

PREDICCIÓN DEL PRECIO DE LA ELECTRICIDAD EN BRASIL USANDO REDES CASCADA CORRELACIÓN

CASCADE CORRELATION NETWORKS FOR ELECTRICITY SPOT PRICE FORECASTING IN BRASIL

Fernán Villa¹, Juan Velásquez²

¹ M.Sc. Escuela de Sistemas. Facultad de Minas. Universidad Nacional de Colombia. e-mail: fernanvilla@gmail.com ² Ph.D. Escuela de Sistemas. Facultad de Minas. Universidad Nacional de Colombia. Carrera 80 No. 65 – 223. Medellín, Colombia. Autor para Correspondencia. e-mail: jdvelasq@unal.edu.co

Rev. U.D.C.A Act. & Div. Cient. 14(2): 161 - 167, 2011

RESUMEN

En este artículo, se propone utilizar redes neuronales tipo cascada correlación regularizadas, para pronosticar el precio mensual, de corto plazo, de la electricidad del mercado brasileño. Se estiman diversos modelos de redes cascada correlación regularizados entre la capa de entrada y oculta, con descomposición o con eliminación de pesos, mientras que entre la capa oculta y la de salida, se regulariza con regresión de borde. Los resultados indican que las redes cascada correlación regularizadas en todas sus capas describen mejor la dinámica de la serie de precios que la misma red sin regularizar, que un modelo ARIMA y que un perceptrón multicapa (MLP) clásico, que usa los mismos rezagos y neuronas en la capa oculta, lo cual, permite afirmar, que para la serie de precios de electricidad, las redes cascada correlación regularizadas permiten encontrar modelos con mejor capacidad de pronóstico.

Palabras clave: Pronóstico, redes neuronales, mercados liberalizados.

ABSTRACT

The aim of this paper is to propose the use of regularized cascade correlation neural networks to forecast the monthly Brazilian electricity spot price. The cascade correlation models have been regularized with weight decay, weight elimination and ridge regression techniques, and several regularized models have been estimated. The results show that the regularized cascade correlation network represents the dynamic series better than other similar models such as the multilayer perceptron (MLP) and ARIMA. Then the regularized cascade correlation neural networks allow finding a suitable model to forecast the monthly Brazilian electricity spot price.

Key words: Forecasting, neural networks, liberalized markets.

INTRODUCCIÓN

En la literatura, se han propuesto diversas técnicas para realizar la predicción de series de tiempo; de las disponibles, las redes neuronales artificiales (RNA) han mostrado ser más robustas que otras técnicas tradicionales, como ARIMA, especialmente, en la representación de relaciones complejas que exhiben comportamientos no lineales. Según Masters (1993), existen varias razones, por las cuales, se debería utilizar una RNA en vez de alguna técnica tradicional, entre estas, que poseen una amplia capacidad para aprender relaciones desconocidas, a partir de un conjunto de ejemplos; además, tienen una alta tolerancia a patrones extraños de ruido y componentes caóticos presentes en la serie y son suficientemente robustas para procesar información incompleta, inexacta o contaminada.

Una revisión del estado del arte, del pronóstico de series de tiempo con redes neuronales, es presentada por Zhang *et al.* (1998); particularmente, en mercados de electricidad, se han realizado contribuciones importantes, entre ellas: Velásquez *et al.* (2007), analizan las dificultades encontradas por los investigadores y profesionales cuando intentan pronosticar los precios de la electricidad, con el objetivo de contribuir a identificar las barreras más importantes para tal fin; Velásquez *et al.* (2008), usan un modelo conocido como red neuronal autorregresiva, un perceptrón multicapa y un modelo autorregresivo, para pronosticar el precio spot de la electricidad en Brasil, entre enero de 1993 y septiembre de 2003, obteniendo mejores resultados con la red neuronal autorregresiva; Gareta *et al.* (2004), muestran que las redes neuronales son una herramienta adecuada para predecir los precios horarios base de la electricidad del mercado

eléctrico Europeo; Hippert *et al.* (2005), realizan una revisión del estado del arte de la predicción de la carga eléctrica a corto plazo, con redes neuronales.

El modelado y la predicción de precios de la electricidad es un problema particularmente difícil, debido a que el proceso de transformación de los sectores eléctricos en el mundo ha creado nuevos mercados competitivos, diseñados bajo el principio de eficiencia económica, que incentivan la entrada de capitales privados a los negocios de generación, de transmisión y de distribución (Steiner, 2000; Armstrong *et al.* 1994). Con la llegada de la nueva estructura competitiva del mercado, se implementaron nuevos mecanismos para la formación de los precios de la electricidad, obligando al desmonte de todas las protecciones y controles existentes. Es así, entonces, como las series de precios de la electricidad poseen, ahora, características únicas que no han estado presentes en los mercados eléctricos tradicionales. Tal como es indicado por Pilipovic (1998), los precios de la electricidad en los mercados liberalizados –sin regulación–, se ven influenciados en el corto plazo por las condiciones instantáneas de operación del sistema de generación para satisfacer la demanda, mientras que en el largo plazo dependen del crecimiento de la demanda y de la nueva capacidad instalada para atenderla; consecuentemente, la evolución del precio se ve influenciada por una gran cantidad de factores complejos, que se resumen en las condiciones físicas del sistema de generación, en las decisiones de negocio de los agentes y en las decisiones y pautas del regulador.

Así, el modelado y la predicción de los precios de la electricidad ha cobrado una importancia fundamental, para los distintos agentes económicos, ya que está relacionada con:

- La necesidad que tienen los generadores, los distribuidores y el regulador del mercado de tomar decisiones, tanto operativas como estratégicas, relacionadas con la formulación de estrategias de comercialización, en el corto y en el largo plazo (Pilipovic, 1998).
- La optimización de su programa de generación la conformación del portafolio de activos de generación (Conejo *et al.* 2005).
- La adquisición de nuevas plantas y el abandono de plantas existentes (Lu *et al.* 2005; Angelus, 2001).
- Así como un mejor manejo y planeamiento del mercado desde el papel del regulador (Angelus, 2001).

Particularmente, en el caso brasileño, el proceso de reforma creó el Mercado Atacadista de Energía (MAE), donde la electricidad es libremente negociada, a través de contratos forward bilaterales, entre los agentes y una Bolsa de excedentes, donde las compras y las ventas se liquida

directamente con el ente administrador del sistema, a un precio de mercado establecido por el gobierno. El precio *spot* o de corto plazo es usado como una señal económica, que refleja el costo marginal de operación del sistema de generación en el corto plazo. Su modelado y su pronóstico son particularmente difíciles, debido a la complejidad de la dinámica de la serie y la corta información histórica disponible. Adicionalmente, existen pocos trabajos relacionados con su modelado e interpretación (De Medeiros, 2004). En este trabajo, se realiza una contribución, en este aspecto, al modelar la serie de precios de corto plazo de Brasil, con redes Cascada Correlación.

La red neuronal artificial, conocida como Cascada Correlación (CASCOR), diseñada originalmente por Fahlman & Lebiere (1990), presenta ventajas conceptuales muy interesantes, en relación al problema de identificabilidad estadística de los MLP (Velásquez *et al.* 2010). La red CASCOR está proyectada siguiendo el esquema de crecimiento de red o de aprendizaje constructivo; se comienza con una red mínima sin capas ocultas, es decir, con sólo algunas entradas y uno o más nodos de salida; las neuronas ocultas son agregadas, una a una, en la red, obteniendo, de esta manera, una estructura multicapa; en el proceso de adición de neuronas ocultas a la red, cada nueva neurona recibe una conexión sináptica de cada una de las neuronas de entrada y también de las neuronas ocultas que la preceden. Luego de agregar la nueva neurona oculta, los pesos sinápticos de su entrada son congelados, mientras que los pesos de su salida son entrenados repetidamente; este proceso continúa hasta que se alcanza un rendimiento deseado. Consecuentemente, en una red CASCOR no es necesario conocer, *a priori*, la cantidad de neuronas necesarias en la capa oculta, por tanto, el aprendizaje de la red puede ser más rápido y tener mejor capacidad de generalización que un MLP (Villa *et al.* 2008).

A pesar que el aprendizaje de las redes CASCOR es constructivo, pueden adolecer de sobreajuste, tal como en otros tipos de técnicas, debido, básicamente, a dos causas: la primera, está relacionada con el tamaño óptimo de la red y, la segunda, con la existencia de datos extremos (*outliers*) en el conjunto de entrada, esto hace que la varianza de los parámetros de la red sea alta. El sobreajuste es un fenómeno, en el cual, la red no generaliza los datos y sólo puede responder correctamente ante los estímulos ya conocidos, es decir, la red memoriza en vez de aprender; este fenómeno se evidencia cuando se produce un error de entrenamiento muy pequeño y un error de validación muy alto (Villa *et al.* 2008); Consecuentemente, si se presentan una o ambas de las causas mencionadas, el modelo CASCOR podría sobreajustar los datos, lo que puede degradar, ostensiblemente, su capacidad de predicción.

Villa *et al.* (2008) proponen controlar la primera causa, regularizando los pesos de la red CASCOR, entre la capa de entrada y la oculta, empleando las estrategias de descomposición de pesos (Weight Decay) propuesta por Hinton (1989) y eliminación de pesos (Weight Elimination), por Weigend *et al.* (1991), las cuales, han sido ampliamente utilizadas para regularizar los MLP. Asimismo, muestran que las estrategias de regularización permiten encontrar modelos con mejor capacidad de generalización y de habilidad para pronosticar series temporales; sin embargo, no tienen en cuenta la segunda causa de sobreajuste.

La segunda causa de sobreajuste, se puede abordar mediante la regularización de las conexiones entre la capa oculta y la capa de salida, usando la estrategia de regresión de borde (Ridge Regression), propuesta por Hoerl & Kennard (1970); la idea central de esta estrategia es controlar la varianza de los parámetros, buscando el equilibrio entre sesgo y varianza (bias variance trade-off) (para más detalles consultar Hoerl & Kennard, 1970 y Marquardt & Snee, 1975). Esta estrategia de regularización puede reducir la varianza de los pesos y minimizar el efecto de los datos extremos y, consecuentemente, reducir el error en validación; sin embargo, no se ha considerado el uso de dicha estrategia en el entrenamiento de redes CASCOR para modelar series de tiempo de precios de la electricidad, aunque es de esperarse que se puedan obtener modelos con una mejor capacidad de generalización.

Entonces, esta investigación tuvo los siguientes objetivos: implementar la estrategia de regularización de regresión de borde en la especificación de la red CASCOR; además, analizar, empíricamente, el efecto de las estrategias de regularización mencionadas sobre las redes CASCOR, al pronosticar la serie de tiempo del precio mensual de corto plazo, de la electricidad del mercado brasileño y comparar los resultados obtenidos, con los de otros modelos.

Además, mediante este trabajo, se busca contribuir, tanto conceptual como metodológicamente, a la solución de algunos de los problemas de la predicción de series de tiempo de precios de la electricidad (Velásquez *et al.* 2007). En este orden de ideas, el modelado y el pronóstico de series de precios de la electricidad es particularmente difícil, debido a la complejidad de la dinámica de la mayoría de las series y la corta información histórica disponible. Entonces, es necesario emplear técnicas suficientemente robustas para realizar su pronóstico, tal como redes neuronales cascada correlación.

Para alcanzar los objetivos propuestos, el resto del artículo está estructurado como sigue: en la siguiente sección, se describe la información utilizada para realizar el pronóstico

en cuestión; a continuación, la metodología empleada; seguidamente, se presentan y se discuten los resultados obtenidos y, finalmente, se concluye.

MATERIALES Y MÉTODOS

El precio de corto plazo en Brasil es fijado semanalmente y se calcula para cada uno de los cuatro submercados (Norte-Nordeste, Sureste/Centro, Oeste y Sur) en que se encuentra dividido el sector eléctrico brasileño. Corresponde al costo marginal de demanda, resultante de la optimización de la operación mensual, usando un modelo de planificación centralizada y, posteriormente, una planificación determinística para llevarlo a nivel semanal. No obstante, el precio puede ser modificado si se considera que no refleja, adecuadamente, las condiciones del sistema de generación en el corto plazo.

Los precios son una señal económica relacionada con el costo marginal del mercado, los cuales, permiten a los generadores, la recuperación de sus costos operacionales en el corto plazo y de sus inversiones en el largo plazo; más aún, el crecimiento de los precios señala la necesidad de nuevas inversiones en activos de generación. Es evidente la importancia de los pronósticos de los precios de electricidad, ya que todas las decisiones operativas y estratégicas de los participantes en el mercado son basadas en ellos (Velásquez *et al.* 2008).

De Medeiros (2004), indica que el parque de generación es predominantemente hidráulico, alcanzando, aproximadamente, un 85% de la capacidad instalada del sistema (unos 68 GW), mientras que la capacidad restante es suministrada por plantas térmicas (alrededor de 9 GW), importaciones (2 GW) y pequeñas plantas (1 GW). El sistema tiene un cubrimiento del 97% de la demanda total del sistema; dada la importancia del modelado y la predicción de largo plazo, para las decisiones de los agentes del mercado.

Para realizar el pronóstico, se posee la información histórica del precio entre 1996:1 y 2009:11, en la región SE, para un total de 167 datos. Se transforma la serie, mediante el logaritmo natural; esto impone una restricción estructural de los precios, ya que evita que los valores pronosticados puedan ser negativos; adicionalmente, facilita la labor del modelado, puesto que la distribución de la variable dependiente se hace más semejante a una normal, minimizando la influencia de los valores extremos. En la Figura 1, se presenta el logaritmo natural de precio mensual de corto plazo de la región SE.

El modelado y la predicción de la serie de precio mensual de corto plazo brasileño de la electricidad de la región SE

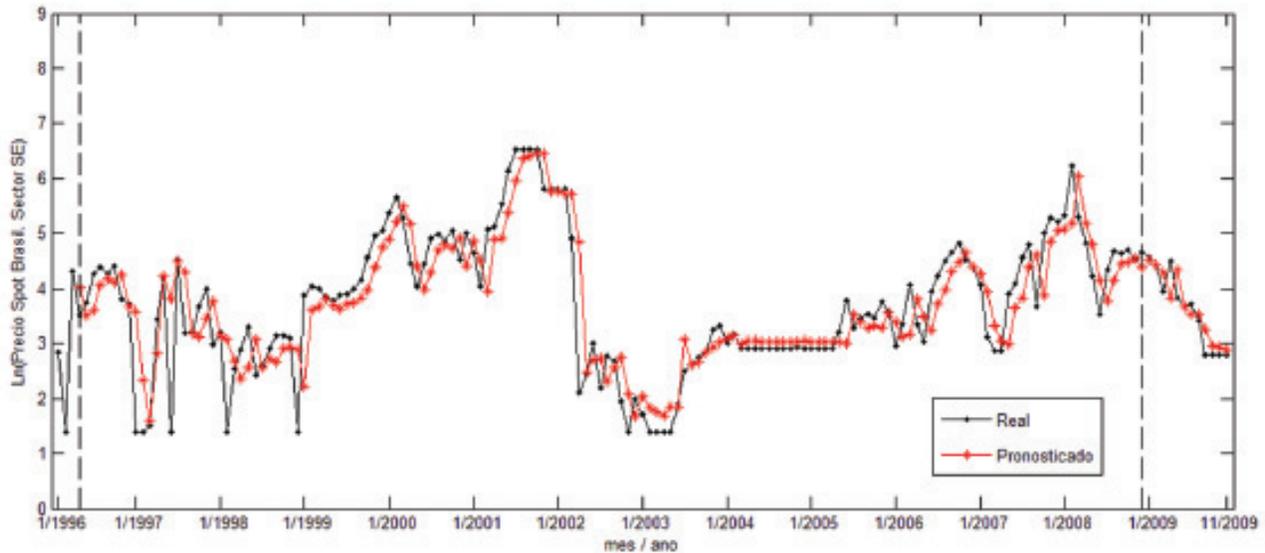


Figura 1. Predicción un paso delante de la Serie de Precios Spot Brasil del Sector SE.

son particularmente difíciles, debido a su dinámica compleja y la corta información histórica disponible. Para estimar los parámetros de los modelos, se toman los primeros 155 datos, los restantes, se emplean para evaluar su capacidad de predicción en un horizonte de doce meses. A continuación, se describe un protocolo de selección para el tipo de red CASCOR, para la predicción de esta serie.

El tamaño inicial de la red CASCOR, se puede especificar de la siguiente manera:

- Las neuronas de la capa de entrada corresponden a cada uno de los rezagos seleccionados a criterio de la persona experta que desea realizar el pronóstico para una serie de tiempo específica.
- Las neuronas en la capa oculta, por el esquema de aprendizaje de las redes CASCOR, su cantidad inicial es cero.
- Para realizar tareas de pronóstico un paso adelante es suficiente con una neurona de salida o de respuesta.
- Para seleccionar la cantidad de neuronas en la capa oculta de la red, el aprendizaje incremental de la arquitectura de las redes CASCOR permite encontrar su cantidad óptima.

A pesar de que la red misma determina su tamaño y su topología, ésta pueden adolecer de sobreajuste; para controlar este problema, se propone regularizar los pesos entre la capa de entrada y la oculta, con las estrategias de descomposición o de eliminación de pesos y los pesos entre

la capa oculta y la de salida, con regresión de borde. En este orden de ideas es posible tener los siguientes esquemas de regularización: sólo regularizar con eliminación de pesos; sólo con descomposición de pesos; sólo con regresión de borde; regularizar completamente la red CASCOR, es decir, regularizar, a la vez, con eliminación de pesos y de regresión de borde o con descomposición de pesos y regresión de borde.

Respecto a la selección de las entradas a la red (rezagos), se controla implícitamente, mediante la estrategia de regularización de eliminación de pesos o descomposición de pesos (Villa *et al.* 2008).

Además, los parámetros de la red CASCOR, se estiman mediante ConRprop, técnica que permite encontrar modelos con mejor capacidad de generalización que los obtenidos con los MLP, optimizados con otras técnicas (Villa *et al.* 2009). Para el entrenamiento de la red, se utiliza el 80% de la información correspondiente a los primeros datos de la serie en su orden y para su validación el 20% restante. Para la regularización por descomposición de pesos, se toma $\lambda=0,0001$, mientras que para eliminación de pesos, $\lambda=0,0001$ y $w_0=100$ (Villa *et al.* 2008). Finalmente, se usa el logaritmo natural de la serie para estabilizarla en varianza; una vez definida la metodología en la siguiente sección, se presentan y analizan los resultados.

RESULTADOS Y DISCUSIÓN

Para la serie estudiada en este artículo, se estimaron los modelos de la Tabla 1, con los cuales, se realizó el pronóstico en un horizonte de un año, es decir, doce meses. La bondad de ajuste de los modelos, se midió con la sumatoria del error cuadrático medio (MSE), tanto en entrenamiento como en pronóstico (validación); los resultados se presentan en la misma tabla. Además, para analizar el efecto de las estrategias de regularización sobre los modelos CASCOR, se usan los siguientes esquemas de regularización:

- (a) EP, red CASCOR regularizada con eliminación de pesos
- (b) DP, red CASCOR regularizada con descomposición de pesos
- (c) RB, red CASCOR regularizada con regresión de borde
- (d) EP+RB, red CASCOR regularizada con eliminación de pesos y regresión de borde
- (e) DP+RB, red CASCOR regularizada con descomposición de pesos y regresión de borde

Para evaluar la capacidad de predicción de las redes CASCOR respecto a otros modelos, se realiza la comparación respecto a un MLP e, ilustrativamente, se presenta un modelo autorregresivo integrado de promedios móviles (ARIMA). El modelo MLP fue estimado para diferentes conjuntos de rezagos y se seleccionaron los mejores modelos con menor error. La arquitectura del MLP consta de una capa de entrada con una neurona por cada uno de los rezagos considerados, una capa oculta con tres neuronas –la misma cantidad alcanzada por los modelos CASCOR– y una capa de salida; los resultados, se presentan en la Tabla 1. Mediante el algoritmo auto ARIMA de Hyndman & Khandakar (2008), se obtiene el mejor modelo ARIMA (4,0,3)(2,0,2)[12] (Tabla 1). Se destaca que todos los modelos CASCOR regularizados completamente alcanzan un error inferior al de los correspondientes modelos de red CASCOR, sin regularizar, y del MLP; además, sus errores son evidentemente menores, tanto en entrenamiento como en predicción, al obtenido con el modelo ARIMA.

Tabla 1. Valores del error cuadrático medio (MSE) al pronosticar la serie con diferentes modelos.

Modelo	Rezagos	Error Cuadrático Medio (MSE)	
		Entrenamiento	Predicción un año
ARIMA	1, 2, 3, 4, 13, 14	0,4757	0,4999
MLP-1	1 – 3	0,4003	0,1011
CASCOR-1	1 – 3	0,3682	0,1282
CASCOR-EP-1	1 – 3	0,3683	0,1284
CASCOR-DP-1	1 – 3	0,3823	0,1412
CASCOR-RB-1	1 – 3	0,3676	0,0955
CASCOR-EP+RB-1	1 – 3	0,3653	0,0927
CASCOR-DP+RB-1	1 – 3	0,3373	0,1009
MLP-2	1 – 6	0,3751	0,1971
CASCOR-2	1 – 6	0,4564	0,1138
CASCOR-EP-2	1 – 6	0,3779	0,1139
CASCOR-DP-2	1 – 6	0,4347	0,1419
CASCOR-RB-2	1 – 6	0,2881	0,1216
CASCOR-EP+RB-2	1 – 6	0,2754	0,1152
CASCOR-DP+RB-2	1 – 6	0,2622	0,1126
MLP-3	1 – 13	0,2994	0,1948
CASCOR-3	1 – 13	0,2548	0,1512
CASCOR-EP-3	1 – 13	0,2423	0,1909
CASCOR-DP-3	1 – 13	0,3589	0,1278
CASCOR-RB-3	1 – 13	0,2348	0,2420
CASCOR-EP+RB-3	1 – 13	0,1730	0,0926
CASCOR-DP+RB-3	1 – 13	0,2431	0,1090

Los resultados muestran que, en los modelos con tres rezagos, el que mejor se ajusta a la serie es la CASCOR-DP+RB-1; sin embargo, el que excelentemente la pronostica es la CASCOR-EP+RB-1; el error de entrenamiento de CASCOR-EP+RB-1 es 8,17% más alto que el logrado con CASCOR-DP+RB-1, mientras que su error de entrenamiento es 8,85% menor. La diferencia entre ambos es relativamente poca, por tanto, cualquiera de los dos es apropiado para modelar la serie; además, sus errores son menores que los logrados con el MLP-1 y el ARIMA. Por otro lado, los modelos que sólo se regularizaron con EP y DP, CASCOR-EP-1 y CASCOR-DP-1, no lograron mejorar el error logrado por CASCOR-1 sin regularizar; mientras que el CASCOR-RB-1 sí lo hizo, incluso, mejoró el error conseguido con MLP-1.

Cuando se tienen seis rezagos, el modelo CASCOR-DP+RB-2 se perfila como uno de los mejores, pues consigue el menor error, tanto en entrenamiento como en pronóstico; asimismo, el modelo que más se acerca a éste es el CASCOR-EP+RB-2, con un error 4,79% y 2,26% mayor, en entrenamiento y predicción, respectivamente. Entonces, del conjunto de modelos con seis rezagos se observa que, también el CASCOR-EP+RB-2 y el CASCOR-DP+RB-2 son apropiados para modelar la serie, teniendo en cuenta que el CASCOR-DP+RB-2 es el que tiene mejor capacidad de generalización; no obstante, la diferencia de CASCOR-EP+RB-2 respecto a CASCOR-DP+RB-2 es relativamente poca; además, sus errores también son menores que los logrados con el MLP-1 y el ARIMA. Por otro lado, se observa que los modelos que sólo se regularizaron con una técnica logran errores poco aceptables. Consecuentemente, para esta serie, en particular, se consiguen buenos resultados, regularizando completamente la red CASCOR.

El hecho de aumentar a 13 rezagos, muestra que el mejor de todos los modelos es el CASCOR-EP+RB-3, regularizado entre la capa de entrada y la oculta con eliminación de pesos y entre la oculta y la de salida con regresión de borde. Los errores, en entrenamiento y en pronóstico del modelo CASCOR-3, que no tiene ningún tipo de estrategia de regularización, son 32,1% y 38,76% más altos que los alcanzados por CASCOR-EP+RB-3; mientras que los del CASCOR-DP+RB-3 son mayores un 28,84% y 15,05%. Del mismo modo, se nota que no existen ganancias significativas al regularizar la red CASCOR con sólo una técnica. En este orden de ideas, el modelo más adecuado para pronosticar la serie es el CASCOR-EP+RB-3; no obstante, el modelo CASCOR-DP+RB-3 también podría ser tenido en cuenta.

En general, para esta serie, los modelos CASCOR regularizados completamente –entre capa de entrada y oculta, y entre oculta y salida– alcanzan mejores errores que la mayoría de modelos; entonces, los regularizados

completamente son más apropiados para realizar el pronóstico, dado que controlan, en gran medida, las causas del sobreajuste. Además, es notorio que no se encontraron ganancias al regularizar las redes CASCOR con una sola técnica; sin embargo, en algunos casos, se logran resultados aceptables al regularizar sólo con regresión de borde.

Los resultados indican que las redes CASCOR regularizadas completamente pronostican, de manera más precisa, que los MLP, que el modelo ARIMA y que las mismas CASCOR sin regularizar. Entonces, las redes cascada correlación regularizadas permiten encontrar modelos con mejor capacidad de generalización que otras propuestas en la literatura. Los buenos resultados conseguidos respecto a otras técnicas, posibilitan la incorporación de las redes CASCOR en el conjunto de herramientas disponibles para el pronóstico de series de tiempo de precios de la electricidad.

Agradecimientos: Los autores expresan sus agradecimientos a los dos evaluadores anónimos, cuyos comentarios permitieron mejorar ampliamente la calidad del artículo.
Conflictos de intereses: Este artículo fue preparado y revisado con la participación de todos los autores, quienes declaran que no existe ningún conflicto de intereses que ponga en riesgo la validez de los resultados presentados.

BIBLIOGRAFÍA

1. ANGELUS, A. 2001. Electricity price forecasting in deregulated markets. *The Electricity Journal (USA)*. 13(4):32-41.
2. ARMSTRONG, M.; COWAN, S.; VICKERS, J. 1994. *Regulatory Reform: Economic Analysis and British Experience*. Ed. Cambridge: The MIT Press (USA). 392p.
3. CONEJO, A.; CONTRERAS, J.; ESPÍNOSA, R.; PLAZAS, M. 2005. Forecasting electricity prices for a day-ahead pool-based electric energy market. *Internal J. Forecasting (USA)*. (21):435-462.
4. DE MEDEIROS, L. 2004. *Previsão do Preço Spot no Mercado de Energia Elétrica*. PhD thesis, Pontificia Universidade Católica do Rio de Janeiro. Disponible desde Internet en: <http://www.maxwell.lambda.ele.puc-rio.br/> [con acceso el 02/10/2009].
5. FAHLMAN, S.E.; LEBIERE, C. 1990. The Cascade-Correlation Learning Architecture. *Advances in Neural Information Processing Systems (USA)*. 2:524-532.

6. GARETA, R.; GIL, A.; MONZÓN, A.; ROMEO, L. 2004. Las redes neuronales como herramienta para predecir el precio de la energía eléctrica. *Energía: Revista de Ingeniería energética y medioambiental (España)*. 30(180):67-72.
7. HINTON, G. 1989. Connectionist learning procedures. *Artificial Intelligence (USA)*. (40):185-243.
8. HIPPERT, H.; BUNN, D.; SOUZA, R. 2005. Large neural networks for electricity load forecasting: Are they overfitted? *Internal J. Forecasting (USA)*. 21(3):425-434.
9. HOERL, A.E.; KENNARD, R.W. 1970. Ridge Regression: Biased Estimation for Nonorthogonal Problems. *Technometrics (USA)*. 12(1):55-67.
10. HYNDMAN, R.; KHANDAKAR, Y. 2008. Automatic time series forecasting: The forecast package for R. *J. Statistical Software (USA)*. 26(3):1-22.
11. LU, X.; DONG, Z.; LI, X. 2005. Electricity market price spike forecast with data mining techniques. *Electric Power Systems Research (USA)*. 73(1):19-29.
12. MARQUARDT, D.W.; SNEE, R.D. 1975. Ridge regression in practice. *The American Statistician (USA)*. 29(1):3-20.
13. MASTERS, T. 1993. Practical neural network recipes in C++. Ed. New York: Academic Press (USA). 493p.
14. PILIPOVIC, D. 1998. Energy Risk. Valuing and Managing Energy Derivatives. Ed. McGraw-Hill (USA). 64p.
15. STEINER, F. 2000. Regulation, industry structure and performance in the electricity supply industry. OECD Economics Department Working Papers (Francia). 238:5-25.
16. VELÁSQUEZ, J.D.; DYNER, I.; SOUSA, R.C. 2007. ¿Por qué es tan difícil obtener buenos pronósticos de los precios de la electricidad en mercados competitivos? *Cuadernos de Administración (Colombia)*. 20:259-282.
17. VELÁSQUEZ, J.D.; VILLA, F.A.; SOUZA, R.C. 2010. Predicción de series de tiempo con redes cascada-correlación. *Ingeniería e Investigación (Colombia)*. 30(1):157-162.
18. VELÁSQUEZ, J.D.; DYNER, I.; SOUZA, R.C. 2008. Modelado del Precio Spot de la Electricidad en Brasil Usando una Red Neuronal Auto Regresiva. *Ingeniare: Rev. Chilena de Ingeniería*. 16(3):394-403.
19. VILLA, F.A.; VELÁSQUEZ, J.D.; JARAMILLO, P. 2009. Conrprop: un algoritmo para la optimización de funciones no lineales con restricciones. *Rev. Facultad de Ingeniería Universidad de Antioquia (Colombia)*. (50):188-194.
20. VILLA, F.A.; VELÁSQUEZ, J.D.; SOUZA, R.C. 2008. Una aproximación a la regularización de redes cascada-correlación para la predicción de series de tiempo. *Investigación Operacional (Portugal)*. (28):151-161.
21. WEIGEND, A.S.; RUMELHART, D.E.; HUBERMAN, B.A. 1991. Generalization by weight-elimination with application to forecasting. *Advances in Neural Information Processing Systems (USA)*. 3:875-882.
22. ZHANG, G.; PATUWO, B.E.; HU, M.Y. 1998. Forecasting with artificial neural networks: the state of the art. *Internal J. Forecasting (USA)*. 14(1):35-62.

Recibido: Octubre 25 de 2010

Aceptado: Octubre 13 de 2011