



## Modelación de la postcombustión en un horno de reducción de mineral para la producción de níquel

Deynier Montero Góngora <sup>1,4\*</sup> <https://orcid.org/0000-0003-0903-6635>

Rafael Arturo Trujillo Codorniú <sup>2</sup> <https://orcid.org/0000-0001-7449-1939>

Ángel Oscar Columbié Navarro <sup>3</sup> <https://orcid.org/0000-0003-4068-1472>

Reineris Montero Laurencio <sup>1</sup> <https://orcid.org/0000-0003-0898-5011>

<sup>1</sup> Centro de Estudios de Energía y Tecnología Avanzada de Moa, Facultad de Metalurgia Electromecánica, Universidad de Moa Dr. Antonio Núñez Jiménez. Holguín, Cuba

<sup>2</sup> Departamento de Control Automático, Facultad de Ingeniería Eléctrica, Universidad de Oriente. Santiago de Cuba, Cuba

<sup>3</sup> Departamento de Ingeniería Eléctrica, Facultad de Metalurgia Electromecánica, Universidad de Moa Dr. Antonio Núñez Jiménez. Holguín, Cuba

<sup>4</sup> Academia de Ciencias de Cuba. La Habana, Cuba

\* Autor para la correspondencia: [dmonterog150688@gmail.com](mailto:dmonterog150688@gmail.com)

### Editor

Lisset González Navarro  
Academia de Ciencias de Cuba.  
La Habana, Cuba

### Traductor

Darwin A. Arduengo García  
Academia de Ciencias de Cuba.  
La Habana, Cuba

### RESUMEN

**Introducción:** Los hornos de múltiples hogares son una etapa clave en el proceso de reducción de níquel. La implementación del sistema de control automático en la postcombustión del horno se ha visto afectado por la inexistencia de modelos matemáticos de este proceso. **Objetivos:** Obtener modelos lineales para diferentes puntos de operación y modelos no lineales basados en redes neuronales artificiales que reflejen las características dinámicas del proceso. **Métodos:** Realización de experimentos activos, con secuencias binarias pseudoaleatorias moduladas en amplitud y frecuencia e insertadas en el autómata que acciona las válvulas reguladoras de flujo de aire y variaciones en el flujo de mineral alimentado, para obtener los modelos lineales. Además, se registraron experimentos pasivos de 10 meses de operaciones para la obtención de modelos neuronales. El modelo neuronal de múltiples entradas-múltiples salidas se evaluó con diferente número de neuronas en la capa oculta y con el empleo del método de validación cruzada aleatoria, escogiéndose el mejor modelo a partir de los criterios de información de Akaike y Bayesiano. **Resultados:** El modelo neuronal predice las temperaturas de los hogares 4 y 6 del horno con un error inferior a 5 °C, y un horizonte de predicción de un paso adelante (120 s). **Conclusiones:** El modelo contribuye a predecir el perfil térmico en la zona de calentamiento del horno, como base para el diseño de estrategias de control que garanticen un mejor aprovechamiento de la energía y del combustible aditivo reductor, para disminuir las pérdidas del proceso y la contaminación ambiental.

**Palabras clave:** horno de reducción; postcombustión; modelo neuronal; validación cruzada aleatoria; criterios de información de Akaike y Bayesiano

# Modeling of post-combustion in an ore reduction furnace for nickel production

## ABSTRACT

**Introduction:** Multi-hearth furnaces are a key stage in the nickel reduction process. The implementation of the automatic control system in the furnace post-combustion has been affected by the lack of mathematical models of this process. **Objectives:** To obtain linear models for different operating points and non-linear models based on artificial neural networks that reflect the dynamic characteristics of the process. **Methods:** Carrying out active experiments, with pseudo-random binary sequences modulated in amplitude and frequency and inserted into the automaton that activates the air flow regulating valves and variations in the flow of mineral fed, to obtain linear models. In addition, they were recorded passive experiments of 10 months of operations to obtain neuronal models. It was evaluated the multiple-input-multiple-output neuronal model with different numbers of neurons in the hidden layer and with the use of the random cross-validation method, choosing the best model based on the Akaike and Bayesian information criteria. **Results:** The neural model predicts the temperatures of furnace hearths four and six with an error of less than 5°C, and a prediction horizon of one step ahead (120s). **Conclusions:** The model contributes to predicting the thermal profile in the heating zone of the furnace, as a basis for the design of control strategies that guarantee better use of energy and the reducing additive fuel, to reduce process losses and pollution environmental.

**Keywords:** reduction furnace; post-combustion; neural model; random cross validation; Akaike and Bayesian information criteria

## INTRODUCCIÓN

La industria metalúrgica desempeña un papel esencial en el desarrollo económico de un país, especialmente en Cuba. La metalurgia implica el procesamiento de metales, obteniendo así metal puro a partir de minerales metálicos. En este sentido, se insta a las empresas a incorporar la necesidad de protección ambiental y sostenibilidad en los esquemas.<sup>(1,2,3)</sup> Las empresas productoras de níquel en Cuba se caracterizan por procesos continuos que requieren una considerable automatización para lograr mayor eficiencia en sus producciones.

En el diagrama de flujo del proceso lixiviación carbonato amoniacal los hornos de múltiples hogares son una etapa clave en el proceso productivo. Estos hornos de reducción son cilindros metálicos en los que los óxidos superiores de hierro y el óxido de níquel se reducen al correspondiente estado metálico, para lo cual se debe mantener un adecuado perfil de temperatura en atmósfera reductora (monóxido de carbono e hidrógeno) en cada hogar.<sup>(4)</sup>

Para lograr el perfil de temperatura deseado el horno dispone de cámaras de combustión con quemadores de baja presión para la combustión incompleta del *fuel oil* que permite enriquecer la atmósfera reductora necesaria para la

reducción de los óxidos. Esta operación requiere un alto consumo de *fuel oil*, que representa un 40 % del costo unitario por tonelada producida de níquel más cobalto, por lo que resulta de vital importancia determinar vías que propicien la reducción de tales costos.

La Empresa Productora de Níquel y Cobalto Comandante Ernesto Che Guevara de Moa, donde se realiza la investigación, comenzó a producir en el año 1986 y se basó en la tecnología caron de la Empresa Comandante René Ramos Latour de Nicaro; donde los problemas de automatización de la postcombustión del horno estaban relacionados con el control de la temperatura en el hogar 4 (H4).

Para el control de la postcombustión se utilizan controladores PID (Proporcional-Integral-Derivativo) convencionales, ajustados por prueba y error que forman parte de los lazos de control individuales, donde se manipula el flujo de aire de un mismo conducto dividido en 2 ramas, que entran en conflicto. Por esta razón, normalmente el lazo de control del hogar 4 opera en modo automático, mientras que el del hogar 6 opera manual. Como consecuencia los procesos físico-químicos que tienen lugar en estos hogares no se llevan a cabo de manera eficiente, lo que provoca indeseadas fluctuaciones

de temperatura que influyen negativamente en el desarrollo de los procesos térmicos e hidrodinámicos dentro del horno.

Se plantea como objetivo general obtener modelos lineales para diferentes puntos de operación y modelos no lineales basados en redes neuronales artificiales que reflejen las características dinámicas del proceso.

## MÉTODOS

### Descripción del proceso de reducción de níquel en el horno

El proceso que se realiza en la Unidad Básica de Producción Planta Hornos de Reducción debe garantizar la reducción del óxido de níquel a níquel metálico, apto para la lixiviación amoniacal. Para ello la planta cuenta con 24 hornos tipo Herreshoff, compuestos por 17 hogares numerados de arriba hacia abajo desde el hogar 0 (H0) hasta el hogar 16 (H16), encerrados en un cilindro metálico de 23,5 m de alto y 6,78 m de diámetro, revestido interiormente por material refractario (figura 1). El mineral se introduce en el horno por el H0, tras

ser dosificado por un sistema de pesaje automatizado. Posteriormente, fluye a contracorriente con los gases reductores y, en su descenso, se seca, calienta y reduce.

La reducción se logra al establecer condiciones, determinadas por un perfil de temperatura y una concentración determinada de gases reductores ( $\text{CO} + \text{H}_2$ ). Para ello el horno dispone de 10 cámaras de combustión, ubicadas en los hogares (H6, H8, H10, H12, H15), equipadas con quemadores donde se realiza la oxidación incompleta del combustible (petróleo). Estas cámaras, además de generar calor, enriquecen la atmósfera reductora y en su interior ocurren reacciones que garantizan temperaturas de  $1350\text{ }^\circ\text{C}$ - $1450\text{ }^\circ\text{C}$ . El horno opera con una ligera presión positiva para evitar la entrada de aire que reoxide al mineral, que se logra al mantener determinada diferencia de presión entre H0 y H16. El tiempo de retención del mineral en el horno es aproximadamente 2700 s. <sup>(5)</sup>

Al considerar que las variables de interés para la identificación han de ser aquellas útiles para el control de las temperaturas del horno, el sistema se consideró como una caja negra cuyas variables son:

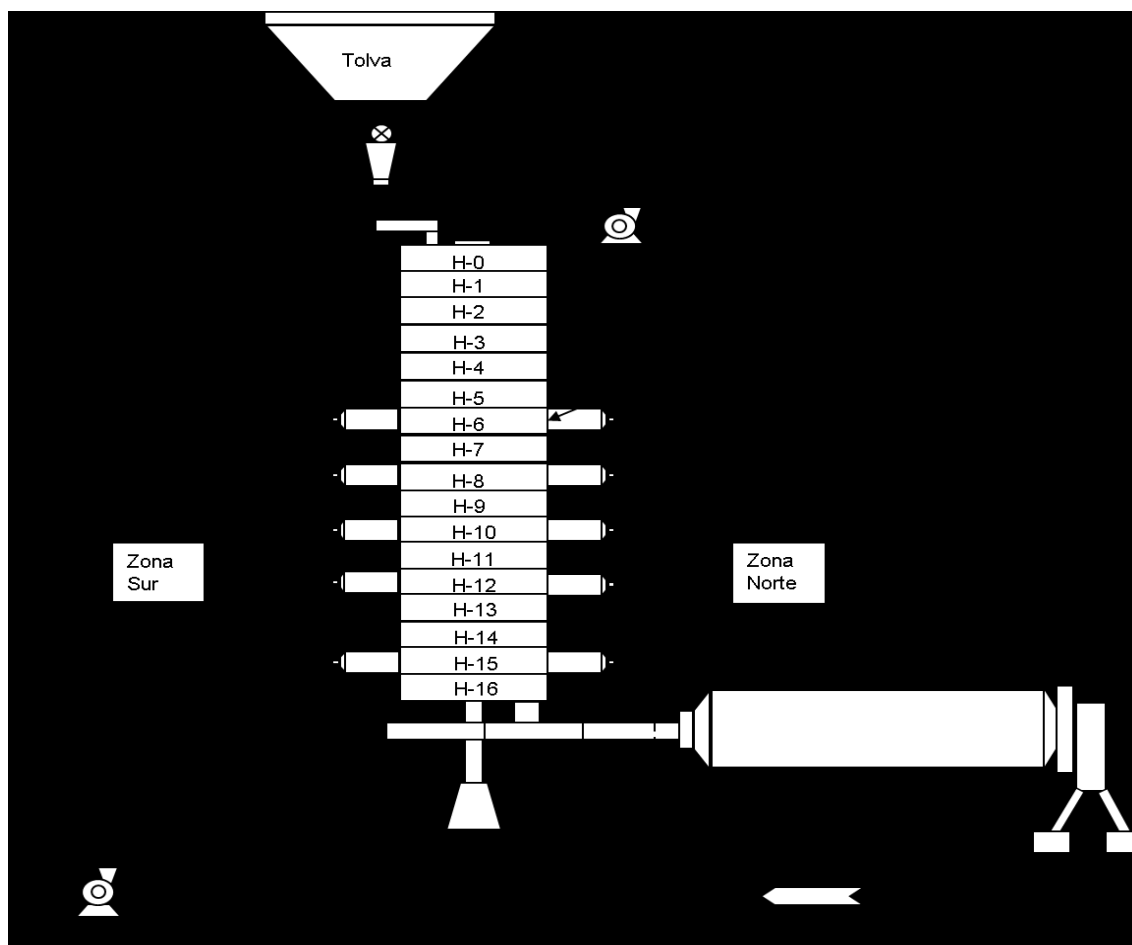


Fig.1. Diagrama de flujo del proceso de reducción en el horno. Fuente: Montero D. <sup>(5)</sup>

Variables de entrada:

- ApH4 apertura de la válvula reguladora de flujo de aire al hogar 4 (%),
- ApH6 apertura de la válvula reguladora de flujo de aire al hogar 6 (%).

Variables de salida:

- TH4 temperatura en el hogar 4 (°C),
- TH6 temperatura en el hogar 6 (°C).

Las principales perturbaciones que afectan a este proceso son:

- Fm, cambios en el flujo de mineral (t/h),
- Cm, composición química de los elementos Ni, Co, Fe, SiO<sub>2</sub>, MgO, S, C, alimentados al horno (%),
- Tm, temperatura del mineral (°C),
- Hm, humedad externa del mineral (%),
- Vcm, velocidad de calentamiento del mineral en la zona de postcombustión (°C/min),
- Fc, flujo de combustible suministrado a las cámaras de combustión (kg/t),
- Fg, flujo de gases (m<sup>3</sup>/h),
- Tg, temperatura de los gases (°C),
- Cqg (composición química de la mezcla de gases (%),
- Ta, temperatura ambiente (°C),
- Hra, humedad relativa del medioambiente (%),
- Ph, presión en el interior del horno (mm de H<sub>2</sub>O),
- Tas, temperatura del aire secundario inyectado en H4 y H6 (°C).

El flujo de mineral (Fm) es una variable de coordinación que depende del sistema de mayor envergadura (horno), que debe tener un valor prácticamente constante de 20 t/h, aunque las condiciones pueden variar y Fm ser una perturbación para el control del subproceso de postcombustión. <sup>(5)</sup> Las variables ApH4 y ApH6 son manipuladas directamente por válvulas, que son elementos de acción final en los lazos de control automático. Las otras variables como el perfil térmico de las cámaras y los restantes hogares no se consideran en la estructura de los modelos. <sup>(6)</sup>

Para la modelación del subproceso de postcombustión fueron utilizados los sistemas de supervisión y control (CI-TECT y EROS), que permitieron medir las variables de interés para el estudio y análisis del subproceso. El software MATLAB®, específicamente, The System Identification Toolbox, Artificial Neural Network "NNSYSD", y el módulo de Deep Learning 14.2; se emplearon para la obtención de los modelos lineales y no lineales del proceso. Las modelaciones se ejecutaron en una laptop Dell Latitude 5310 con procesador Intel (R) Core (TM) i5-10210U CPU a una frecuencia 1,60 GHz; 2,11 GHz y una memoria RAM de 8 GB.

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

## Modelos lineales del proceso

Para la obtención de los modelos lineales se siguieron los pasos del proceso de identificación por la vía experimental.

<sup>(7)</sup> Se llevaron a cabo experimentos previos con señal escalón para determinar las constantes de tiempo dominantes del subproceso de postcombustión, la presencia de no linealidades y los detalles de la construcción de las señales de excitación definitivas. Luego, se siguieron 4 etapas para la obtención de los modelos lineales:

- Diseño del experimento con señales de excitación. Se excitó el sistema con una señal de entrada diseñada expresamente con este fin y se registró la evolución de entradas y salidas durante un intervalo de tiempo.
- Elección de la estructura del modelo. Se probaron las estructuras de modelos discretos y para cada una se tomaron diferentes órdenes.
- Estimación de los parámetros del modelo. Se procedió a la estimación de los parámetros de la estructura que mejor ajustaba la respuesta del modelo a los datos de entrada-salida obtenidos experimentalmente.
- Validación del modelo. Se determinó si el modelo obtenido satisfacía el grado de exactitud requerido para la aplicación en cuestión. Ante un modelo no válido, se revisaba si el conjunto de datos representaba la dinámica del proceso, la estructura escogida era la adecuada o el criterio de ajuste de los parámetros era el más apropiado.

Se hizo un tratamiento previo de las variables TH4, TH6, ApH4, ApH6, Fm; que consistió en sustraer el valor medio de los datos y hacer que la media de los mismos fuera 0 a través del comando dtrend del programa MATLAB®, luego se seleccionó una parte de los datos para la estimación y otra en la validación.

## Modelos no lineales del proceso

Para obtener los modelos no lineales se emplearon datos históricos del horno, correspondientes a 10 meses (distribuidos en 3 meses de 2015, 4 meses de 2018, y 3 meses de 2022, con un período de muestreo de 120 s) con el objetivo de tener una idea de la variabilidad del proceso en diferentes períodos.

Se eliminaron los datos anómalos mediante el comando filloutliers del programa MATLAB®, que establece como anó-

malo un valor que se aleje de la media en más de 3 desviaciones estándar y lo reemplaza por un valor medio entre el valor anterior y posterior al anómalo. Luego con la función `mapminmax` se normalizaron los datos al rango [-1 1].

### Modelo no lineal autorregresivo con entrada externa de simple entrada-simple salida (NARX SIS0)

Se seleccionaron las variables del subproceso de postcombustión (ApH4, TH4, ApH6, TH6), que pertenecen a los 3 meses de 2015 para estimar 2 modelos NARX SIS0. Luego, este modelo fue validado con las mismas variables correspondientes a los 4 meses de 2018. <sup>(6)</sup> La selección adecuada del número de capas y las neuronas en cada capa tiene un efecto mayor en el rendimiento de la red que el efecto de la función de transferencia y entrenamiento. <sup>(8)</sup> En este estudio, el número de neuronas en la capa oculta se eligió por prueba y error.

En concreto, se tomó una arquitectura de red totalmente conectada con 3 regresores como entradas, función de activación tangente hiperbólica en la capa oculta y 1 neurona con función de activación lineal como salida. Se utilizó el algoritmo de entrenamiento Levenberg-Marquardt, que implica bajos errores de predicción en la etapa de entrenamiento y estos tienden a aumentar en la validación; por ello, la obtención de un buen modelo depende principalmente del comportamiento de los errores de predicción de estos nuevos datos. En este paso se prueba lo aprendido por la red. La red obtenida se valida primeramente para los datos de entrenamiento y luego para los de validación.

El *toolbox* de redes neuronales artificiales desarrollado por Nørgaard, proporciona 5 estructuras de modelos: NNARX "no lineal autorregresivo exógeno", NNOE "no lineal con error de salida", NNARMAX1 "no lineal con media móvil autorregresivo exógena (filtro de ruido lineal)", NNARMAX2 "no lineal con media móvil autorregresivo exógena", NNSSIF "no lineal en espacio de estado". <sup>(9)</sup> En este caso, se seleccionó el modelo NNARX porque la regla básica que ofrece el autor en el manual es utilizarlo siempre que sea posible, pues solo éste tiene un predictor sin realimentación; los otros tienen realimentación a través de los regresores que en la terminología de la red significa que la red se convierte en recurrente y, por consiguiente, puede conducir a la inestabilidad en ciertos rangos de operación.

El modelo NNARX utilizado se muestra en la figura 2, donde  $x(t)$  es la entrada,  $y(t)$  es la salida de la red un paso adelante. La estructura regresiva  $[n_a n_b n_k]$  fue 221, donde  $n_a$  es el número de salidas pasadas,  $n_b$  es el número de entradas pasadas, y  $n_k$  es el retardo de tiempo del sistema. Aunque se realizaron 30 pruebas, los mejores resultados se obtuvieron con esta estructura.

### Modelo no lineal autorregresivo con entrada externa de múltiples-entradas múltiples-salidas (NARX MIMO)

Fueron elegidas en este estudio 3 capas para el modelo NARX: capa de entrada, capa oculta y capa de salida (figura 3). En la capa de entrada hay 2 neuronas que representan las 2 variables de entrada (ApH4, ApH6). Se implementaron 5 retrasos en la capa oculta, de acuerdo con la identificación de las constantes de tiempo predominantes de 600 s para los 2 hogares de postcombustión y al considerar que los datos históricos se recolectan con 1 un período de muestreo de 120 s. El número de neuronas en la capa oculta fue variado de 1 hasta 30 con función de activación (tangente hiperbólica) y 2 neuronas con función de activación lineal en la capa de salida que representan a las variables de salida TH4 y TH6.

Los datos de entrada-salida correspondientes a los 3 meses de 2015 son presentados al modelo NARX en matriz  $2 \times 64\ 146$  cada uno, un sistema  $2 \times 2$ . El conjunto de datos se divide aleatoriamente en 3 partes: 70 % para entrenamiento, 15 % para validación y 15 % para prueba. El número de repeticiones escogido para la aplicación de esta técnica fue  $k = 16$ , lo que garantizó que la probabilidad de que 1 dato se escogiera al menos 1 vez en el conjunto de prueba fuera mayor que 0,9 y prácticamente el 95 %. Para cada división se entrenó el modelo y se promediaron los errores cuadráticos medios. De esta forma se obtuvo el error promedio ( $\overline{RMSE}$ ) para una cantidad específica de neuronas en la capa oculta. Luego este proceso se repitió con diferente número de neuronas en la capa oculta para seleccionar el modelo con mejores resultados. <sup>(10)</sup> La selección se hace a partir del modelo con menores valores del coeficiente de información de Akaike (AIC) y el coeficiente de información Bayesiano (BIC).

Para la generalización del modelo NARX MIMO se utilizó 1 conjunto de datos de años diferentes que no participó en el entrenamiento del modelo y se diseñó el experimento numérico al dividirlo en 20 subconjuntos, los 10 primeros abarcan 80 567 datos del 2018, y los restantes comprenden 65 313 datos del 2022. Los subconjuntos están conectados, temporalmente, uno tras otro. Luego se calculó el  $\overline{RMSE}$  para cada subconjunto a partir del modelo identificado con los datos del 2015. El horizonte de predicción empleado es de un paso adelante de 120 s. <sup>(10)</sup> Durante la experimentación pasiva, las perturbaciones descritas en la figura 1 pudieron haber tenido influencia en el desarrollo del subproceso de postcombustión. Sin embargo, al no poder controlarlas directamente, se tienen en cuenta durante la validación del modelo porque pasan a formar parte del  $\overline{RMSE}$ .

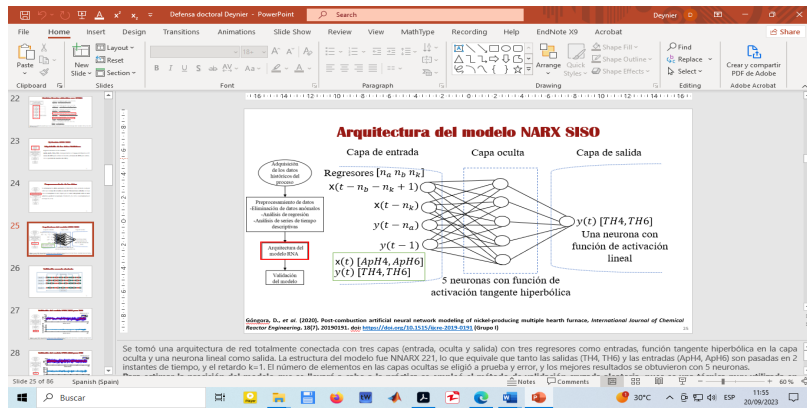


Fig. 2. Arquitectura de la red neuronal artificial. Fuente: Elaboración propia

## RESULTADOS Y DISCUSIÓN

Los modelos lineales en funciones de transferencia reflejaron el comportamiento del subproceso de postcombustión de forma adecuada, lo que constituye una premisa importante para el diseño de estrategias de control de elevado desempeño, donde es necesaria una fase de simulación. Con respecto a la validación de los modelos, se efectuaron análisis de residuos (errores de predicción) y correlación cruzada.

En la tabla 1 se muestra un resumen de los errores de predicción logrados con los modelos lineales identificados mediante las señales binarias pseudoaleatorias (SBPA) y señales binarias pseudoaleatorias de amplitud modulada (APRBS), y se evidencia que los modelos obtenidos con APRBS presentan mejor ajuste en relación con los modelos obtenidos mediante SBPA, por lo que su comportamiento resulta representativo a la dinámica del sistema. A su vez, estos resultados están en el rango del error cuadrático medio (RMSE) logrado con modelos lineales aplicados a un proceso de reducción de níquel, similar al objeto de estudio. <sup>(11)</sup>

Los resultados del modelo NARX SISO muestran errores de predicción para TH4 de 6,13 °C y 8,12 °C para TH6, con

5 neuronas y función de activación tangente hiperbólica en la capa oculta. <sup>(6)</sup> El resultado del proceso de prueba y error con el modelo NARX MIMO se muestra en la tabla 2. Al comparar los valores de AIC y BIC, el BIC de 28 936,7 sugiere un modelo con 41 parámetros y 3 neuronas en la capa oculta, más sencillo que el modelo sugerido por el AIC de 27 879,7 con 340 parámetros y 26 neuronas en la capa oculta.

Además, el modelo sugerido por BIC, aunque con menos parámetros del modelo, posee una capacidad predictiva ( $\overline{RMSE} = 4,7 \text{ °C}$ ) con un coeficiente de variación ( $CV = 3,8 \%$ ), que es aproximada a la del modelo basado en AIC ( $\overline{RMSE} = 4,5 \text{ °C}$ ,  $CV = 3,5 \%$ ). Esto resulta de vital importancia para lograr una representación parsimoniosa de sistemas no lineales complejos en muchas situaciones de aplicación, porque un modelo con menos parámetros puede reducir en gran medida el trabajo de recopilación de datos y beneficiar el proceso de comprensión de los sistemas.

Se constata que el modelo NARX tiene éxito para capturar el modelo dinámico del sistema, pues se logran errores de predicción inferiores a 5 °C, y se consideran bajos en comparación con el rango de temperatura (superiores a 900 °C)

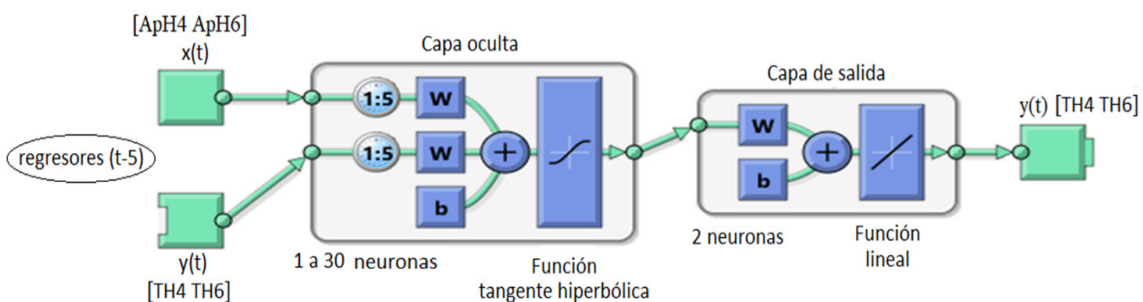


Fig. 3. Modelo NARX para el subproceso de postcombustión del horno. Fuente: Montero D *et al.* <sup>(10)</sup>

**Tabla 1.** Ajuste comparativo de los modelos lineales

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

Fuente: Elaboración propia

de los termopares instalados en H4 y H6 del horno. <sup>(10)</sup> Estos resultados están en el rango de los errores obtenidos para la modelación del perfil térmico de un horno de reducción de níquel con características diferentes al objeto de estudio de esta investigación. <sup>(12)</sup> Los resultados de la generalización del modelo identificado con datos de 2015, adaptado a 2 años diferentes, corresponden a un  $\overline{RMSE}$  de la serie temporal del 2018 de 8,1 °C, y 14,4 °C para el 2022, ambos con valores de regresión cercanos a 1.

Los errores de generalización son superiores al error del modelo identificado del 2015 (5°C) porque las condiciones de operación del horno pudieron haber variado, sin embargo, el modelo puede readecuarse a esos nuevos datos, a partir de una actualización de los pesos de la red con determinada frecuencia. En el caso de los subconjuntos 3 y 4 del 2022, el error aumentó considerablemente porque se produjo la parada de la empresa debido a la contingencia energética del país. Se demuestra que la solución final de identificación requiere un aprendizaje en línea con realimentación en tiempo real, además de alargar el tiempo de eficacia de los coeficientes identificados con el modelo NARX. <sup>(10)</sup>

Se sugiere al personal de la industria que monitoree el RMSE con el modelo identificado en línea, como un dato más

de operación y como señalizador para la entrada en tiempo real del control en los subconjuntos temporales. Pues en los intervalos de tiempo donde el error es bajo podrían tornarse una especie de patrón para la Unidad Básica de Producción Planta Hornos de Reducción, e invitarían a muchos investigadores a proponer esquemas de control en tiempo real. <sup>(10)</sup>

La actualidad del trabajo está sustentada en el interés del estado cubano y de su Ministerio de Energía y Minas en

**Tabla 2.** Comportamiento del modelo NARX MIMO para diferentes neuronas

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

Fuente: Elaboración propia

que las plantas que utilizan la tecnología caron optimicen el consumo de combustible para elevar su competencia internacional. Se refleja el uso, relativamente reciente, de las redes neuronales artificiales para la modelación matemática de procesos tecnológicos complejos como base de sus automatizaciones y búsquedas de eficacia y eficiencia. <sup>(6,10)</sup>

Los modelos matemáticos propuestos tienen los siguientes impactos científicos: modelos lineales en funciones de transferencia, que no requieren avanzados recursos computacionales, abarcan diferentes puntos de operación del proceso y pueden ser empleados en estrategias de control multivariable que se insertan en los controladores lógicos programables (PLC) de la empresa. Modelo NARX SISO, que refleja las características dinámicas de la postcombustión con mayor exactitud, aunque requieren una mayor potencia de cálculo, disponible ya en algunos PLC de la empresa.

Modelo NARX MIMO, que incluye la descripción del modelo NARX SISO, y que presenta ventajas, tales como: la estructura es MIMO a diferencia de los modelos previos SISO, lo que permite estimar el comportamiento multivariable de la postcombustión. <sup>(6,13)</sup> Permite readecuarse a diferentes condiciones de operación si se realizan actualizaciones de los pesos de la red neuronal con determinada frecuencia. Permite capturar la no linealidad inherente del proceso.

### Impacto económico

El control adecuado de la postcombustión tiene un efecto económico apreciable, pues se logra mayor eficiencia del proceso que se desarrolla en los hornos de reducción. El máximo aprovechamiento del potencial energético de los elementos reductores (CO, H<sub>2</sub>) que no han participado en el proceso de reducción, evita la expulsión al medio ambiente de considerables cantidades de calor y disminuye las pérdidas de mineral en forma de polvo, contenido en los gases de escape de los hornos. El control automático de la postcombustión a partir de los modelos matemáticos identificados podría reducir las pérdidas de calor que se producen en los gases de salida. De esta forma, se ahorrarían aproximadamente  $95, \frac{t_c}{\text{año}}$  que equivale a 111 406,8 USD anualmente, con posibilidades de que se eleve a 2 673 763,2 USD para los 24 hornos de la Unidad Básica de Producción Planta Hornos de Reducción.

### Impacto social

La inserción del modelo matemático dinámico en una estrategia de control para el subproceso de postcombustión del horno de reducción la Empresa Productora de Níquel y Cobalto Comandante Ernesto Che Guevara, disminuirá el consumo de combustible y las emisiones de gases y polvos a la atmósfera,

proporcionará una buena predicción de las variables de salida operacionales ante diferentes situaciones, y permitirá operar la instalación sin la necesidad de estar expuestos a las altas temperaturas, ruido y polvo excesivo. Al incrementar la calidad de la producción con el menor costo posible, garantizará mayores importaciones al país, lo que facilitará la adquisición de productos de primera necesidad, como alimentos y combustibles.

### Impacto ambiental

En aras de contribuir con el programa de desarrollo y perfeccionamiento de la industria cubana del níquel se deben introducir nuevas tecnologías para la disminución de las agresiones al ecosistema, y ofrecer resultados superiores para la sociedad y la economía, en comparación con las tradicionalmente usadas hasta el momento. La automatización del subproceso de postcombustión a través de un modelo matemático de la planta, debe contribuir en alguna medida a la disminución de la degradación y el deterioro del ecosistema.

Las emisiones gaseosas y de polvo guardan una estrecha relación con la postcombustión. Si se logra un control efectivo de la misma se deben reducir al máximo las emisiones por alta concentración de monóxido de carbono en los gases de escape, equivalente a no expulsar a la atmósfera un mínimo de 400 toneladas de polvo anuales y se reduce considerablemente la cantidad de gases nocivos. De esta forma, disminuiría la propagación de enfermedades respiratorias en la población de Moa.

### Conclusiones

El modelo NARX MIMO sugerido por BIC, de 3 neuronas en la capa oculta, capturó el comportamiento dinámico de la postcombustión con una predicción de error de 4,7 °C y una generalización de 11 °C. El modelo neuronal identificado puede utilizarse para el diseño de estrategias de control, en aras de aumentar la eficacia y la eficiencia del proceso, y sirve de referencia para otras investigaciones en el procesamiento de reducción de minerales lateríticos, especialmente para el control del perfil térmico. La implementación del modelo posibilitaría la disminución del consumo de portadores energéticos con un ahorro de 95 toneladas de combustible anuales y evitaría la expulsión al ecosistema de unas 400 t/año de polvo y gases nocivos.

### REFERENCIAS BIBLIOGRÁFICAS

1. Fraser ED, Dougill AJ, Mabee WE, et al. Bottom up and top down: Analysis of participatory processes for sustainability indicator identification as a pathway to community empowerment and sustainable environmental management. *Journal of Environmental Management* [Internet]. 2006 ene [citado 14 abr 2023];78(2):114-27. Disponible en: <https://www.sciencedirect.com/science/article/abs/pii/S0301479705001659>



2. Reed MS, Stringer LC, Fazey I, *et al.* Five principles for the practice of knowledge exchange in environmental management. *Journal of Environmental Management* [Internet]. 2014 dic [citado 15 feb 2024];146:337-45. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/25194520/>
3. Tseng SC, Hung SW. A strategic decision-making model considering the social costs of carbon dioxide emissions for sustainable supply chain management. *Journal of Environmental Management* [Internet]. 2014 ene [citado 10 feb 2024];133:315-22. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/24412595/>
4. Castellanos J, Castillo CR, García I. Elaboración de minerales oxidados de níquel por el esquema carbonato amoniacal. *Minería Y Geología* [Internet]. 1986 jul [citado 11 nov 2023];4(2):77-91. Disponible en: <https://revista.ismm.edu.cu/index.php/revistamg/article/view/394/1169>
5. Montero D. Modelación matemática del subproceso de post-combustión en un horno de reducción de minerales lateríticos [tesis doctorado en Internet]. Moa, Cuba: Centro de Estudios de Energía y Tecnología Avanzada de Moa; 2023 [18 sep 2023].130. Disponible en: <https://ninive.ismm.edu.cu/bitstream/handle/123456789/4098/MonteroGongoraM2023.pdf?sequence=1&isAllowed=yURL>
6. Góngora D, Caneghem JV, Haeseldonckx D, *et al.* Post-combustion artificial neural network modeling of nickel-producing multiple hearth furnace. *International Journal of Chemical Reactor Engineering* [Internet]. 2020 jul [citado 13 oct 2023];18(7):1-14. Disponible en: <https://www.degruyter.com/document/doi/10.1515/ijcre-2019-0191/html>
7. Ljung L. System identification [Internet]. *Signal Analysis and Prediction. Applied and Numerical Harmonic Analysis.* Boston, MA: Birkhäuser Boston; 1998 [citado 12 oct 2023].163-73. Disponible en: [https://doi.org/10.1007/978-1-4612-1768-8\\_11](https://doi.org/10.1007/978-1-4612-1768-8_11)
8. Benardos PG, Vosniakos GC. Optimizing Feedforward Artificial Neural Network Architecture. *Engineering Applications of Artificial Intelligence* [Internet]. 2007 abr [citado 12 mar 2024];20(3):365-82. Disponible en: <https://www.sciencedirect.com/science/article/abs/pii/S0952197606001072>
9. Nørgaard M. Neural Network Based System Identification Toolbox [Internet]. Version 2, Technical Report. Denmark: Department of Automation, Technical University of Denmark; 2000 ene [citado 15 ene 2024].1-32. Disponible en: [http://matlab.fei.tuke.sk/raui-new/subory/nnsysid\\_manual1.pdf](http://matlab.fei.tuke.sk/raui-new/subory/nnsysid_manual1.pdf)
10. Montero D, Columbié Á, Montero R, *et al.* Modelo NARX de la postcombustión en un horno de reducción de mineral laterítico. *RIELAC* [Internet]. 2022 sept-dic [citado 8 sept 2023];43(3):1-14. Disponible en: [http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S1815-59282022000300015](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1815-59282022000300015)
11. Ramírez M. Identificación experimental del subproceso de post-combustión en un horno de reducción de níquel. *Minería Y Geología* [Internet]. 2001 may [citado 7 jun 2023];18(2):61-6. Disponible en: <https://revista.ismm.edu.cu/index.php/revistamg/article/view/207/194>
12. Purnomo LA, Biyanto TR. Advanced Industrial Technology in Engineering Physics AIP Conf. Proc. Neural network model for profile temperature of nickel kiln [Internet]. Surabaya: AIP Publishing; 2019 [citado 7 jul 2023] 020015-1-020015-7. Disponible en: <https://doi.org/10.1063/1.5095267>
13. Montero D, Ramírez M, Gilbert A, *et al.* Modelación matemática para el control de la postcombustión en un horno de reducción de níquel. *RIELAC* [Internet]. 2015 sept-dic [citado 10 mar 2024];XXXVI(3):21-34. Disponible en: <http://scielo.sld.cu/pdf/eac/v36n3/eac03315.pdf>

Recibido: 14/03/2024

Aprobado: 23/09/2024

**Conflictos de intereses**

Ninguno de los autores manifestó la existencia de posibles conflictos de intereses que debieran ser declarados en relación con este artículo.

**Contribuciones de los autores**

Conceptualización: Rafael Trujillo Codorníu

Curación de datos: Rafael Trujillo Codorníu

Análisis formal: Deynier Montero Góngora, Rafael Trujillo Codorníu, Reineris Montero Laurencio

Adquisición de fondos: Ángel Oscar Columbié Navarro

Investigación: Deynier Montero Góngora

Metodologías: Deynier Montero Góngora, Rafael Trujillo Codorníu

Administración de proyecto: Ángel Oscar Columbié Navarro, Reineris Montero Laurencio

Recursos: Reineris Montero Laurencio

Software: Deynier Montero Góngora, Rafael Trujillo Codorníu

Supervisión: Rafael Trujillo Codorníu

Validación: Deynier Montero Góngora

Visualización: Deynier Montero Góngora, Rafael Trujillo Codorníu

Redacción-borrador original: Deynier Montero Góngora

Redacción-revisión y edición: Deynier Montero Góngora, Rafael Trujillo Codorníu, Ángel Oscar Columbié Navarro, Reineris Montero Laurencio

**Financiamientos**

Las fuentes de financiamientos fueron 2 proyectos desarrollados, reducción del consumo de energía eléctrica en la Planta de Hornos de Reducción de la Empresa Productora de Níquel y Cobalto Comandante Ernesto Che Guevara en Moa, Proyecto asociado a programa nacional (PAP-1512), en coordinación con la Universidad de Camagüey y la Universidad de Moa. Diciembre/2015-2018; diagnóstico tecnológico, energético y organizacional a la Planta Hornos de Reducción, investigación aplicada. Proyecto Empresarial Universidad de Moa-Empresa Productora de Níquel y Cobalto Comandante Ernesto Che Guevara (05-06/2021).

**Cómo citar este artículo**

Montero Góngora Deynier, Trujillo Codorníu RA, Columbié Navarro AO, Montero Laurencio R. Modelación de la postcombustión en un horno de reducción de mineral para la producción de níquel. *An Acad Cienc Cuba* [internet] 2024 [citado en día, mes y año];14(3):e1548. Disponible en: <http://www.revistaccuba.cu/index.php/revacc/article/view/1548>

El artículo se difunde en acceso abierto según los términos de una licencia Creative Commons de Atribución/Reconocimiento-NoComercial 4.0 Internacional (CC BY-NC-SA 4.0), que le atribuye la libertad de copiar, compartir, distribuir, exhibir o implementar sin permiso, salvo con las siguientes condiciones: reconocer a sus autores (atribución), indicar los cambios que haya realizado y no usar el material con fines comerciales (no comercial).

© Los autores, 2024.

