

ESTADO DEL ARTE EN LA ESTIMACIÓN DE LOS PRECIOS DE LA ENERGÍA EN EL MERCADO SPOT

Sergio Botero B. D.Sc. & Jovan A. Cano C. M.Sc.
Facultad de Minas
Universidad Nacional de Colombia - Sede Medellín
sbotero@unalmed.edu.co, jcano@isa.com.co

Recibido para evaluación: 31 de Octubre de 2006
Aceptación: 6 de Noviembre de 2006
Entrega de versión final: 30 de Noviembre de 2006

Resumen

A partir de la desregulación de los mercados de energía en el mundo diferentes técnicas de predicción de los precios de la energía en el mercado spot (corto plazo) han sido desarrolladas; este artículo identifica y compara los principales métodos de predicción empleados en Colombia y algunos otros a nivel internacional. Con lo anterior es posible determinar el estado del conocimiento en el tema específico y así indagar en el desarrollo de nuevas técnicas de estimación que verdaderamente aporten a la solución del problema. El horizonte de predicción es algo que debe tenerse presente en la revisión de las diferentes técnicas, dado que de éste depende la magnitud del modelo final de estimación y el tipo de tratamiento que se da a cada serie de tiempo.

Palabras Claves: Precio de la energía, bolsa de energía, Mercado Spot, Predicción, Series de tiempo, Redes Neuronales, Mercados de Energía.

Abstract

Since the start energy markets deregulation in the world, several spot market (short term) price prediction methods have been developed; this article identifies and compares the main methods of prediction used in Colombia and other international markets. With this review it is possible to determine the state of the knowledge in the specific subject and then to look for the development of new forecasting techniques that can contribute to the solution of this problem. The prediction horizon is something that must be taken into account in the review of the several techniques, given that both the magnitude of the final model of estimation, and the time-series treatment type, depend on this horizon.

Key Words: Energy market price, Energy exchange, spot market, Prediction, time series, neuronal grids, Energy Markets

1. INTRODUCCIÓN

La predicción de los precios de la energía en las diferentes bolsas del mundo, a menudo emplea técnicas de predicción similares como son: los modelos ARIMA, GARCH, Redes Neuronales, Método de Montecarlo, Análisis de volatilidad, etc. (Guang Li, 2005) Aunque su aplicación específica se encuentra delimitada por la bolsa de energía sobre la cual se pretende dar señales de pronóstico. Lo anterior es debido a la particularidad en las reglas de cada una de las bolsas de energía; las cuales pueden diferir incluso desde el principio económico desde el cual fueron concebidas; es así como se encuentran bolsas donde la formación de los precios se concibe a partir de los costos de producción de la energía, ofertas de los agentes, tipo de combustible, precios nodales, restricciones del sistema, etc. (Stoft, 2002)

Colombia no ha sido la excepción y desde la entrada en operación de la misma (junio de 1995) han sido desarrolladas diferentes técnicas con horizontes de predicción diario, mensual y de largo plazo, que en algunos casos han sido implementadas en programas de simulación como es el caso de la Capacitación en Comercialización a través de Micromundos (Smith, 2000).

2. MODELOS DE ESTIMACIÓN EMPLEADOS EN COLOMBIA

Los pronósticos se establecen con el fin de orientar las decisiones en muchas áreas del mundo. Estos se relacionan en forma inextricable con la construcción de modelos estadísticos. Para pronosticar una variable se debe construir un modelo de ella y estimar los parámetros de ese modelo, usando datos históricos observados, es decir, da una caracterización estadística de los enlaces entre el presente y el pasado. En forma simple se usa el modelo estimado del pronóstico para extrapolar los datos observados. (Diebold, 1998)

Las técnicas de predicción empleadas históricamente en la predicción de los precios de la energía en la bolsa de Colombia son: modelos ARIMA, series de tiempo, redes neuronales, método de Montecarlo, curvas de oferta y demanda y métodos de regresión.

2.1. Redes Neuronales

Las variables empleadas en este trabajo fueron: precio promedio mensual de la energía en bolsa, embalse ofertable, aportes agregados, demanda real de energía y variables macroclimáticas como: Temperaturas y anomalías de temperatura sobre la superficie del océano pacífico en la región niño 4 y 3-4. A partir de las cuales se realizaron análisis de correlación donde la hipótesis de que $\rho=0$ se rechaza cuando:

$$|t| = \left| \frac{\rho}{\sqrt{1-\rho^2}} \right| \sqrt{n-2} \geq t_{\alpha/2; n-2}$$

Donde ρ es el coeficiente de correlación de los datos, n es el número de datos, $t_{\alpha/2; n-2}$ es el valor tabulado para un valor de confiabilidad de $\alpha/2$ y $n-2$ grados de libertad. (Pulgarín, 2001)

La estructura de la red neuronal empleada para la estimación consiste en una red tipo perceptron multicapa, una capa de entrada, una capa de salida y una capa oculta. La comparación de los resultados se presenta en la Figura 1.




Figura 1 Comparación de resultados precio de la energía en bolsa vs red neuronal

El análisis estadístico de los resultados se presenta en la Tabla 1.

Tabla 1 Análisis de errores

Estadístico	Entrenamiento	Verificación
Coefficiente de correlación	0.99998	0.9995
Error Cuadrático Medio	215.6	1422.43
Error Absoluto	162.07	1224.84
Media de los Datos	40414.6	35968.5
Desviación Estándar de los Datos	49364.8	31698.1
Media del Error	114.89	-714.94
Desviación Estándar del Error	219.28	1231.64
Radio de la Desviación Estándar	0.00445	0.0398

2.2. Series de tiempo - Modelo de intervención

Las intervenciones se modelan por medio de variables indicadoras de los intervalos o de los periodos, en los cuales la intervención afecta la serie o por medio de funciones del tiempo que explican la variación que producen en la serie. (Cano, 2004)

La representación funcional de este tipo de modelos puede tomar en cada etapa de intervención, formas funcionales similares a las estudiadas e incluso tener intercepto global o independiente, de la siguiente forma:

$$Z_t = \beta_{00} I_0 + \beta_{01} P_0 + \sum_{i=0}^n \delta_{0i} I_{0_mes_{it}} + \beta_{10} I_1 + \beta_{11} P_1$$

$$..... + \sum_{i=0}^n \delta_{1i} I_{1_mes_{it}} + \beta_{20} I_2 + \beta_{21} P_2$$

$$..... + \sum_{i=0}^n \delta_{ji} I_{j_mes_{it}} + \beta_{j0} I_j + \beta_{j1} P_j + U_t$$

Donde:

Z_t : variable aleatoria.

δ_{ji} : parámetros de cada estación y en cada etapa de intervención.

$I_{i_mes_{it}}$:estaciones en cada etapa de intervención.

β_{ji} : pendientes de cada etapa de intervención.

U_t : variable aleatoria de residuales

e_t : ruido blanco.

El modelo anterior combina análisis de regresión, identificación de estacionalidades, inclusión de intervenciones del mercado y autoregresión sobre los errores de la primera estimación.

La comparación de los resultados se presenta en la Figura 2.




Figura 2 Comparación de resultados precio de la energía en bolsa vs modelo de intervención

El análisis estadístico de los resultados se presenta en la Tabla 2.

Tabla 2 Estadísticos de prueba residuales

Estadísticos de Prueba	Modelo de intervención
media	0.0
varza	0.0
des	0.0
mediana	0.0
asimetría	0.23
curtosis	-0.72
wnormal	0.97
vpnorm	0.68

2.3. Micromundos

El Precio esperado, se estima con un modelo basado en las expectativas que se puedan tener del sistema y del estado del mismo. El precio esperado lo afectan algunas variables y expectativas futuras como se muestra en la Figura 3. (Smith, 2000).

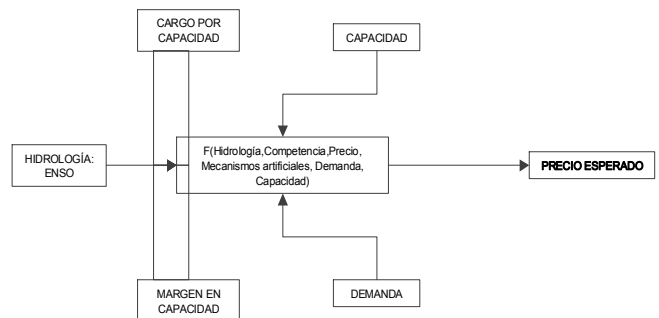


Figura 3 Esquema funcional de formación del precio esperado

El cálculo período a período con el cual se calculo el precio esperado, P_e , se realiza de la siguiente manera:

$$P_e^k = PM(t^k) * \prod_i F_i^k$$

Donde:

- P_e^k : precio esperado para la tecnología k.
- $PM(t^k)$: promedio móvil del precio de t meses anteriores, t depende de k.
- F_i^k : factores de influencia sobre el precio crítico que depende de las variables que influyen en el sistema.
- i : factores de influencia, = cargo por capacidad, demanda, capacidad del sistema, hidrología o margen.
- k : tecnología, = hidráulica con embalse, hidráulica filo de agua, térmica a carbón o térmica a gas.

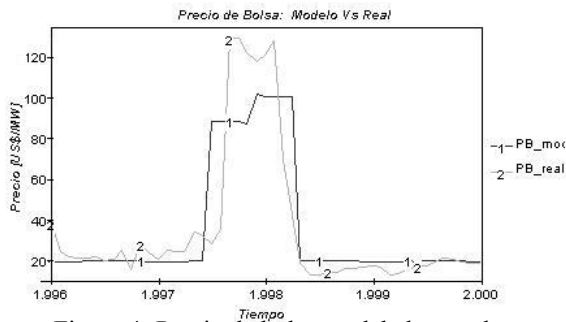


Figura 4 Precio de bolsa modelado y real

El análisis estadístico de los resultados se presenta en la Figura 4.

Tabla 3 Cuantificación del error del modelo Vs real

Estadístico	Precio Bolsa
R	0.83
RMSE	0.39
ABSE	11.29

2.4 Redes neuronales (valle)

El modelo de pronóstico emplea los datos históricos del año 2002 para la construcción del modelo y los datos del año 2003 para su validación. Las variables empleadas fueron : demanda comercial, generación ideal, precio en bolsa, aportes ríos medios históricos, aportes ríos (volumen), aportes ríos (energía), disponibilidad comercial y precio de oferta.

En la Figura 5 se presenta el diagrama esquemático del modelo de pronóstico de precio implementado en Matlab.

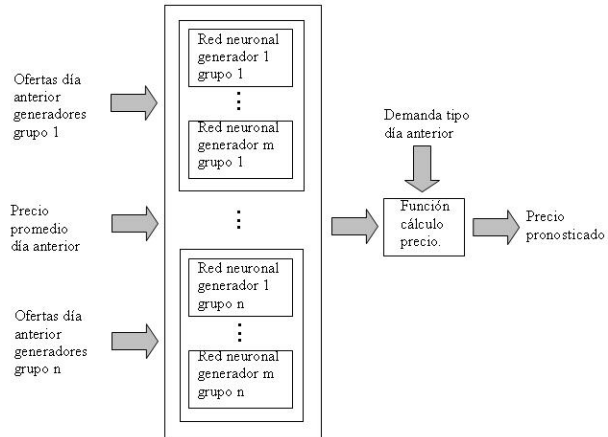


Figura 5 Diagrama esquemático modelo pronóstico de precio

La metodología empleada en la construcción del modelo presenta los siguientes pasos :

Selección de agentes generadores : se seleccionaron sólo los que presentaron mayor participación en el despacho por orden de mérito durante el año 2002.

Diseño de las redes neuronales : se construyó una red neuronal para cada uno de los generadores identificados en el ítem anterior.

Entrenamiento de las redes neuronales : fue realizado con datos del 2002.

Validación del modelo : los resultados de las redes neuronales anteriores alimenta una función final que realiza el cálculo final de los precios de la energía en bolsa.

Tabla 4 Porcentajes de error del precio en el mercado por tipo de día

Tipo de día	# de datos	% de error
Día laboral	216	6.32
Sábado	48	8.19
Domingo	48	9.56
Festivo	24	9.22
Total	336	7.26

2.5 Análisis de resultados

De las figuras de los modelos anteriores vs los precios reales, se tiene que las diferentes metodologías presentan aproximaciones valiosas, especialmente en el seguimiento de los valores altos que en algunos casos obligó la intervención del mercado. (UPME, 2002)

El análisis de errores aunque diferente en todos los casos muestra para el modelo de redes neuronales una media diferente a cero (-714.94), lo cual indica que aún existe información pendiente por incluir en el modelo de estimación, por lo demás se conoce su desviación estándar y el radio de desviación, lo cual es una condición necesaria para el análisis de errores.

Para el caso del modelo de intervención, se tiene una media del error igual a cero (0), desviación estándar conocida y probabilidad de distribución normal cercana a 1, lo cual indica que los errores se comportan como ruido blanco y por tanto se tiene un modelo de estimación adecuado.

Para micromundos, observa la cuantificación del error, por medio del coeficiente de correlación -R-, del error medio cuadrático -RMSE- y del error absoluto -ABSE-. Se observa que el coeficiente de correlación es mayor que 0.6, lo que indica una adecuada representación del precio. Además presenta valores de error medio cuadrático y error absoluto inferiores a los del modelo de redes neuronales.

Los resultados de algunos de los trabajos más representativos en la predicción de los precios en la bolsa de energía de Colombia, permite además de establecer el estado del arte en el tema, identificar el grado de precisión y el intervalo de pronóstico de cada una de las herramientas con lo cual es posible decidir cual metodología emplear en casos específicos de aplicación como compras y ventas de energía, estudios de expansión, instalación de nuevos proyectos de generación, etc. En últimas maximizar sus beneficios. (García, 2005)

3 MODELOS DE ESTIMACIÓN EMPLEADOS A NIVEL INTERNACIONAL

Las aplicaciones existentes para la predicción de los precios de la energía en bolsa varían de acuerdo al horizonte de pronóstico : corto, mediano y largo plazo.

A partir de los resultados de los modelos indicados los agentes del mercado deciden reducir o

incrementar su generación, comprar o vender en el mercado spot (corto plazo) o en el mercado de futuros en aras de maximizar sus beneficios. (Guang Li, 2005).

3.1 Modelo ARIMA (Contreras, 2003)

Los procesos ARIMA son una clase de procesos estocásticos usados para analizar series de tiempo. La metodología empleada para el desarrollo del presente modelo emplea los siguientes pasos:

0. Un tipo de modelo es formulado asumiendo una determinada hipótesis.

En este paso se identifican las principales características de la serie de tiempo como : frecuencia, picos, media, varianza, estacionalidades, etc.

1. El modelo es identificado a partir de los datos históricos.

En este paso se realiza la formulación del modelo ARIMA y se realizan los cálculos en el software de aplicación hasta el punto de obtener el que mejor se ajuste a los datos bajo estudio.

2. Se estiman los parámetros del modelo.

En este paso, se extraen los parámetros del modelo que son significativos a partir de los estadísticos de prueba definidos.

3. Si la hipótesis del modelo es validada, se pasa al paso 4, en caso contrario se regresa al paso 1 para refinar el modelo.

En este paso se realiza el diagnóstico del modelo a partir de la definición realizada en el paso 0 y se toma la decisión si el modelo se encuentra listo para predecir o es necesario ajustarlo.

4. El modelo está listo para predecir.

En este paso se realizan las predicciones de los precios que serán empleados para la verificación de resultados.

Como resultado de los 5 pasos anteriores, el modelo obtenido para la bolsa de energía de España para el año 2000 se presenta en la siguiente expresión:

$$\begin{aligned}
 & (1 - \phi_1 B^1 - \phi_2 B^2 - \phi_3 B^3 - \phi_4 B^4 - \phi_5 B^5) \\
 & \times (1 - \phi_{23} B^{23} - \phi_{24} B^{24} - \phi_{47} B^{47} - \phi_{48} B^{48} \\
 & - \phi_{72} B^{72} - \phi_{96} B^{96} - \phi_{120} B^{120} - \phi_{144} B^{144}) \\
 & \times (1 - \phi_{168} B^{168} - \phi_{336} B^{336} - \phi_{504} B^{504}) \log p_t \\
 & = c + (1 - \theta_1 B^1 - \theta_2 B^2) (1 - \theta_{24} B^{24}) \\
 & \times (1 - \theta_{168} B^{168} - \theta_{336} B^{336} - \theta_{504} B^{504}) \varepsilon_t
 \end{aligned}$$

Algunos de los resultados obtenidos para la bolsa de energía de España y el análisis de errores se presentan la Figura 6 y la Tabla 5.




Figura 6 Resultados modelo ARIMA

Tabla 5 Bolsa de energía de España - errores en % modelo ARIMA

Days	1	2	3	4	5	6	7
Mean (%)	4.73	4.13	3.71	6.84	6.09	6.96	3.41

3.2 Modelo GARCH (García, 2005)

Consiste en estimar un modelo ARMA con componentes de error GARCH empleando la aproximación de Box-Jenkins. El modelo ARMA (p,q) incluye componentes autoregresivas y de promedios móviles.

$$y_t = c + \sum_{i=1}^p \phi y_{t-i} + \sum \theta_i \varepsilon_{t-i} + \varepsilon_t$$

La estimación tradicional de los modelos ARMA asume que el error tiene media cero y varianza constante. Para el modelo ARCH la condición de varianza constante no es necesaria (heterocedasticidad). El modelo considera que la varianza depende del tiempo,

$$V(\varepsilon_t | \varepsilon_{t-1}) = h_t ; h_t = c + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2$$

Una extensión del modelo anterior es el modelo GARCH, donde:

$$\varepsilon_t^2 = v_t^2 h_t ; \sigma_t^2 = 1 ; h_t = c + \sum_{i=1}^p \alpha_i h_{t-i} + \sum_{i=1}^q \beta_i \varepsilon_{t-i}^2$$

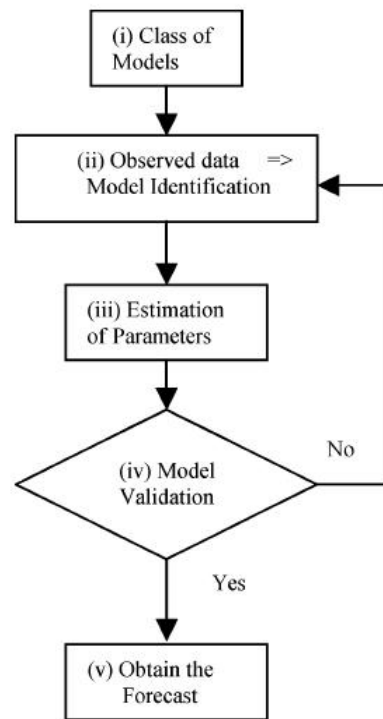


Figura 7 Diagrama de flujo de la metodología empleada para la identificación del modelo

La metodología anterior fue implementada en el software EViews para las bolsas de energía de España y California, algunos de los resultados obtenidos se presentan en la Tabla 6.

Tabla 6 Bolsa de energía de California - errores en % modelos GARCH y ARIMA

	GARCH	GARCH with demand	ARIMA
January	5.76	5.76	8.65
February	5.07	4.19	5.02
March	5.76	5.33	5.71
April	9.14	8.54	13.23
May	11.5	10.58	13.24
June	15.91	15.4	22.26
July	12.27	12.26	15.09
August	14.03	12.36	17.57
September	10.97	9.72	11.78
October	8.1	7.83	9.51
November	5.69	5.43	5.68
December	13.63	13.22	14.38
Average	9.82	9.21	11.88

3.3 Redes Neuronales en cascada (Zang, 2003)

La predicción con redes neuronales, generalmente se divide en tres estados : entrenamiento, predicción y actualización. Una red neuronal inicialmente es entrenada con los datos históricos para hallar la relación entre entrada y salida con medidas de otras variables que igualmente son alimentadas a la entrada; cuando el entrenamiento finaliza se tiene una nueva entrada para la red neuronal como se muestra en la Figura 8.




Figura 8 Estructura en cascada de una red para predicción de precios de bolsa

Es de anotar que el empleo de variables exógenas requiere predecir previamente dichas variables y por tanto se hace necesario el empleo de redes neuronales en cascada como se observa en la Figura 9.




Figura 9 Diagrama esquemático de una red perceptron multicapa

Algunos de los resultados obtenidos para un caso académico y el análisis de errores se presentan la Figura 10 y la Tabla 7.




Figura 10 Resultados modelo RN

Tabla 7 Análisis de errores

Date	July	Aug.	Sep.	Oct.	Nov.	Overall
MAE(\$)	2.81	7.01	4.68	4.14	4.05	4.54
MAPE(%)	6.27	13.4	9.35	7.28	7.7	8.8
MAPE of ISO-NE (%)	10.9	9.68	12.95	7.05	8.2	9.73
# of Days outside CI Coverage (%)	7	17	8	11	8	51
	77	42	73	64	73	66.6

3.4 Análisis de resultados

A pesar de que los resultados de los modelos anteriores no son para un mismo ejercicio de predicción (bolsa, frecuencia, periodos de tiempo, variables, etc.) es posible realizar un primer análisis sobre los porcentajes de error publicados; es así como se observa que el modelo RN propuesto por Zang presenta los valores más bajos de error (4.54% en promedio), seguido por el modelo ARIMA presentado por Contreras con errores del 5% en promedio, finalmente el modelo propuesto por García demuestra como mejora un modelo ARIMA realizando un análisis sobre los residuales (modelo GARCH), logrando disminuir los porcentajes de error del 12% a 9%.

Las diferentes técnicas de predicción empleadas a nivel internacional generalmente parten de métodos estudiados históricamente y sobre los cuales se realizan mejoras aprovechando los nuevos hallazgos introducidos desde diferentes

áreas del conocimiento como son la estadística y la matemática.

Nuevamente se hace relevante tener presente el horizonte de pronóstico que se desea, dado que de este depende la selección de una metodología u otra, además de analizar los errores de cada modelo y cuantificar así el nivel de riesgo al momento de tomar decisiones por parte de un agente del mercado.

4 CONCLUSIONES

Diferentes métodos de predicción han sido desarrollados en torno a los precios de la energía en el mercado spot, los cuales pueden resumirse en análisis de series de tiempo, inteligencia computacional y métodos de simulación.

Investigadores e instituciones en Colombia como Dyner, Smith, Blandón, UPME y MEM coinciden en la identificación de las variables con mayor incidencia en la formación de los precios de la energía en bolsa como lo son las variables de tipo macroclimático, la hidrología, restricciones del sistema, la entrada de nuevos proyectos de generación y expansión, los precios del combustible y las intervenciones del mercado.

A pesar de que la estimación de los precios de la energía en el mercado spot presenta diferentes alternativas estadísticas y/o matemáticas, el empleo de una metodología determinada varía dependiendo de la bolsa específica sobre la cual se decide realizar un estudio de esta naturaleza, dado que al momento de realizar la validación del modelo los datos de una bolsa u otra podrían no ajustarse.

La comparación de resultados de los modelos presentados debe ser revisados de forma cuidadosa por parte del lector dado que las series de tiempo analizadas por cada autor presentan condiciones diferentes de estimación, algunas con más cambios súbitos, otras con promedios móviles, varianzas variables, etc. Un ejercicio interesante sería emplear las diferentes herramientas en un caso específico de predicción, lo cual se escapa al alcance de este artículo.

5 REFERENCIAS

- Stoft, S., 2002. Power System Economics. John Wiley & Sons, INC., Publication, p. 33 - 45
- Diebold, F., 1998. Elements of forecasting. South Western Collegue Publyshing, an ITP Company. Pennsylvania, USA. p. 317
- Pulgarín, A. J., 2001. Tesis de Maestría - Aplicación De Herramientas De Inteligencia Computacional En La Planificación De Recursos. Universidad Nacional de Colombia, Facultad de Minas, Medellín, Colombia. p. 18 - 58
- Smith, R., Dyner I., 2000. Capacitación en Comercialización de Energía en Colombia a Través de Micromundos. Avances en Recursos Hidráulicos N7. p. 62 - 75
- Londoño, S. M., Lozano C. A., Caicedo G., 2003. Pronóstico del precio en el mercado de electricidad Colombiano empleando redes neuronales. Universidad del Valle, p. 1 - 6
- Cano, J., 2004. Tesis de Maestría - Estimación de los precios en la bolsa de energía de Colombia. Universidad Nacional de Colombia, Facultad de Ciencias Humanas, Medellín, Colombia. p. 8 - 100
- Guang, L., Chen-Ching L., Jacques L., Massimo G., Andrea V., 2005. State-of-Art of Electricity Prices Forecasting. CIGRE/IEEE PES, International Symposium, p. 110 - 119
- García, R. C., Contreras J., Akkeren M. V., García J. B., 2005. A GARCH Forecasting Model to Predict Day-Ahead Electricity Prices. IEEE Transactions on Power Systems, vol. 20, No.2, p. 867 - 874
- Zang, L., Luh P. B., Kasiviswanathan K., 2003. Energy Clearing Price Prediction and Confidence Interval Estimation with Cascade Neural Networks. IEEE Transactions on Power Systems, vol.18, No.1, p.99 - 105
- UPME, 2002. Plan de expansión de referencia. Generación Transmisión 2002 - 2001. p. 18-30.
- XM, 2006. Informe mensual del Mercado de Energía Mayorista, Agosto de 2006.