		36	3	
61	2		24	2	
42	1		53	1	
68	3		29	3	
52	1		17	1	
68	1		39	1	
52	1		49	1	
63	1		20	1	
41	4		42	4	
20	1		34	1	
64	2		40	2	
35	1		40	1	
60	1		32	1	
36	2		48	2	
24	2		26	2	
67	5		16	5	
50	3		40	3	
65	2		23	2	
44	1		12	1	
26	3		29	3	
38	1		51	1	
55	1		38	1	