

AVANCES RECIENTES EN LA PREDICCIÓN DE LA DEMANDA DE ELECTRICIDAD USANDO MODELOS NO LINEALES

RECENT ADVANCES IN LOAD FORECASTING USING NONLINEAR MODELS

VIVIANA MARÍA RUEDA

Estudiante, Maestría en Administración, Universidad Nacional de Colombia, vmrueda@unal.edu.co

JUAN DAVID VELÁSQUEZ HENAO

Profesor Asociado, Escuela de Sistemas, Universidad Nacional de Colombia, jdvelasq@bt.unal.edu.co

CARLOS JAIME FRANCO CARDONA

Profesor Asociado, Escuela de Sistemas, Universidad Nacional de Colombia, cjfranco@bt.unal.edu.co

Recibido para revisar septiembre 7 de 2010, aceptado noviembre 26 de 2010, versión final mayo 4 de 2011

RESUMEN: La predicción de la demanda es un problema de gran importancia para el sector eléctrico, ya que a partir de sus resultados, los agentes del mercado de energía toman las decisiones más adecuadas para su labor. En este artículo se presenta un análisis de las técnicas y modelos más usados en el pronóstico de la demanda de electricidad y la problemática o dificultades a las que se enfrentan los investigadores al momento de realizar un pronóstico. El análisis muestra que las técnicas más usadas son los modelos ARIMA y las redes neuronales artificiales. Sin embargo, se encontró poca claridad sobre cuál modelo es más adecuado y en qué casos, adicionalmente, los estudios no presentan una recomendación específica para desarrollar modelos de pronóstico de demanda, específicamente en el caso colombiano. Finalmente, se propone realizar un estudio sistemático con el fin de determinar los modelos más adecuados para predicción de demanda para el caso colombiano.

PALABRAS CLAVE: Pronóstico, demanda de electricidad, modelos no lineales.

ABSTRACT: Electricity demand forecasting is a major problem for the electricity sector, because the energy market players use the results of the electricity demand forecasting to make the right decisions for their work. This article presents an analysis of models and techniques used in the electricity demand forecasting and explain the problems or difficulties that researchers have when making a forecast. Our analysis shows that the most used techniques are the ARIMA model and artificial neural networks. However, it appears unclear evidence on which model is most appropriate and in what cases, in addition, the studies do not present a specific recommendation to develop models for forecasting demand, specifically in the Colombian case. Finally, we propose to make a systematic study to determine the most appropriate models for forecasting demand for the Colombian case.

KEYWORDS: Forecasting, electricity demand, nonlinear models.

1. INTRODUCCIÓN

La predicción de la demanda de electricidad es un insumo fundamental para la toma de decisiones operativas y estratégicas [1], cuya falta de precisión puede traer altos costos económicos[2].

La liberalización del mercado y las integraciones energéticas regionales han causado una gran incertidumbre sobre la evolución de los precios debido a la gran cantidad de factores que intervienen en el mercado [3], los cuales también han aumentado la incertidumbre inherente al crecimiento de la demanda [1].

La gran cantidad de publicaciones realizadas en la última década son una evidencia de los grandes esfuerzos que ha realizado la comunidad académica por desarrollar nuevos y mejores métodos para el pronóstico de la demanda de electricidad. El análisis de dicha información es uno de los objetivos de este trabajo.

Existen varias razones que pueden explicar la dificultad de realizar pronósticos acertados de la demanda; entre ellas se cuentan: las complejidades de sus factores determinantes, las características estructurales de los datos, el horizonte de pronóstico y las limitantes propias de las metodologías empleadas. Uno de los objetivos de este artículo es discutir estas limitantes.

Existe un consenso general de que muchas series de demanda presentan evidencias de comportamiento no lineal. De ahí, que se haya presentado una proliferación del uso de metodologías no lineales para su pronóstico. Otro objetivo de este artículo es presentar una visión panorámica e integradora de las metodologías utilizadas y de los casos de aplicación abordados que ayude a identificar, organizar, clasificar y caracterizar la diversidad de aproximaciones existentes.

El resto de este artículo está organizado como se describe a continuación: en la Sección 2, se discuten las razones que motivan la necesidad de pronosticar la demanda. En la Sección 3, se analizan las características de las series de demanda. En la Sección 4, se analizan las principales experiencias reportadas en la literatura técnica sobre la predicción de la demanda de electricidad. Seguidamente, se realiza, en la Sección 5, una discusión sobre las principales metodologías empleadas y los casos exitosos reportados en la literatura técnica. Posteriormente, se presenta un análisis de las principales dificultades a la hora de construir pronósticos de la demanda de electricidad. Finalmente, se concluye en la Sección 7.

2. NECESIDAD DE PRONOSTICAR LA DEMANDA

La predicción de la demanda de electricidad se realiza para horizontes de corto, mediano y largo plazo[5]. El corto plazo corresponde a la predicción en tiempo real para la hora siguiente y con un horizonte de hasta una semana hacia delante; el pronóstico se basa en los datos históricos de demanda diaria y factores climáticos. El mediano plazo corresponde al pronóstico mensual con un horizonte de hasta un año a partir de la demanda histórica de electricidad, y la predicción de algunas variables explicativas como el crecimiento de la economía o el clima. Finalmente, el largo plazo abarca un horizonte de uno hasta diez años; la predicción de la demanda en el largo plazo es usada para la planeación y expansión de la generación y de la transmisión; los datos usados para este pronóstico son la demanda anual, el precio de la electricidad, el precio de productos sustitutos, la evolución demográfica e indicadores económicos, entre otros.

Dependiendo del tipo de agente del mercado, la predicción de la demanda se justifica por las razones enunciadas a continuación.

- Para los generadores[6,7,8]: El pronóstico de demanda

en el corto plazo permite definir la cantidad de energía a generar (ofertar) para el día siguiente, programar la operación de unidades y fijar el precio de oferta de la electricidad en el mercado spot. En el mediano plazo es un insumo fundamental para la definición de planes de mercadeo y ventas en contratos, y análisis de la evolución del mercado. En el largo plazo, permite detectar los periodos para los cuales existen excesos y faltantes de capacidad de generación con el fin de planificar las inversiones en la expansión del sistema de generación y adoptar medidas de conservación de la energía; en el largo plazo, este es un problema fundamental debido a que la construcción de una nueva planta generadora puede tomar varios años [12], afectando la confiabilidad del suministro de energía eléctrica.

- Para los distribuidores y transmisores [6,7]: En el corto plazo, permite realizar el monitoreo del comportamiento de la red con el fin de identificar puntos críticos que en el futuro pueden llevar a grandes fallas. Se utiliza en el mediano plazo para el planeamiento de los mantenimientos del sistema. Es un insumo fundamental para definir el programa de expansión del sistema de transmisión en el largo plazo.
- Para los comercializadores[6]: En el mediano y largo plazo, es un insumo fundamental para el análisis del comportamiento del mercado y la definición de los planes estratégicos y operativos para la comercialización de la electricidad.
- Para el operador del mercado[7]: En el corto plazo es un insumo fundamental para la programación y operación de las unidades de generación, minimizando los ajustes del programa de operación en tiempo real, con el fin de evitar los sobrecostos en la producción de la electricidad.

3. CARACTERÍSTICAS GENERALES DE LAS SERIES DE DEMANDA

Las series de demanda de electricidad presentan características particulares que se han identificado en diferentes estudios [5, 6,9]:

- Las series de demanda que presentan fuertes patrones cíclicos de periodicidad anual, mensual, semanal, diaria y horaria; además, es afectada por eventos atípicos como la presencia de días festivos.
- El consumo de electricidad varía de acuerdo con la estación del año, el día de la semana y la hora del día. Los mayores consumos se presentan durante los días

laborales y en las horas pico como son las 12:00 h y 19:00 h.

- Su evolución en el corto, mediano y largo plazo está influenciada por eventos climáticos extremos como el fenómeno de El Niño o La Niña; y por factores económicos como el crecimiento del PIB, los precios de energía o el crecimiento de la población [10, 11, 13, 14, 15].

4. EXPERIENCIA EN EL PRONÓSTICO DE LA DEMANDA

Para analizar la evolución reciente de los estudios de pronóstico de demanda, se consideraron artículos publicados en el periodo 1992 – 2010; la revisión bibliográfica realizada consta de 74 artículos. La búsqueda se realizó en las bases de datos ScienceDirect, Scopus e IEEE Explorer utilizando el término “load forecasting” y sus extensiones o sinónimos; adicionalmente, se consideró la revisión bibliográfica realizada por Franco et al. [16].

De la revisión de la literatura realizada, se encuentra que la técnica de pronóstico más usada son las redes neuronales artificiales y de ellas, principalmente, el perceptrón multicapa; como segunda opción se tienen los modelos estadísticos de series de tiempo, siendo el modelo ARIMA el más utilizado, usualmente como modelo de comparación frente a técnicas más complejas. Se resalta además el uso de modelos híbridos los cuales combinan técnicas de redes neuronales, lógica difusa, algoritmos genéticos y las técnicas tradicionales de serie de tiempo y regresión.

Finalmente, se identificaron los artículos de mayor relevancia en el tema de pronóstico de demanda utilizando como medida de influencia el número de citas, para esto se consultó la base de datos de Scopus (<http://info.scopus.com/>). La lista de los principales artículos publicados en las visitas consultadas se presenta en la Tabla 2. Se seleccionaron los artículos que presentaban más de 25 citas.

El análisis realizado muestra que el tema de predicción de la demanda de electricidad es de actualidad; se encuentra que: primero, la mayor parte de las investigaciones es realizada utilizando redes neuronales tipo perceptrón multicapa; otros tipos de redes neuronales son poco explorados, o no se han reportado experiencias en la literatura citada. Segundo, para la mayoría de las series, existen pocos estudios que permitan realizar una comparación clara entre modelos; más aún, existe muy poca información y una gran variedad de casos de aplicación, lo que no permite concluir sobre cuales tipos de modelos podrían ser más adecuados para pronosticar este tipo de series de tiempo. Tercero, la mayoría de los estudios están concentrados en el pronóstico de series diarias u horarias; existen muy pocas experiencias reportadas para series mensuales.

5. MODELOS Y TÉCNICAS DE PRONÓSTICO

A continuación se presenta una revisión de los principales estudios sobre la predicción de la demanda en el ámbito internacional y nacional.

5.1 Estudios en el ámbito internacional

Una gran cantidad de modelos han sido estudiados en la comunidad internacional y se han aplicado a diferentes series de demanda de acuerdo a la necesidad de cada país. Estos métodos se pueden clasificar a grandes rasgos en tres grupos [11, 24]:

El primer grupo se basa en modelos estadísticos (regresión, series de tiempo y/o econométricos), los cuales modelan la serie de demanda en función sus valores pasados (modelos univariados) o en función de algunas variables exógenas como el tiempo o factores socio-económicos.

Tabla 2. Artículos más citados

Table 2. Mostcitedpapers

	Artículo	Citaciones
[18]	Senjyu, T.;Takara, H.;Uezato, K.;Funabashi, T. (2002). One-hour-ahead load forecasting using neural network. <i>IEEE Transactions on Power Systems</i> , 17, 1, 113 – 118	86
[1]	Pai, P.; Hong, W. (2005). Forecasting regional electricity load based on recurrent support vector machines with genetic algorithms. <i>Electric Power Systems Research</i> , 74, 3, 417-425	67
[19]	Ediger, V.;Tatlidil, H. (2002). Forecasting the primary energy demand in turkey and analysis of cyclic patterns. <i>Energy Conversion and Management</i> , 43(4), 473-487.	43
[20]	Al-Saba, T; El-Amin, I. (1999). Artificial neural networks as applied to long-term demand forecasting. <i>Artificial Intelligence in Engineering</i> , 13(2), 189-197.	39
[21]	Yalcinoz, T.;Eminoglu, U. (2005). Short term and medium term power distribution load forecasting by neural networks. <i>Energy Conversion and Management</i> , 46, 9-10, 1393-1405	28
[22]	Beenstock, M.;Goldin, E.;Nabot, D. (1999). The demand for electricity in Israel. <i>Energy Economics</i> , 21(2), 168-183.	28
[23]	Taylor, J.; de Menezes, L.;McSharry, P. (2006). A comparison of univariate methods for forecasting electricity demand up to a day ahead. <i>International Journal of Forecasting</i> , 22, 1, 1-16	25

Algunos modelos de este grupo se han aplicado a la serie mensual de Arabia Saudita [25], de Chile [26], serie anual de demanda de Ciprés [17]. El segundo grupo reúne los modelos basados en inteligencia artificial. Esta técnica ha sido usada en los últimos años y se han elaborado estudios donde se comparan los resultados con métodos tradicionales como el caso de Taylor, et al [23], en el cual pronostican la serie horaria de demanda de Rio de Janeiro, Inglaterra y Gales mediante un modelo de redes neuronales artificiales y comparan los resultados con modelos estadísticos (ARIMA,

Suavizado exponencial, componentes principales). Dentro de las técnicas usadas se encuentran las redes neuronales artificiales [20, 27, 28, 29], modelos de neuro – difusos y modelos híbridos (1, 13, 27, 30). El tercer grupo son modelos empíricos que dependen del juicio y la intuición humana.

En la Tabla 3 se muestran algunos estudios representativos donde se especifica la escala de tiempo de la serie y el modelo usado para pronóstico de demanda en diferentes países.

Tabla3. Estudios representativos de pronóstico de demanda
Table 3. Representative studies about demand forecasting

Estudio	Serie	País	Modelo	Datos
[33]Abdel-Aal, Al-Garni, A. y Al-Nassar (1997)	Mensual	Arabia Saudita	Redes abductivas	Parámetros climáticos e indicadores económicos y demográficos.
[34]Abdel-Aal (2008).	Mensual	Arabia Saudita	Redes abductivas Redes neuronales (Univariado)	
[20]Al-Saba y El-Amin, I. (1999)	Anual (1981 - 1996)	Arabia Saudita	Redes neuronales artificiales (ANN)	Producción de petróleo, clima, población.
[38] Hippert, Bunn y Souza (2005)	Horaria (1996 - 1997)	Brasil	Redes neuronales	
[13]Velasco, Pacheco, Ribeiro y de Souza (2004)	Horaria (1996 - 1998)	Brasil	Modelo híbrido neuro - difuso HNFB (Hierarchical Neuro-Fuzzy BSP (Binary Space Partitioning))	Temperatura, índice de comodidad y el perfil de consumo. Estación del año Companhia Paulista de Força e Luz (São Paulo Light and PowerCompany) in Campinas, and the LIGHT Company, in Río de Janeiro
[23]Taylor, de Menezes y McSharry (2006)	Horaria Media -hora	Brasil, Inglaterra y Gales	ARMA de doble estacionalidad. Suavizamiento exponencial para doble estacionalidad. Redes neuronales ANN. Modelo de regresión con componentes principales PCA	
[26]Benavente, Galetovic, Sanhueza y Serra (2005).	Mensual (1995 - 2001)	Chile	Variables rezagadas y datos panel	
[35]Zhou, Ang, y Poh (2006).	Anual - Trimestral (1981 - 2002)	China	trigonometric grey prediction (traditional grey model GM(1,1) with the trigonometricresidual modification technique)	
[17]Egelioglu, Mohamad y Guven (2001)	Anual (1988 - 1997)	Ciprés	Regresión múltiple	Precio de la electricidad, número de consumidores y turistas.
[36]Chaveza, Bernata y Coallab (1999).	Mensual (1980 - 1996)	España	ARIMA	
[37] Harris y Liu (1993)	Mensual (1969 - 1990)	Estados Unidos	Funciones de transferencia	Clima, precios, ingresos.
[39] Mirasgedis, Sarafidis, Georgopoulou, Lalas, Moschovits, Karagiannisy Papakonstantinou (2006)	Diario y mensual	Grecia	Regresión múltiple	Variables climáticas
[40] Tserkezos (1992)	Mensual Trimestral	Grecia	Funciones de transferencia	Ingresos, temperatura, precios.
[41] Azadeh, Ghaderiy Sohrabkhani(2007)	Mensual	Irán	Integración de ANN (MLP - percepción multi-cap), series de tiempo y ANOVA.	20 años de historia.
[27] Azadeh, Ghaderi, Tarverdian y Saberi (2007)	Anual (1975 - 2005)	Irán	ANN y algoritmos genéticos	Precio de la electricidad, IVA, numero de consumidores, consumo.
[22] Beenstock, Goldin y Nabot (1999)	Trimestral	Israel	Regresión dinámica, Cointegración	
[42] Bianco, Manca y Nardini (2009).	Anual (1970 - 2007)	Italia	Regresión lineal	PIB, población
[28] Senjyu, Mandal, Uezatoy Funabashi(2004)	Horaria	Japón	Redes neuronales Concepto de día similar	Temperatura
[18] Senjyu, Takara, Uezato y Funabashi (2002)	Horaria	Japón	Redes neuronales Concepto de día similar	Temperatura
[43] Nasr, Badr y Dibeh (2000).	(1993 - 1997)	Líbano	Cointegración	Producto interno bruto (PIB), total importaciones
[44] Saab, Badr y Nasr (2001).	Mensual (1970 - 1999)	Líbano	AR, ARIMA y filtro pasa alta.	
[45] Mohamed y Bodger (2005).	Anual (1965 - 1999)	Nueva Zelanda	Regresión lineal múltiple	PIB, precio promedio de electricidad y población, exportaciones
[46] Pedregal y Traperó (2009).	Horaria y Mensual	Reino Unido	Modelo de componentes no observables	
[29] Ghiassi, Zimbray Saidane (2006)	Mensual (1982 - 1997)	Taiwán	Redes neuronales artificiales dinámicas (DAN2)	Clima. Se predice mensual, trimestral y anual.
[1] Pai y Hong (2005)	Anual (1981 - 2000)	Taiwán	Support vector machines (SVMs) y Algoritmos genéticos - RSVMG (recurrentsupport vector machines)	
[47] Akay y Atak (2007)	Anual (1970 - 2004)	Turquía	Grey prediction with rolling mechanism	
[19] Edigery Tatlidil (2002).	Anual (1950 - 1999)	Turquía	Regresión, Análisis de ciclos y aplicación del patrón cíclico	
[48] Hamzaçebi (2007)	Anual (1970 - 2004)	Turquía	Redes neuronales ANN	
[21] Yalcinoz y Eminoglu (2005)	Diaria Mensual	Turquía	Redes neuronales	Temperatura
[49] Al-Hamadi y Soliman (2005)	Horaria - Diaria		Regresión lineal simple - múltiple	Correlación de del comportamiento de la demanda en el corto plazo y crecimiento anual.

5.2 Estudios en el ámbito Colombiano

En Colombia, la UPME que es la entidad encargada de realizar la planeación del sistema, elabora un pronóstico de la demanda de energía mensual y anual del país, sin embargo, este modelo, a pesar de ser el oficial, no se conoce públicamente; por lo cual quedan grandes interrogantes en cuanto a la forma de aplicación de las metodologías y los resultados obtenidos. Adicionalmente, en la literatura científica hay muy poca información relevante, con lo cual no se pueden tener conclusiones contundentes que permitan

determinar cuál es el mejor modelo a seguir de acuerdo con el pronóstico requerido.

Dentro de la literatura revisada, en Colombia se ha utilizado principalmente modelos ARIMA para el pronóstico de la demanda de energía [9, 11, 31], los modelos de inteligencia artificial como redes neuronales (perceptrón multicapa) o lógica difusa han sido poco aplicados [6, 32]. Estos estudios son realizados para escalas mensual y horaria, y considerando, en algunos casos, variables explicativas (ver Tabla 4).

Tabla 4. Estudios de pronóstico de demanda para el caso colombiano
Table 4. Studies about demand forecasting in the Colombian case

Estudio	Serie	Modelo	Variables explicativas
[11] Barrientos, Olaya y González (2007).	Horaria (2001:01 - 2004:11)	Funciones Spline ARIMA (Modelo para cada hora del día)	Hora, día, mes
[31] Castaño (2007).	Horaria	ARIMA con intervenciones	
[16] Franco, Velásquez y Olaya (2008).	Mensual	Modelo de componentes no observables	
[6] Medina y García (2005).	Mensual (1999 - 2004)	Sistemas de inferencia borroso adaptativo – ANFIS Perceptron multicapa Componentes principales	Tarifa promedio de energía, instalaciones domiciliarias de gas, consumo de ACPM, consumo de gas natural, PIB, etc.
[9] Murillo, Trejos y Carvajal(2003).	Horaria (2001:01 - 2001:12)	ARIMA	
[51] Sarmiento y Villa (2008)	Horaria	Perceptron multicapa (MLP)	
[7] Valencia, Lozano y Moreno (2007)	Horaria	Promedios móviles	Filtros por tipo de día
[32] Velásquez, Franco y García (2009).	Mensual	ARIMA, Perceptron multicapa, Red neuronal autorregresiva	

6. DIFICULTADES EN EL PRONÓSTICO DE LA DEMANDA

El pronóstico de la serie de demanda es una tarea difícil. Primero, porque las series de demanda son complejas y presentan diferentes niveles de estacionalidad. Segundo, porque hay muchas variables exógenas importantes que deben ser consideradas, especialmente las relacionadas con el clima. Una desviación grande en el pronóstico de demanda puede implicar grandes costos de operación, por lo cual se debe tener especial cuidado con el uso de los modelos [24].

En las siguientes subsecciones se exponen las principales dificultades que se han encontrado los expertos relacionadas con el proceso de pronóstico, selección de variables influyentes y uso de los modelos.

6.1 Proceso de pronóstico y variables influyentes

Los mercados eléctricos son complejos debido al alto número de factores físicos, tecnológicos y sociales

que influyen en su comportamiento. Las variables físicas como las condiciones climáticas tienen un comportamiento poco predecible en el mediano y largo plazo, al igual que los cambios tecnológicos y sociales como innovaciones en la generación de electricidad o los cambios en los patrones de consumo [3].

En áreas de rápido crecimiento, una dificultad para el pronóstico de la demanda es que la base de datos es corta e insuficiente, no se tiene experiencia con la cual se pueda comparar y las técnicas de predicción son incapaces de modelar adecuadamente factores relacionados con los ciclos y los eventos dinámicos tales como efectos calendario o cambios de temperatura. Es necesario involucrar el conocimiento de los expertos y los modelos matemáticos para realizar un buen pronóstico [50].

Es importante el conocimiento de eventos futuros que puedan afectar el pronóstico de la demanda ya que se pueden realizar intervenciones para mejorar la precisión del modelo; sin embargo, intervenir los modelos es difícil ya que los cambios deben

ser justificados a partir de apreciaciones e hipótesis sobre eventos futuros, situaciones similares en el pasado, el comportamiento esperado de los factores determinantes de los precios y su influencia relativa.

Es necesario contar con herramientas que permitan analizar la información histórica para validar hipótesis sobre las condiciones del mercado y para construir pronósticos usándolas. Además, es importante validar si los ajustes basados en la experiencia son de valor para mejorar la precisión de los pronósticos.

Los pronósticos basados en juicios son más creíbles que aquellos basados en sofisticados modelos matemáticos [52]; sin embargo, la calidad del pronóstico se ve afectada por el hecho de que no se basa en un proceso sistemático de razonamiento, tal que ellos no son fácilmente defendibles, argumentables y sustentables en las evidencias, y resulta difícil documentar cómo fueron obtenidas las predicciones. Por esta razón, no es posible realizar procesos de realimentación y revisión con el ánimo de mejorar las prácticas y corregir las desviaciones y errores sistemáticos.

Las desviaciones y los errores sistemáticos degradan ostensiblemente la precisión y la calidad de los pronósticos basados en juicios. Las técnicas de modelado matemático ofrecen a los pronosticadores modelos sofisticados capaces de manejar cantidades considerables de información; pero en esta aproximación es difícil incorporar el conocimiento subjetivo, usualmente disponible a los pronosticadores [3].

6.2 Uso de los modelos

El uso de modelos no lineales para el estudio del pronóstico de la demanda aún no ha sido completamente estudiado, ya que no se ha agotado la lista de los modelos posibles para emplearse.

Velásquez et al [3] en su estudio sobre pronóstico de precios de electricidad, menciona algunos problemas teóricos, metodológicos y empíricos sobre el uso de modelos no lineales, los cuales son válidos para el pronóstico de la demanda. Estos problemas se listan a continuación:

- No existen razones empíricas, metodológicas o teóricas para preferir un modelo específico entre varias alternativas.
- Falta claridad sobre cuáles son los procedimientos más adecuados para la estimación y la prueba de cada modelo particular.

- No hay concordancia en cómo seleccionar el modelo final cuando se consideran varios alternativos; ya que existen muchas críticas en el uso de criterios basados en alguna medida de error.
- Es confuso cuándo y cómo transformar los datos antes del modelado.
- Es difícil incorporar información cualitativa, subjetiva y contextual en los pronósticos.

7. CONCLUSIONES

El pronóstico de la demanda es un insumo importante para la operación, planeación y expansión de los sistemas eléctricos de potencia; ya que puede ser un factor determinante para la toma de decisiones en el mercado eléctrico.

Las características principales de la serie de demanda son la tendencia, estacionalidad, ciclos y la irregularidad, además dicha serie tiene una fuerte influencia de variables económicas y climáticas.

La literatura analiza distintos casos de los cuales no se pueden obtener conclusiones generales, es decir, presenta diferentes tipos de modelos para diferentes series y escalas de tiempo; adicionalmente, algunos modelos involucran variables exógenas que hacen más complejo el mismo modelo e involucran los errores asociados a los pronósticos de estas variables, agregando más incertidumbre en los resultados del modelo.

No hay una revisión completa de la literatura respecto al tema de predicción del consumo de energía, aún hay modelos sin explorar que se pueden aplicar a dicho tópico.

No hay un estudio sistemático y ordenado respecto a cuáles modelos son mejores. Para el caso colombiano, no hay un estudio consistente donde se indique cuál o cuáles modelos son los mejores de acuerdo con el pronóstico requerido. Más aún, existe una amplia variedad de modelos no lineales que aun no han sido estudiados.

REFERENCIAS

- [1] PAI, P.; HONG, W. (2005). Forecasting regional electricity load based on recurrent support vector machines with genetic algorithms. *Electric Power Systems Research*, 74(3), 417–425.

- [2] BUNN, D.W.; FARMER, E. D. (1985). Comparative models for electrical load forecasting. New York: John Wiley.
- [3] VELÁSQUEZ, J.D.; DYNER, I.; SOUZA, R.C. (2007). ¿Porqué es tan difícil obtener buenos pronósticos de los precios de la electricidad en mercados competitivos? Cuadernos de Administración, 20, 34, 259 – 282.
- [4] BASTIDAS, L.M.; MONTOYA, S.F.; VELÁSQUEZ, J.D. (2008). ¿Hacia dónde irán los sectores eléctricos de los países de la región Andina? Tendencias posibles. Cuadernos de Administración, 21(35), 307–325.
- [5] GUTIÉRREZ, E. (2003). La demanda residencial de energía eléctrica en la Comunidad Autónoma de Andalucía: un análisis cuantitativo. Tesis de Doctorado. Facultad de Ciencias Económicas y empresariales, Universidad de Sevilla.
- [6] MEDINA, S.; GARCÍA, J. (2005). Predicción de demanda de energía en Colombia mediante un sistema de inferencia difuso neuronal. Revista Energética, 33, 15–24.
- [7] VALENCIA, A.L.; LOZANO, C.A.; MORENO, C.A. (2007) Modelo de promedios móviles para el pronóstico horario de potencia y energía eléctrica. El Hombre y la Máquina, 29, 96 - 105
- [8] KHER, L.K.; SIOSHANSI, F.P.; SOROOSHSIAN, S. (1987). Energy demand modelling with noisy input – output variables. TheEnergyJournal, 8, 4, 33 – 49.
- [9] MURILLO, J.; TREJOS, A.; CARVAJAL, P. (2003). Estudio del pronóstico de la demanda de energía eléctrica utilizando modelos de series de tiempo. Scientia et Technica, 23, 37–42.
- [10] UNIDAD DE PLANEACIÓN MINERO ENERGÉTICA. (2010). Proyección de demanda de energía eléctrica y potencia. Revisión, marzo de 2010.
- [11] BARRIENTOS, A.F.; OLAYA, J.; GONZÁLEZ, V.M. (2007). Un modelo spline para el pronóstico de la demanda de energía eléctrica. Revista Colombiana de Estadística, 30(2), 187-202.
- [12] LABYS, W. (1999). Modelling Mineral and Energy Markets. Kluwer Academic Publishers.
- [13] VELLASCO, M.; PACHECO, M.; RIBEIRO, L.; DE SOUZA, F. (2004) Electric load forecasting: evaluating the novel hierarchical neuro-fuzzy BSP model. International Journal of Electrical Power & Energy Systems, 26, 2, 131-142.
- [14] CARRENO, E.M.; SANCHES, T.I.; PADILHA-FELTRIN, A. 2006. Consumer behavior after the Brazilian Power Rationing in 2001. Transmission & Distribution Conference and Exposition: Latin America, 1 – 6.
- [15] GONZALEZ, E.; JARAMILLO, M. A.; CARMONA, D. (2007). Forecasting of the electric energy demand trend and monthly fluctuation with neural networks. Computers & Industrial Engineering, 52, 3, 336-343
- [16] FRANCO, C.J.; VELÁSQUEZ, J.D.; OLAYA, Y. (2008). Caracterización de la demanda mensual de electricidad en Colombia usando un modelo de componentes no observables. Cuadernos de Administración, 21, 36, 221-235.
- [17] EGELIOGLU, F., MOHAMAD, A. Y GUVEN, H. (2001). Economic variables and electricity consumption in northern Cyprus. Energy, 26(4), 355–362.
- [18] SENJYU, T.; TAKARA, H.; UEZATO, K.; FUNABASHI, T. (2002). One-hour-ahead load forecasting using neural network. IEEE Transactions on Power Systems, 17, 1, 113 – 118.
- [19] EDIGER, V.; TATLIDIL, H. (2002). Forecasting the primary energy demand in turkey and analysis of cyclic patterns. Energy Conversion and Management, 43(4), 473–487.
- [20] AL-SABA, T.; EL-AMIN, I. (1999). Artificial neural networks as applied to long-term demand forecasting. Artificial Intelligence in Engineering, 13(2), 189–197.
- [21] YALCINOZ, T.; EMINOGLU, U. (2005). Short term and medium term power distribution load forecasting by neural networks. Energy Conversion and Management, 46, 9-10, 1393-1405.
- [22] BEENSTOCK, M.; GOLDIN, E.; NABOT, D. (1999). The demand for electricity in Israel. Energy Economics, 21(2), 168–183. [23] TAYLOR, J.; DE MENEZES, L.; MCSHARRY, P. (2006). A comparison of univariate methods for forecasting electricity demand up to a day ahead. International Journal of Forecasting, 22, 1, 1-16.
- [24] HIPPERT, H. S.; PEDREIRA, C. E.; Souza, R.C. (2001). Neural Networks for short – term load forecasting: A review and evaluation. IEEE Transactions on Power Systems, 16, 1, 44 – 55.
- [25] ABDEL-AAL, R.; AL-GARNI, A. (1997). Forecasting monthly electric energy consumption in eastern Saudi Arabia using univariate time series analysis. Energy, 22(11), 1059–1069.
- [26] BENAVENTE, J., GALETOVIC, A., SANHUEZA, R. Y SERRA, P. (2005). Estimando la demanda residencial por electricidad en Chile: El consumo es sensible al precio. Cuadernos de Economía, 42, 31–61.
- [27] AZADEH, A., GHADERI, S.F., TARVERDIAN, S. Y SABERI, M. (2007). Integration of artificial neural networks and genetic algorithm to predict electrical energy

consumption. *Applied Mathematics and Computation*, 186(2), 1731-1741.

[28] SENJYU, T., MANDAL, P., UEZATO, K. Y FUNABASHI, T. (2004) Next day load curve forecasting using recurrent neural network structure. *IEE Proceedings-Generation, Transmission and Distribution*, 151(3), 388 – 394.

[29] GHIASSI, M. ZIMBRA, D. Y SAIDANE, H. (2006). Medium term system load forecasting with a dynamic artificial neural network model. *Electric Power Systems Research*, 76(5), 302-316.

[30] MAMLOOK, R.; BADRAN, O.; ABDULHADI, E. (2009). A fuzzy inference model for short-term load forecasting. *Energy Policy*, 37, 4, 1239-1248.

[31] CASTAÑO, E. (2007). Reconstrucción de datos de series de tiempo: una aplicación a la demanda horaria de electricidad. *Revista Colombiana de Estadística*, 30(2), 247–263.

[32] VELÁSQUEZ, J.D.; FRANCO, C.J.; GARCÍA, H.A. (2009). Un modelo no lineal para la predicción de la demanda mensual de la electricidad en Colombia. *Estudios Gerenciales*, 25, 112, 37-54

[33] ABDEL-AAL, R., AL-GARNI, A. Y AL-NASSAR, Y. (1997). Modelling and forecasting monthly electric energy consumption in eastern Saudi Arabia using abductive networks. *Energy*, 22(9), 911–921.

[34] ABDEL-AAL, R.E. (2008). Univariate modeling and forecasting of monthly energy demand time series using abductive and neural networks *Computers & Industrial Engineering*, 54(4), 903-917

[35] ZHOU, P., ANG, B.W. Y POH, K.L. (2006). A trigonometric grey prediction approach to forecasting electricity demand. *Energy*, 31(14), 2839-2847.

[36] CHAVEZA, S.G., BERNATA, J.X. Y COALLAB, H.L. (1999). Forecasting of energy production and consumption in Asturias (northern Spain). *Energy*, 24(3), 183–198.

[37] HARRIS, J. Y LIU, L.M. (1993). Dynamic structural analysis and forecasting of residential electricity consumption. *International Journal of Forecasting*, 9(4), 437–455.

[38] HIPPERT, H.S., BUNN, D.W. Y SOUZA, R.C. (2005). Large neural networks for electricity load forecasting: Are they overfitted? *International Journal of Forecasting*, 21(3), 425-434.

[39] MIRASGEDIS, S.; SARAFIDIS, Y.; GEORGOPOULOU, E.; LALAS, D.; MOSCHOVITS, M., KARAGIANNIS, F.; PPAKONSTANTINOY, D. (2006). Models for mid-term electricity demand forecasting incorporating weather influences. *Energy*, 31(2–3), 208–227.

[40] TSERKEZOS, E. (1992). Forecasting residential electricity consumption in Greece using monthly and quarterly data. *Energy Economics*, 14(3), 226–232.

[41] AZADEH, A.; GHADERI, S.F. y Sohrabkhani, S. (2007). Forecasting electrical consumption by integration of Neural Network, time series and ANOVA. *Applied Mathematics and Computation*, 186(2), 15 1753-1761.

[42] BIANCO, V.; MANCA, O.; NARDINI, S. (2009). Electricity consumption forecasting in Italy using linear regression models. *Energy*, 34, 9, 1413-1421.

[43] NASR, G.; BADR, E.; DIBEH, G. (2000). Econometric modelling of electricity consumption in post-war Lebanon. *Energy Economics*, 22(6), 627–640.

[44] SAAB, S., BADR, E. Y NASR, G. (2001). Univariate modelling and forecasting of energy consumption: the case of electricity in Lebanon. *Energy*, 26(1), 1–14.

[45] MOHAMED, Z.; BODGER, P. (2005). Forecasting electricity consumption in New Zealand using economic and demographic variables. *Energy*, 30(10), 1833–1843.

[46] PEDREGAL, D.J. Y TRAPER, J.R. (2009). Mid-term hourly electricity forecasting based on a multi-rate approach *Energy Conversion and Management*, doi:10.1016/j.enconman.2009.08.028.

[47] AKAY, D. Y ATAK, M. (2007). Grey prediction with rolling mechanism for electricity demand forecasting of Turkey. *Energy*, 32(9), 1670-1675.

[48] HAMZAÇEBI, C., (2007). Forecasting of Turkey's net electricity energy consumption on sectoral bases. *Energy Policy*, 35(3), 2009-2016.

[49] AL-HAMADI, H.M. Y SOLIMAN, S.A. (2005). Long-term/mid-term electric load forecasting based on short-term correlation and annual growth. *Electric Power Systems Research*, 74(3), 353-361.

[50] KANDIL, M.S.; EI-DEBEIKY, S.M.; HASANIEN, N.E. (2002). L. *IEEE Transactions on Power Systems*, 17, 2, 491 – 496.

[51] SARMIENTO, H.; VILLA, W. (2008). Inteligencia artificial en pronóstico de demanda de energía eléctrica: una aplicación en optimización de recursos energéticos. *Revista Colombiana de Tecnologías Avanzadas*, 2, 12, 94 – 100.

[52] BUNN, D.; WRIGHT, G. (1991). Interaction of Judgmental and Statistical Forecasting Methods: Issues & Analysis. *Management Science*, 37(5), 501-518, DOI: 10.1287/mnsc.37.5.501.