

ESTIMACIÓN DEL CONSUMO ENERGÉTICO EN EL HORNO DE ARCO ELÉCTRICO

Ana González Marcos

Universidad de La Rioja

Manuel Castejón Limas

Universidad de León

Alpha V. Pernía Espinoza

Carmen Bao Iturbe

Rubén Escribano

Grupo EDMANS (<http://www.mineriadatos.com>). Universidad de La Rioja.

Abstract

Steel production in the electric arc furnace (EAF) requires an amount of energy which depends on the scrap mix, the type of product, the final temperature, the type and amount of slag, as well as other factors. An inadequate operation of EAF (long stops, frequent openings of the roof, etc.) could increase the energy consumption and thus, increment production costs. Preparing a model of electric energy demand will enable the optimisation of the electric energy consumption. This paper presents the use of techniques and data mining tools for the modelling of electric energy consumption. The results illustrate the advantages of using these techniques against some of the classic models proposed in literature.

Keywords: *EAF, energy consumption, data mining*

Resumen

Para producir acero en el horno de arco eléctrico (EAF) es necesaria la aportación de una determinada cantidad de energía, la cual depende del tipo de carga metálica, del tipo de producto, de la temperatura final, del tipo y cantidad de escoria, así como de otros factores. Una operación inadecuada del EAF, con elevados tiempos de paradas, frecuentes aperturas de la bóveda, etc., aumenta el consumo de energía por tonelada, lo que implica un incremento en los costes de producción. Un primer paso para lograr una optimización del consumo de energía eléctrica consiste en la obtención de un modelo de demanda energética. En este trabajo se presenta la utilización de técnicas y herramientas de minería de datos para el modelado del consumo energético. Los resultados obtenidos muestran las ventajas del empleo de estas técnicas frente a algunos de los modelos clásicos propuestos en la literatura.

Palabras clave: *EAF, consumo energético, minería de datos*

1. Introducción

El sector siderúrgico, a pesar de ser una actividad tradicional y madura, se caracteriza por realizar importantes esfuerzos en el campo de las nuevas tecnologías de fabricación y de mejora de calidad de sus productos. Aunque en la industria del acero es muy común el uso de técnicas clásicas para desarrollar modelos matemáticos que expliquen el comportamiento de un producto o proceso, es cada vez más habitual el empleo de técnicas de minería de datos para obtener un mayor conocimiento de los procesos de fabricación, así como desarrollar estrategias con las que disminuir costes, mejorar la calidad del producto y aumentar la producción.

El incremento en el uso de este tipo de técnicas es debido a la concurrencia de varios factores. Por un lado, los procesos industriales actuales han experimentado un rápido crecimiento en su capacidad para almacenar datos, lo que supone que día a día se disponga de mayor información acerca de dichos procesos productivos en forma de históricos. Es cierto que la información reduce la incertidumbre y, por tanto, permite tomar mejores decisiones. Sin embargo, al aumentar la cantidad de datos almacenados, la capacidad para asimilarlos disminuye, por lo que se hace necesario el uso de herramientas que permitan extraer conocimiento útil a partir de grandes conjuntos de datos.

Por otro lado, el hecho de que en la mayoría de los procesos industriales, las relaciones entre variables sean no lineales, y la dificultad derivada de obtener modelos explícitos que definan su comportamiento, hace que se piense en recurrir a modelos basados en datos frente a otros modelos analíticos basados en ecuaciones explícitas. Hoy en día, el modelado no lineal cuenta con importantes técnicas que han alcanzado gran aplicabilidad gracias al creciente desarrollo de los procesadores.

En este trabajo se presentan las actividades desarrolladas por el grupo EDMANS (*Engineering Data Mining And Numerical Simulations*)¹ en el seno de un horno de arco eléctrico (EAF) de un fabricante europeo de acero, ya que lejos de ser una excepción, el principal objetivo de este proceso es la obtención de acero líquido a partir de chatarra, de la forma más rápida y barata posible. La fabricación de acero en el EAF se basa en la fusión de chatarra mediante fuentes de energía eléctrica y químicas, y el ajuste de la composición química para obtener el grado de acero deseado. En los hornos modernos, la energía eléctrica se transfiere al acero en forma de arco eléctrico a través de tres electrodos. La contribución química proviene de las reacciones de combustión que tienen lugar en el horno. Dado que la energía eléctrica es uno de los factores con mayor peso en los costes de producción, una optimización del uso de energía, supondrá una reducción en dichos costes. Un primer paso para lograr una optimización del consumo de energía eléctrica consiste en la obtención de un modelo de demanda energética. En este trabajo se presenta la utilización de técnicas y herramientas de minería de datos para el modelado del consumo energético. Los resultados obtenidos muestran las ventajas del empleo de estas técnicas frente a algunos de los modelos clásicos propuestos en la literatura.

El resto del documento está organizado de la siguiente manera: en la sección 2 se describe brevemente el proceso de operación del horno de arco eléctrico; las herramientas empleadas y los resultados obtenidos se detallan en la sección 3; este trabajo finaliza con las conclusiones presentadas en la sección 4.

¹ <http://www.mineriadatos.com>

2. Descripción del proceso

En la operación del horno de arco eléctrico pueden distinguirse las siguientes etapas: carga, precalentamiento, fusión y vaciado (*tapping*).

El proceso se inicia con la carga del horno, formada por las chatarras –conjunto de piezas, partes metálicas, etc., de acero, inservibles y sin ninguna utilidad– y los aditivos formadores de escoria (principalmente cal). Normalmente se cargan dos o tres cestas de chatarra por colada, en función de la densidad de la chatarra utilizada y el volumen del horno.

Durante el precalentamiento tiene lugar la combustión del gas natural para elevar la temperatura del acero, tras lo cual, se bajan los electrodos del horno y se conecta la corriente para fundir los materiales cargados.

El programa eléctrico de fusión se establece con idea de optimizar la aportación de energía eléctrica en ese periodo y evitar los problemas derivados del ataque del arco al horno, teniendo en cuenta que:

- En los momentos iniciales, al estar fría la chatarra y estar llena toda la cuba del horno, si se iniciase la fusión con una tensión elevada y un arco largo, el arco eléctrico sería inestable. Además, al ser el arco largo y no estar los electrodos introducidos en la chatarra, la bóveda soportaría una radiación importante. Por todo ello, la fusión se inicia con una tensión no muy alta y con arco corto.
- En el periodo inicial los electrodos han abierto un agujero central en la carga y sus puntas están rodeadas de chatarra, por lo que la bóveda y las paredes se encuentran protegidas de la radiación del arco. En estas condiciones se pueden emplear altas tensiones y arco largo para aportar altas potencias y fundir rápidamente. La utilización de un arco largo da lugar a la creación de un cráter mayor alrededor de los electrodos, por lo que se facilita una fusión más rápida y homogénea, al mismo tiempo que se disminuye el riesgo de rotura de electrodos por la caída de chatarra.
- En ocasiones, cuando la chatarra va fundiéndose y descendiendo, se desprotege la cuba del horno, por lo que conviene bajar la potencia eléctrica, pasando a tensiones más bajas y un arco más corto.

En esta etapa también se usan la inyección de oxígeno y los quemadores auxiliares para acelerar la fusión, así como ayudar a fundir la chatarra situada en los puntos fríos, para lograr una fusión más uniforme .

Cuando la carga se ha fundido y el acero se encuentra en estado líquido, la inyección de oxígeno en el acero favorece la oxidación –cuyas reacciones también sirven como fuente de energía– y permite eliminar o reducir al máximo los elementos indeseables del baño (Silicio, Manganeso, Fósforo, etc.), formando óxidos que pasan a la escoria y quemando el Carbono que se elimina de forma gaseosa (CO y CO₂).

Tras el aporte de una cierta cantidad de energía, se miden la temperatura del baño y la composición química, con objeto de determinar si es necesario, o no, realizar algún otro tipo de adición para alcanzar las especificaciones finales deseadas. Una vez obtenidos la composición química y temperatura finales, se vuelca el contenido del horno en una cuchara para transportar el acero a la siguiente operación.

3. Desarrollo del modelo

La generación de un buen modelo parte de que la base de datos analizada contenga observaciones completas y válidas de forma que sea posible determinar las características

esenciales de los datos y, por tanto, realizar predicciones acertadas. Para ello, como etapa previa al modelado de los datos, se lleva a cabo un análisis y depuración previos.

Tras este tratamiento inicial, se obtuvo una base de datos con 1915 muestras correctas. Con ellas se trató de obtener un estimador del consumo energético en el EAF. El modelo propuesto tiene 16 variables de entrada: composición de la mezcla de chatarra y elementos de adición, oxígeno y gas aportados, duraciones del proceso y temperatura medida.

En primer lugar, se realizó el ajuste de un modelo de consumo de energía eléctrica mediante el empleo de técnicas clásicas: modelos lineales. En este caso, la base de datos se dividió en dos conjuntos de patrones: entrenamiento (75% de las muestras) y test (25% restante). La Figura 1, en la que se representa gráficamente la predicción del consumo energético con los patrones de test –los no vistos por el modelo durante su ajuste–, muestra que el modelo lineal realiza predicciones bastante buenas. Además, los gráficos de residuos representados en la misma figura, permiten evaluar la normalidad de los residuos y determinar si existe una estructura interna remanente que el modelo no es capaz de explicar: a la vista de los resultados, se puede considerar que los residuos siguen una distribución normal y, por tanto, verifican la bondad del ajuste realizado.

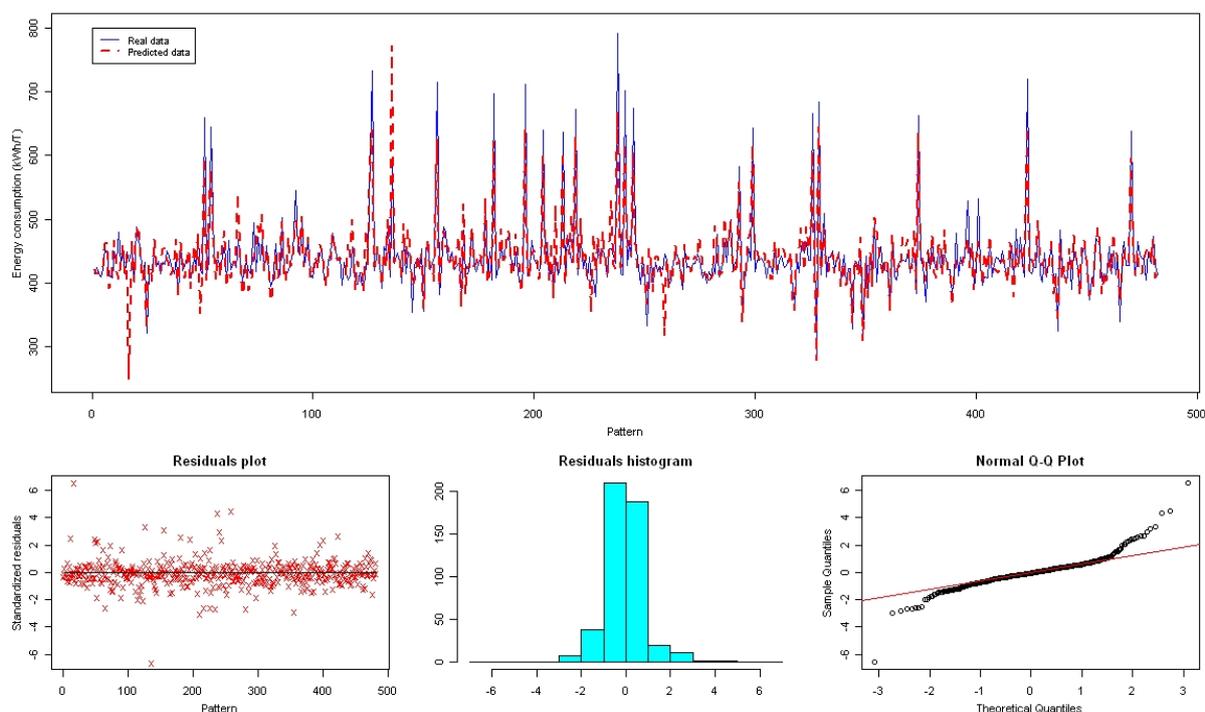


Figura 1. Resultados de test del modelo lineal de consumo de energía eléctrica (kWh/T).

El siguiente paso consistió en utilizar una forma de regresión mucho más general para estimar el consumo de energía eléctrica: las redes neuronales.

De entre todas las arquitecturas de redes neuronales existentes en la actualidad, una de las más adecuadas para la determinación de modelos de procesos, empleando datos de entrada y salida del mismo, es la llamada red perceptrón multicapa (*multilayer perceptron*, MLP), por ser considerada un aproximador universal de funciones (Funahashi, 1989; Hornik *et al*, 1989). Más concretamente, una red MLP conteniendo al menos una capa oculta con suficientes unidades no lineales, puede aprender cualquier tipo de función o relación continua entre un grupo de variables de entrada y salida.

De esta forma, se entrenó un conjunto de redes perceptrón multicapa con dieciséis entradas, un número variable de neuronas en la capa oculta (entre 18 y 30) y una salida. Para el aprendizaje se utilizaron dos algoritmos robustos propuestos por Liano (1996) y Pernía Espinoza *et al* (2005). Además, con objeto de obtener la mejor generalización posible, se utilizó el criterio de parada temprana (*early stopping*), dividiendo la base de datos en tres conjuntos de patrones: entrenamiento (55% de las muestras), validación (20% de los datos disponibles) y test (25% restante). Con los patrones de entrenamiento se realiza el ajuste de los pesos de las neuronas, mientras que los de validación son utilizados para comprobar, cada cierto número de ciclos de entrenamiento, que el error obtenido con los patrones de entrenamiento es coherente con el error que vería la red neuronal frente a nuevos datos que no hubieran participado en el ajuste. Cuando este error de validación se minimiza, el entrenamiento de la red finaliza. Por último, los patrones de test, que no han sido vistos nunca por la red entrenada, sirven para comprobar la capacidad de generalización de la misma.

Tras entrenar todas las configuraciones diseñadas, su comportamiento con los patrones de test se utilizó como indicador para seleccionar la mejor red neuronal. De todas las redes entrenadas, las mejores ofrecieron resultados bastante buenos (Figura 2), siendo los errores medios relativos de los patrones de test, no superiores al 3%.

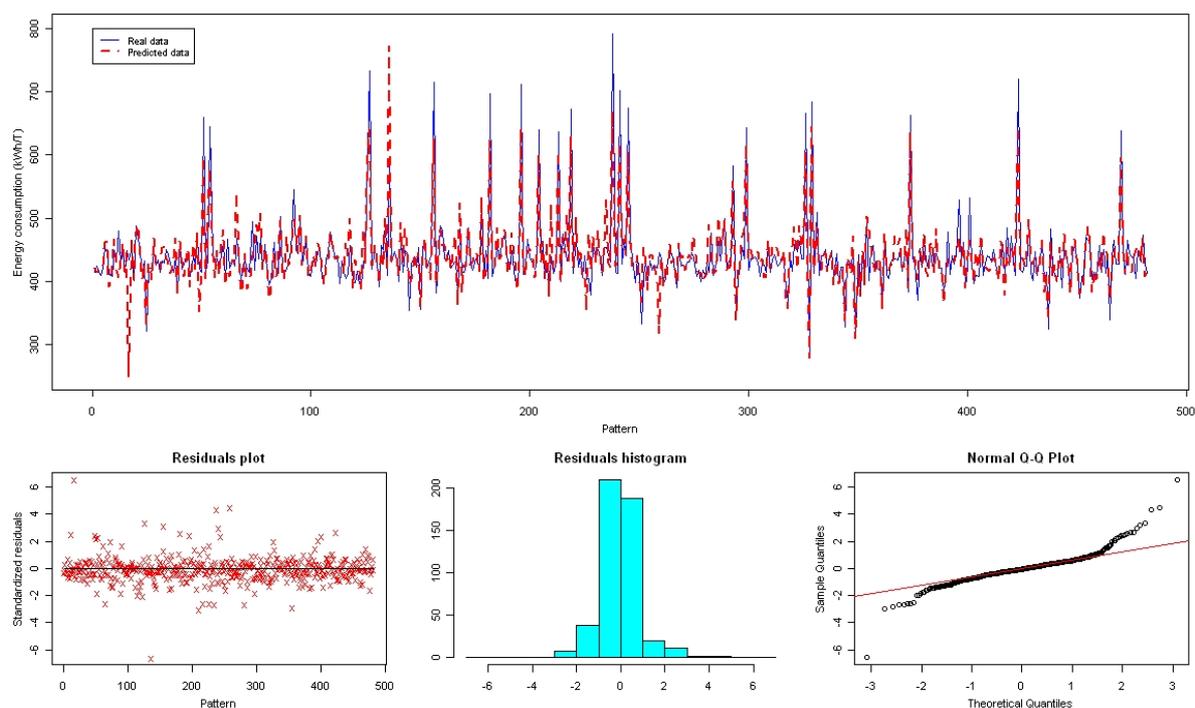


Figura 2. Resultados de test de la mejor red neuronal entrenada para predecir el consumo de energía eléctrica (kWh/T).

En la tabla 1, donde se muestran los errores de test de los modelos entrenados, se observa que las redes neuronales son capaces de ajustar mejor el consumo de energía eléctrica en el EAF. A continuación se detallan los parámetros incluidos en dicha tabla:

- Los errores mínimo y máximo muestran el rango en el que se mueven los errores de predicción de los modelos.
- Error medio. Es el valor medio de los errores de predicción.

- Desviación típica. Es una medida de la dispersión de los errores y determina la variabilidad de los mismos frente a la media. Si el valor es pequeño, los errores están próximos a la media y, si es grande, están separados de ella.
- Error medio relativo (%). Valor medio, en tanto por ciento, de los errores relativos de predicción.

Parámetro	Modelo lineal	Red neuronal
Error mínimo	-185	-122.17
Error máximo	183.9	106.06
Error medio	-0.67	-0.05
Desviación típica	27.58	19.19
Error medio relativo (%)	3.94	2.78

Tabla 1. Errores de test de los modelos entrenados.

2.1 Comparación con otros modelos

En esta sección, se compara el comportamiento de los modelos previos con el desarrollado por Köhle (2002):

$$W_R = 300 + 900 \cdot \left[\frac{G_E}{G_A} - 1 \right] + 1600 \cdot \frac{G_Z}{G_A} + 0.7 \cdot [T_A - 1600] + 0.85 \cdot (t_S + t_N) - 4.3 \cdot M_L - 8 \cdot M_G - 2.8 \cdot M_{O_2} + 80 \cdot \frac{G_{DRI/HBI}}{G_A} - 300 \cdot \frac{G_{HM}}{G_A} - 15 \cdot CON$$

donde:

- G_E – peso total de la carga metálica (T)
- G_A – peso esperado del baño metálico (T)
- G_Z – peso de la escoria (T)
- T_A – temperatura final (°C)
- t_S – tiempo de consumo energético (min)
- t_N – duración total del proceso (tap to tap) (min)
- M_L – oxígeno inyectado (m³/T)
- M_G – gas natural utilizado (m³/T)
- M_{O_2} – oxígeno empleado para oxidar el Carbono (m³/T)
- $G_{DRI/HBI}$ – peso del hierro de reducción directa (DRI) y del hierro briquetado en caliente (HBI) (T)
- G_{HM} – peso del metal líquido remanente (T)
- CON – información acerca de si la colada es una continuación o una colada inicial

Para poder realizar una comparación más precisa entre ambos modelos, los patrones de test fueron seleccionados de tal modo que coincidiesen con los utilizados por los modelos previos. En la Figura 3 se presentan las predicciones obtenidas con la ecuación de Köhle:

este modelo no es capaz de predecir el consumo de energía eléctrica adecuadamente. La Tabla 2 muestra los mayores errores de test que los obtenidos, por ejemplo, con el modelo lineal entrenado a partir de los datos de proceso.

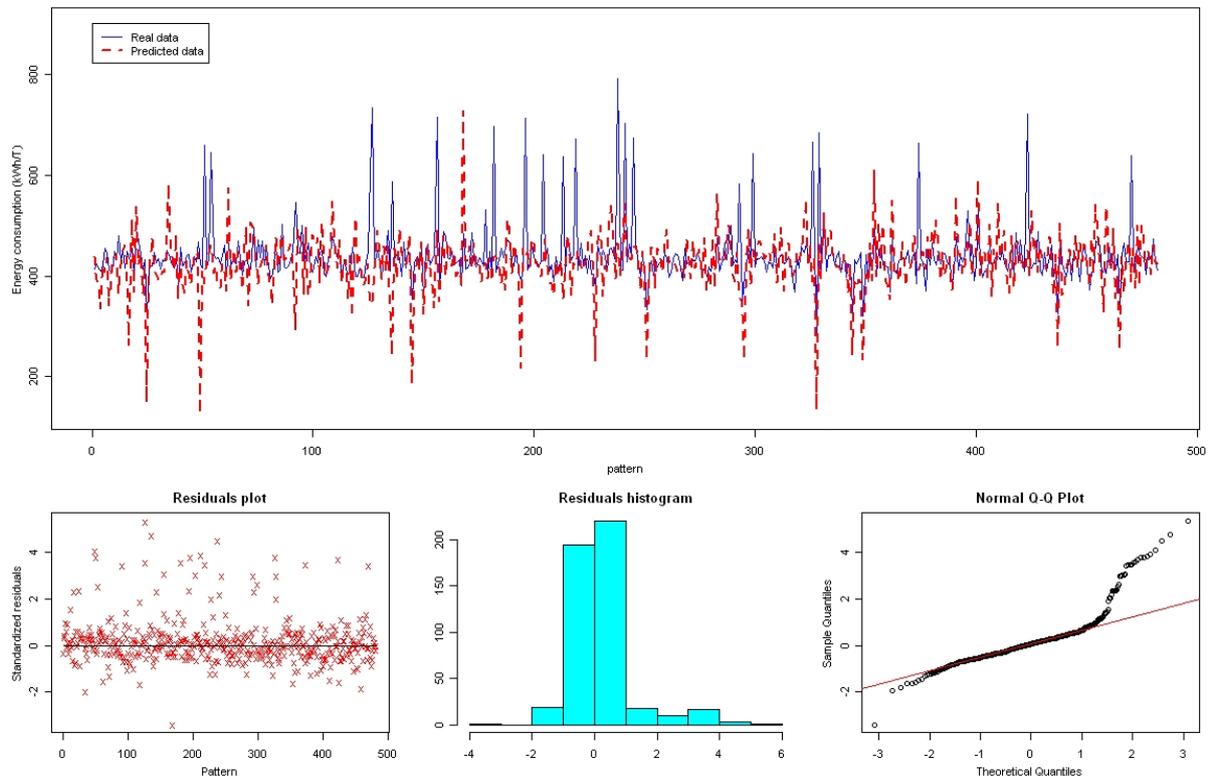


Figura 3. Resultados obtenidos con la ecuación de Köhle.

Parámetro	Ecuación de Köhle	Modelo lineal
Error mínimo	-244.90	-182.6
Error máximo	387.20	180.4
Error medio	14.92	-0.38
Desviación típica	71.60	27.43
Error medio relativo (%)	9.63	3.88

Tabla 2. Errores de test de los modelos lineales.

4. Conclusiones

En este trabajo se han utilizado técnicas de minería de datos que extraen conocimiento útil de los datos de proceso. Se ha generado, a partir de la composición de la mezcla de chatarra y elementos de adición, oxígeno y gas aportados, duraciones del proceso y temperatura medida, un modelo neuronal con una buena capacidad de predicción del consumo energético en el EAF.

La mejor capacidad de generalización de las redes neuronales frente a los modelos lineales era totalmente esperable, ya que como se comentaba al principio de este artículo, en la mayoría de los procesos industriales, las relaciones entre variables no son lineales. Además,

se ha comprobado la bondad de los modelos basados en datos propuestos frente a alguno de los modelos explícitos existentes en la literatura.

El modelo del consumo de energía eléctrica propuesto, es el primer paso para poder optimizar el proceso del horno de arco eléctrico, incrementar el rendimiento de la instalación, así como su productividad, y reducir costes de operación.

Referencias

Adams, W., Alameddine, S., Bowman, S., Lugo, B., Paege, S. and Stafford, P., "Total energy consumption in arc furnaces", *Metallurgical Plant and Technology International*. Vol. 25, no. 6, 2002, pp. 44-51.

Czapla, M., Karbowniczek, M. and Michaliszyn, A., "The optimization of electric energy consumption in the electric arc furnace", *Archives of Metallurgy and Materials*, Vol. 53, 2008, pp. 559-565.

Fruehan, R.J., Fortini, O., Paxton, H.W. and Brindle, R., "*Theoretical Minimum Energies to Produce Steel for Selected Conditions*". Energetics, Inc., Columbia, MD, US Department of Energy Office of Industrial Technologies Washington, DC, 2000.

Funahashi, K., "On the approximate realization of continuous mapping by neural networks", *Neural Networks*, 2, 1989, pp. 183-192.

Hornik, K.; Stinchcombe, M. & White, H., "Multilayer feedforward networks are universal approximators", *Neural Networks*, 2(5), 1989, pp. 359-366.

Köhle, S. "Recent improvements in modeling energy consumption of electric arc furnaces", *Proceedings of the 7th European Electric Steelmaking Conference*, Venice, 2002, pp. 1.305-1.314.

Liano K., "Robust Error Measure for Supervised Neural Network Learning with Outliers". *IEEE Transactions on Neural Networks*, 7(1), 1996, pp. 246-250.

Pernía Espinoza, A.V., Ordieres Meré, J.B., Martínez de Pisón, F.J., González Marcos, A., "TAO-robust backpropagation learning algorithm", *Neural Networks*, Vol. 18, 2005, pp. 191-294.

Pfeiffer, H. and Kirschen, M., "Thermodynamic analysis of EAF energy efficiency and comparison with a statistical model of electric energy demand", *Proceedings of the 7th European Electric Steelmaking Conference*, Venice, 2002, pp. 1.413-1.428.

Agradecimientos

Los autores agradecen al Ministerio de Educación y Ciencia de España, Dirección general de Investigación, a través de los proyectos DPI2007-61090, DPI-2006-02454 y DPI2006-03060.

Correspondencia (Para más información contacte con):

Ana González Marcos.
Área de Proyectos de Ingeniería. Departamento de Ingeniería Mecánica.
Universidad de La Rioja
C/ Luis de Ulloa 20, 26004 Logroño, La Rioja (España).
Phone: +34 941 299 519
E-mail: ana.gonzalez@unirioja.es