

NOTA TÉCNICA # 005

PROYECCIÓN DE DEMANDA DE ENERGÍA

ELÉCTRICA EN COLOMBIA.

REVISIÓN DE LA METODOLOGÍA

Diciembre de 2014



SUBDIRECCION DE DEMANDA

**Nota Técnica # 005**  
**Proyección de Demanda de Energía Eléctrica en Colombia**  
**Revisión de la Metodología**  
**Diciembre de 2014**

**República de Colombia**  
**Ministerio de Minas y Energía**  
**Unidad de Planeación Minero Energética, UPME**  
**Subdirección de Demanda**

**Revisión**  
**Diciembre 2014**

## PROYECCIÓN DE DEMANDA DE ENERGÍA ELÉCTRICA EN COLOMBIA

### REVISIÓN DE LA METODOLOGÍA

#### Resumen

La proyección de la demanda de energía eléctrica es uno de los pilares fundamentales para la concepción y elaboración de los planes de expansión y transmisión del Sistema Interconectado Nacional (SIN). La modelación identifica las variables que permiten explicar el comportamiento histórico y el futuro de la demanda de energía.

Otro aspecto fundamental es el enfoque de valoración de los errores y sesgos sistemáticos de cada proyección. La mayoría de estudios se rigen por una evaluación de los resultados cualitativos, y en aquellos dónde se cuantifica el análisis optan por el uso de estadísticos simples: MSE, AAE y APE.

Con este objetivo, se combinaron tres modelos que predicen la demanda de energía eléctrica en Colombia, los cuales son modelos multivariados. Los modelos empleados fueron: VAR endógeno y exógeno, y un VEC endógeno con variable exógena. Dichos modelos emplean las variables de demanda de energía eléctrica, PIB total, población y temperatura.

## TABLA DE CONTENIDO

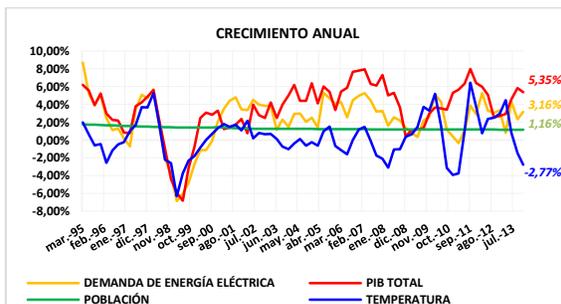
<b>INTRODUCCIÓN .....</b>	<b>5</b>
<b>1. PRESENTACIÓN DEL MODELO .....</b>	<b>5</b>
<b>2. DESCRIPCIÓN DE LA METODOLOGÍA .....</b>	<b>6</b>
2.1 Ecuaciones de Modelos Multivariados para la Proyección de la Demanda de Energía Eléctrica .....	7
2.2 Análisis Comparativo de Proyecciones - Errores y Sesgo Sistemático.....	9
<b>3. RESULTADOS.....</b>	<b>10</b>
3.1 Criterios de Selección de los Modelos .....	11
<b>4. CONCLUSIONES Y RECOMENDACIONES.....</b>	<b>13</b>
<b>REFERENCIAS BIBLIOGRÁFICAS.....</b>	<b>14</b>

## INTRODUCCIÓN

El comportamiento de la demanda de energía eléctrica, depende en general de variables como el comportamiento de la economía, el crecimiento de la población y de factores ambientales como la temperatura. [3], [4] y [7]. Al examinar las series históricas en Colombia, se evidencia un desacople con el PIB como consecuencia de un crecimiento económico soportado en sectores con un bajo consumo de energía eléctrica. Igualmente sugiere una dependencia variable respecto a los cambios de temperatura que muestra comportamientos abruptos de un período a otro.

Se espera que el crecimiento de la demanda de energía eléctrica Colombia se vea afectado además por la dinámica de cambio tecnológico y por los cambios estructurales originados por grandes consumidores – ya sean industriales que autogeneren mayores cantidades, o proyectos mineros o petroleros que demanden cantidades crecientes.

Gráfica 1. Crecimiento anual de las variables del modelo



Fuente: UPME, Base de Datos XM, DANE, IDEAM, 2014.

Para la construcción del modelo de proyección de la demanda de energía eléctrica se emplea la teoría de combinación

de pronósticos y variables predictoras con error, propuesta por [1]. Por otra parte, señala que si los resultados de diferentes modelos pueden ser tratados formalmente como pronósticos de diferentes expertos, entonces su combinación no debería generar ninguna controversia, pues equivaldría a combinar en la predicción distintos aspectos y fuentes de información.

De lo anterior se concluye que, el procedimiento de combinación de pronósticos incide en valores de proyecciones más exactas que los valores de las proyecciones de cada uno de los modelos analizados independientemente.

## 1. PRESENTACIÓN DEL MODELO

Este modelo toma en cuenta las series históricas de demanda de energía eléctrica mensual desde enero de 1991 a mayo de 2014 publicadas por [14] y los datos trimestrales del PIB, población y temperatura de Colombia desde los años 1991 a 2028 publicados por [3], [4] y [7].

La información del PIB se encuentra disponible hasta el cuarto trimestre de 2013 y la de población corresponde a proyecciones hechas por dicha entidad.

El escenario de crecimiento económico UPME corresponde a las proyecciones estimadas por el Ministerio de Hacienda y Crédito Público (MHCP). Según [9], se espera que el crecimiento alcance su potencial en los próximos años y tienda a una tasa cercana a 4,6% en el largo plazo.

## 2. DESCRIPCIÓN DE LA METODOLOGÍA

Partiendo de dicha información se propone un modelo de combinación de pronósticos empleando modelos multivariados como los VAR (modelo de vectores autorregresivos) y los VEC (modelo de vectores de corrección de error), los cuales proponen un sistema de ecuaciones, con tantas ecuaciones como series a analizar o predecir. Así, cada variable es explicada por los retardos de sí misma y por los retardos de las demás variables.

Para la realización de estos modelos se utiliza el paquete estadístico Eviews 8.0, empleado para análisis estadístico general, pero es especialmente útil para realizar análisis econométrico, como modelos multivariados y estimación y predicción con modelos de series de tiempo.

A partir de estas consideraciones se estimaron los modelos VAR con las diferencias logarítmicas estacionarias de cada una de las variables y el modelo VEC con los logaritmos de las variables.

Un modelo VAR es un modelo de ecuaciones simultáneas formado por un sistema de ecuaciones de forma reducida sin restringir. Que sean ecuaciones de forma reducida quiere decir que los valores contemporáneos de las variables del modelo no aparecen como variables explicativas en las distintas ecuaciones. El conjunto de variables explicativas de cada ecuación está constituido por un bloque de retardos de cada una de las variables del modelo. Que sean ecuaciones no restringidas significa que aparece en cada una

de ellas el mismo grupo de variables explicativas. [10].

$$Y_t = \beta_0 + \sum_{s=1}^k \beta_s Y_{t-s} + u_t \quad (1)$$

Donde  $Y_t$  es un vector columna  $n \times 1$ ;  $K$  es el orden del modelo VAR, o número de retardos de cada variable en cada ecuación, y  $u_t$  es un vector  $n \times 1$  de innovaciones, es decir, procesos sin autocorrelación, con  $Var(u_t) = \Sigma$ , constante.

El elemento  $(i; j)$  en la matriz  $A_s$ ;  $1 \leq s \leq K$  mide el efecto directo o parcial de un cambio unitario en  $Y_j$  en el instante  $t$  sobre  $Y_i$  al cabo de  $s$  períodos,  $Y_{i;t+s}$ . La columna  $j$  de la matriz  $A_s$  mide el efecto de un cambio unitario en  $Y_j$  en el instante  $t$  sobre el vector  $Y_{t+s}$ . El elemento  $i$ -ésimo en  $u_t$  es el componente de  $Y_{it}$  que no puede ser previsto utilizando el pasado de las variables que integran el vector  $Y_t$ . [10].

En un modelo VAR todas las variables son tratadas simétricamente, siendo explicadas por el pasado de todas ellas. El modelo tienen tantas ecuaciones como variables, y los valores retardados de todas las ecuaciones aparecen como variables explicativas en todas las ecuaciones. Una vez estimado el modelo, puede procederse a excluir algunas variables explicativas, en función de su significancia estadística, pero hay razones para no hacerlo.

Un modelo de Vector de Corrección del Error (VEC) es un modelo VAR restringido (habitualmente con sólo dos variables) que tiene restricciones de cointegración incluidas

en su especificación, por lo que se diseña para ser utilizado con series que no son estacionarias pero de las que se sabe que son cointegradas. [6] y [11].

Si las variables  $X_t$  e  $Y_t$  tiene el mismo orden de integración (de orden 1, habitualmente) y están cointegradas mediante la relación:

$$Y_t = \beta_1 + \beta_2 X_t + u_t \quad (2)$$

Entonces el modelo de corrección del error VEC es:

$$\begin{aligned} \Delta Y_t &= \alpha + \delta \Delta X_t + \gamma(Y_{t-1} - \hat{\beta}_1 - \hat{\beta}_2 X_{t-1}) + \varepsilon_t \\ &= \alpha + \delta \Delta X_t + \gamma \hat{\mu}_t + \varepsilon_t \end{aligned} \quad (3)$$

De este modo, las variaciones  $Y_t$  ( $\Delta Y_t$ ) dependen de las variaciones experimentales en  $X_t$  a través de  $\delta \Delta t$  y del equilibrio que se produjo en el periodo anterior

$$Y_{t-1} - \hat{\beta}_1 - \hat{\beta}_2 X_{t-1} \quad (4)$$

a través del término de Corrección del Error (CE)

$$CE = \gamma(Y_{t-1} - \hat{\beta}_1 - \hat{\beta}_2 X_{t-1}) \quad (5)$$

Resumiendo podemos decir que si existe cointegración entre las variables de un modelo, este puede analizarse mediante un modelo de corrección del error (VEC) que representa correctamente el comportamiento dinámico de las series del modelo. Como una función lineal de los cambios en las variables explicativas y del término de corrección de error (CE). [6] y [11].

## 2.1 Ecuaciones de Modelos Multivariados para la Proyección de la Demanda de Energía Eléctrica

### 1) Modelo VAR Endógeno:

Partiendo de la ecuación (1), tenemos que:

$$\begin{aligned} \Delta \ln DEE_t &= \sum_{a1=1}^k \beta_{a1} \Delta \ln DEE_{t-a1} \\ &+ \sum_{b1=1}^k \beta_{b1} \Delta \ln PIBTotal_{t-b1} \\ &+ \sum_{c1=1}^k \beta_{c1} \Delta \ln POB_{t-c1} \\ &+ \sum_{d1=1}^k \beta_{d1} \Delta \ln TEMP_{t-d1} \\ &+ \beta_{01} \end{aligned} \quad (6)$$

$$\begin{aligned} \Delta \ln PIBTotal_t &= \sum_{a2=1}^k \beta_{a2} \Delta \ln DEE_{t-a2} \\ &+ \sum_{b2=1}^k \beta_{b2} \Delta \ln PIBTotal_{t-b2} \\ &+ \sum_{c2=1}^k \beta_{c2} \Delta \ln POB_{t-c2} \\ &+ \sum_{d2=1}^k \beta_{d2} \Delta \ln TEMP_{t-d2} \\ &+ \beta_{02} \end{aligned} \quad (7)$$

$$\begin{aligned} \Delta \ln POB_t = & \sum_{a=1}^k \beta_{a3} \Delta \ln DEE_{t-a3} \\ & + \sum_{b=1}^k \beta_{b3} \Delta \ln PIB_{total,t-b3} \\ & + \sum_{c=1}^k \beta_{c3} \Delta \ln POB_{t-c3} \\ & + \sum_{d=1}^k \beta_{d3} \Delta \ln TEMP_{t-d3} \\ & + \beta_{03} \end{aligned} \quad (8)$$

$$\begin{aligned} \Delta \ln TEMP_t = & \sum_{a=1}^k \beta_{a4} \Delta \ln DEE_{t-a4} \\ & + \sum_{b=1}^k \beta_{b4} \Delta \ln PIB_{total,t-b4} \\ & + \sum_{c=1}^k \beta_{c4} \Delta \ln POB_{t-c4} \\ & + \sum_{d=1}^k \beta_{d4} \Delta \ln TEMP_{t-d4} \\ & + \beta_{04} \end{aligned} \quad (9)$$

Realizando el criterio de selección de longitud de rezagos, los estadísticos Akaike, Schwarz y Hannan-Quinn, indican el número de rezagos a emplear en el modelo, dando como resultado con  $k = 4$  rezagos. Las variables explicativas de cada ecuación son: cuatro constantes, más cuatro retardos de cada una de las variables del modelo, con 68 coeficientes en total.

Las variables endógenas para este modelo son: PIB total, población y la temperatura.

## 2) Modelo VAR Exógeno:

Partiendo de la ecuación (1), tenemos que:

$$\begin{aligned} \Delta \ln DEE_t = & \sum_{s=1}^k \beta_s \Delta \ln DEE_{t-s} \\ & + \beta_{PIB_{total}} \Delta \ln PIB_{total,t} \\ & + \beta_{POB} \Delta \ln POB_t \\ & + \beta_{TEMP} \Delta \ln TEMP_t \\ & + \beta_0 \end{aligned} \quad (10)$$

Realizando el criterio de selección de longitud de rezagos, los estadísticos Akaike, Schwarz y Hannan-Quinn, indican el número de rezagos a emplear en el modelo, dando como resultado con  $k = 4$  rezagos. Las variables explicativas de cada ecuación son: una constante, más cuatro retardos de la variable endógena y tres de las variables exógenas, con 8 coeficientes en total.

Las variables exógenas para este modelo son: PIB total, población y como variable exógena la temperatura.

## 3) Modelo VEC:

Partiendo de la ecuación (3), tenemos que:

$$\begin{aligned} \Delta \ln DEE_t = & \sum_{a=1}^k \delta_{a1} \Delta \ln DEE_{t-a1} \\ & + \sum_{b=1}^k \delta_{b1} \Delta \ln PIB_{total,t-b1} \\ & + \sum_{c=1}^k \delta_{c1} \Delta \ln POB_{t-c1} + \delta_{01} \\ & + \delta_{TEMP1} \ln TEMP_t \\ & + \delta_{Dummy1} \ln Dummy_t \\ & + \gamma_1 (\ln DEE_{t-1}) \\ & + \beta_1 \ln PIB_{total,t-1} \\ & + \beta_2 \ln POB_{t-1} \\ & + \beta_3 \Delta Trend(91T1) \\ & + \beta_0 \end{aligned} \quad (11)$$

$$\begin{aligned} \Delta \ln \text{PIB} \text{Total}_t &= \sum_{a2=1}^k \delta_{a2} \Delta \ln \text{DEE}_{t-a2} \\ &+ \sum_{b2=1}^k \delta_{b2} \Delta \ln \text{PIB} \text{Total}_{t-b2} \\ &+ \sum_{c2=1}^k \delta_{c2} \Delta \ln \text{POB}_{t-c2} + \delta_{02} \\ &+ \delta_{TEMP2} \ln \text{TEMP}_t \\ &+ \delta_{Dummy2} \ln \text{Dummy}_t \\ &+ \gamma_2 (\ln \text{DEE}_{t-1}) \\ &+ \beta_1 \ln \text{PIB} \text{Total}_{t-1} \\ &+ \beta_2 \ln \text{POB}_{t-1} \\ &+ \beta_3 \Delta \text{Trend}(91T1) \\ &+ \beta_0 \quad (12) \end{aligned}$$

$$\begin{aligned} \Delta \ln \text{POB}_t &= \sum_{a3=1}^k \delta_{a3} \Delta \ln \text{DEE}_{t-a3} \\ &+ \sum_{b3=1}^k \delta_{b3} \Delta \ln \text{PIB} \text{Total}_{t-b3} \\ &+ \sum_{c3=1}^k \delta_{c3} \Delta \ln \text{POB}_{t-c3} + \delta_{03} \\ &+ \delta_{TEMP3} \ln \text{TEMP}_t \\ &+ \delta_{Dummy3} \ln \text{Dummy}_t \\ &+ \gamma_3 (\ln \text{DEE}_{t-1}) \\ &+ \beta_1 \ln \text{PIB} \text{Total}_{t-1} \\ &+ \beta_2 \ln \text{POB}_{t-1} \\ &+ \beta_3 \Delta \text{Trend}(91T1) \\ &+ \beta_0 \quad (13) \end{aligned}$$

Se realizó la prueba de Phillips - Perron (PP) a cada una de las variables, de las cuales algunas de ellas presentaban estacionariedad, a lo cual se procedió a realizarle el tratamiento de sacarle el logaritmo natural a las variables para quitarle la estacionariedad. De esta manera se cumplía la regla para el modelo VEC, donde la serie de datos fuera no estacionaria.

Realizando el criterio de selección de longitud de rezagos, los estadísticos Akaike, Schwarz y Hannan-Quinn, indican el número de rezagos a emplear en el modelo, dando como resultado con  $k = 4$  rezagos. Las variables endógenas para este modelo son: PIB total, población y como variables exógenas: la temperatura y una dummy entre los periodos de septiembre de 2010 a marzo de 2011 (donde el crecimiento del PIB es inverso al de la demanda de energía y la temperatura, en éste periodo se presentó el fenómeno de “La Niña”).

## 2.2 Análisis Comparativo de Proyecciones - Errores y Sesgo Sistemático

Se realiza un análisis de sesgo sistemático empleando la metodología utilizada por [2], en donde se permite medir la precisión de la proyecciones realizadas por los modelos mencionados anteriormente, la cual analiza el Error Promedio Porcentual (APE), el Error Promedio Absoluto (AAE), el Error Cuadrático Medio (MSE), el Sesgo (B), el Modelo (M) y los Aleatorios (R). Éstos estadísticos permiten medir la precisión de la proyección.

El error cuadrático medio da la medida de las diferencias en promedio entre los valores pronosticados y los observados. De éste, se divide en tres medidas que cuantifican la sobrestimación o la subestimación del modelo, como son: el error por sesgo, del modelo y por aleatoriedad. La suma de estas medidas debe ser del 100%, lo idóneo es que el modelo sea explicado en su gran totalidad por la aleatoriedad.

Para el cálculo de este análisis, se emplearon las proyecciones realizadas por los modelos anteriormente descritos, en el periodo

comprendido desde 2008 a 2013, con una frecuencia trimestral.

La verificación de cada uno de los valores proyectados por cada uno de los modelos, se realizó empleando la metodología celda a celda, la cual consiste en comparar el resultado del pronóstico con el análisis para el mismo año. La ventaja que conlleva éste método es la sencillez en la computación, ya que, todos los puntos de los valores observados y pronosticados coinciden espacialmente. Sin embargo, algunos autores, [12] y [13], han constatado la tendencia de esta metodología en producir un sesgo a favor de los resultados de los dominios con resoluciones menores. [8].

**A. Error Promedio Porcentual:**

$$APE = \frac{1}{n} \sum_{t=1}^n 100 * \frac{(P_t - A_t)}{A_t} \quad (14)$$

**B. Error Promedio Absoluto:**

$$AAE = \frac{1}{n} \sum_{t=1}^n |A_t - P_t| \quad (15)$$

**C. Error Cuadrático Medio:**

$$MSE = \frac{1}{n} \sum_{t=1}^n \left( \frac{(P_t - A_t)}{A_{t-1}} \right)^2 = \frac{1}{n} \sum_{t=1}^n (p_t - a_t)^2 \quad (16)$$

donde,

$$p_t = (P_t - A_{t-1}) / A_{t-1} \quad (17)$$

$$a_t = (A_t - A_{t-1}) / A_{t-1} \quad (18)$$

Siendo  $P$  el valor proyectado y  $A$  el valor real histórico.

Del Error Cuadrático Medio se desprenden los errores que determinan cuan confiable es el modelo.

$$B = Sesgo = \frac{(\bar{p} - \bar{a})^2}{MSE} \quad (19)$$

$$M = Modelo = \frac{(S_p - rS_a)^2}{MSE} \quad (20)$$

$$R = Aleatorio = \frac{(1 - r^2)S_a^2}{MSE} \quad (21)$$

Donde  $S_p$  es la desviación estándar de la población de  $p$ ,  $r$  son los coeficientes de correlación entre  $P$  y  $A$ , y  $S_a$  es la desviación estándar de  $a$ . [2].

Se selecciona aquel modelo que su MSE, sea el menor y que además sus errores sean atribuidos especialmente a aleatoriedad, y con porcentajes mínimos al sesgo y al modelo.

### 3. RESULTADOS

Para la estimación eficiente de las ponderaciones de cada modelo, se emplea el menor valor de MSE utilizando como restricciones el máximo valor de los errores aleatorios y los mínimos valores de los errores por sesgo y de modelo; además como criterio de selección, se otorga la mayor ponderación a aquel modelo que minimiza los criterios de Akaike y Schwarz y maximiza el estadístico del Logaritmo de Máxima Verosimilitud.

### 3.1 Criterios de Selección de los Modelos

Para la selección de un modelo entre las especificaciones alternativas se analizaron los diferentes criterios utilizados en este tipo de investigaciones [5]:

- I. Logaritmo de la función de máxima verosimilitud (Log likelihood), prefiriendo aquel modelo con un valor superior.
- II. Criterio de información de Akaike (AIC), siendo preferible aquel modelo que presente un valor AIC menor.
- III. Estadístico de Schwarz (SC), que tiene en cuenta explícitamente el tamaño de la muestra, siendo preferible aquel modelo que presente un valor del estadístico SC menor.
- IV.  $R^2$  ajustado, prefiriendo aquel modelo con un valor superior.
- V. Estadístico de Hannan-Quinn (HQ), que también tiene en cuenta el tamaño de la muestra y que refiere aquel modelo que presente un valor del estadístico HQ menor.

Tabla 1. Estadísticos – Modelo VAR Endógeno

R-squared	0.758118	0.288042	0.987211	0.433612
Adj. R-squared	0.693616	0.098186	0.983801	0.282575
Sum sq. resids	0.008862	0.007241	1.27E-07	0.013991
S.E. equation	0.012153	0.010986	4.60E-05	0.015270
F-statistic	11.75343	1.517162	289.4782	2.870905
Log likelihood	239.9288	247.7057	669.3905	222.3480
Akaike AIC	-5.790357	-5.992355	-16.94521	-5.333713
Schwarz SC	-5.272894	-5.474891	-16.42774	-4.816250
Mean dependent	0.005417	0.008386	0.003227	0.000321
S.D. dependent	0.021956	0.011568	0.000361	0.018029
Determinant resid covariance (dof adj.)	5.74E-21			
Determinant resid covariance	2.12E-21			
Log likelihood	1395.736			
Akaike information criterion	-34.48665			
Schwarz criterion	-32.41680			

Fuente: UPME, 2014.

Tabla 2. Estadísticos – Modelo VAR Exógeno

R-squared	0.679183
Adj. R-squared	0.648420
Sum sq. resids	0.012375
S.E. equation	0.013020
F-statistic	22.07774
Log likelihood	240.9189
Akaike AIC	-5.751085
Schwarz SC	-5.514596
Mean dependent	0.006180
S.D. dependent	0.021959

Fuente: UPME, 2014.

Tabla 3. Estadísticos – Modelo VEC

R-squared	0.759639	0.245611	0.990321
Adj. R-squared	0.700534	0.060105	0.987941
Sum sq. resids	0.008806	0.007673	9.60E-08
S.E. equation	0.012015	0.011215	3.97E-05
F-statistic	12.85234	1.324008	416.0834
Log likelihood	240.1716	245.4769	680.1163
Akaike AIC	-5.822639	-5.960440	-17.24977
Schwarz SC	-5.335615	-5.473416	-16.76275
Mean dependent	0.005417	0.008386	0.003227
S.D. dependent	0.021956	0.011568	0.000361
Determinant resid covariance (dof adj.)	2.00E-17		
Determinant resid covariance	9.95E-18		
Log likelihood	1179.463		
Akaike information criterion	-29.28476		
Schwarz criterion	-27.70193		

Fuente: UPME, 2014.

Donde se concluye, que entre una familia de modelos el que cumple con la mayoría de criterios es el modelo VAR Exógeno, debido a que presenta el mayor valor del logaritmo de la función máxima verosimilitud, y el menor valor del estadístico de Schwarz.

Por otro lado, el criterio de selección para el  $R^2$  deberá ser mayor al 65%, de lo anterior con un 67,92% de la variabilidad de la demanda de energía eléctrica es explicada por el modelo VAR Exógeno. Donde se concluye que el modelo es adecuado para describir la relación que existe entre el PIB Total, la población y la temperatura.

Para la asignación de las participaciones a cada modelo, empleando la teoría de combinación de modelos [1], se calculó de la

siguiente manera, dando una justificación matemática.

Sea,

$$\begin{aligned} B &= \text{Sesgo} \\ M &= \text{Modelo} \\ R &= \text{Aleatorio} \end{aligned}$$

Encontrar

$$MSE(B, M, R) \mid \{B, M, R \in IR(0, 1) \mid B + M + R = 1\}$$

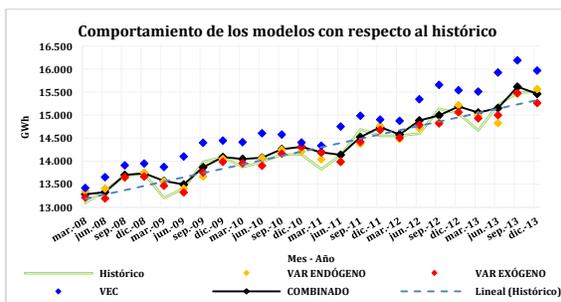
$$Max MSE_R \mid MSE_{Optimo} < MSE(VAR \text{ Endógeno}, VAR \text{ Exógeno}, VEC)$$

donde,

$$0,99 < \frac{\varepsilon M_{(VAR \text{ Endógeno}, VAR \text{ Exógeno}, VEC)}^2}{\varepsilon B_{(VAR \text{ Endógeno}, VAR \text{ Exógeno}, VEC)}^2} < 1,01 \quad (22)$$

De donde se obtuvo como resultado empleando la ecuación (22), que el modelo VAR endógeno se le asigna una participación del 20%, el modelo VAR exógeno un 60% y el modelo VEC un 20%. Además, dichas participaciones también fueron asignadas por medio de métodos heurísticos (criterio experto).

Gráfica 2. Comportamiento de los modelos con respecto al histórico



Fuente: UPME, Base de Datos XM, DANE, IDEAM, 2014.

Tabla 4. Errores de los modelos

	VAR Endógeno	VAR Exógeno	VEC	Modelo Combinado
APE	0.16%	-0.10%	3.40%	0.65%
AAE	155.97	151.54	485.42	139.43
MSE	0.019%	0.017%	0.135%	0.016%

Fuente: UPME, 2014.

Tabla 5. Errores que cuantifican la calidad del modelo

MSE	VAR Endógeno	VAR Exógeno	VEC	Modelo Combinado
Sesgo (B)	0.21%	1.62%	88.80%	23.51%
Modelo (M)	31.56%	17.03%	1.50%	26.45%
Aleatorio (R)	68.23%	81.36%	9.71%	50.04%

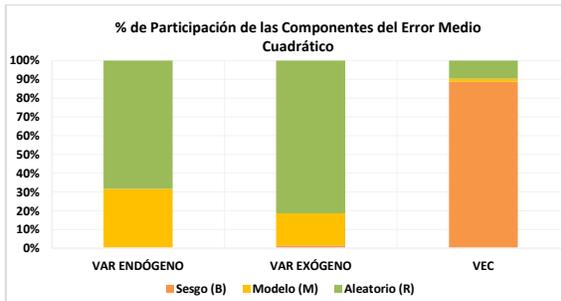
Fuente: UPME, 2014.

Como se puede observar en la Tabla 4 y en la Tabla 5, los valores menores para cada uno de los tipos de error se presentan en el modelo VAR Exógeno; además en las componentes del MSE el valor máximo de aleatoriedad se presenta en dicho modelo.

Realizando la combinación de modelos, se observa que el equilibrio se encuentra entre los tres modelos; al disminuir aún más el MSE se podría estar reduciendo la confiabilidad del modelo combinado, debido a que cualquier variación de alguna de las variables colocaría al modelo con una alta sensibilidad, dando como resultado valores atípicos o lejanos del valor real.

Esto se traduce, al minimizar el MSE disminuye la confiabilidad del modelo, ya que toda la sensibilidad se trasladaría al aumento del porcentaje de participación de las componentes de sesgo y modelo y se reduciría el porcentaje de aleatoriedad.

**Gráfica 3. Porcentaje de participación de las componentes del Error Cuadrático Medio**



Fuente: UPME, Base de Datos XM, DANE, IDEAM, 2014.

como la misma demanda, el PIB, la población y la temperatura. Este modelo proporciona un insumo de planeación energética novedoso y cambia los paradigmas tradicionales de proyección en Colombia.

#### 4. CONCLUSIONES Y RECOMENDACIONES

- Se desarrolló un modelo que estadísticamente es robusto, permitiendo combinar de manera óptima los resultados de las proyecciones generados por distintos modelos. Conjuntamente, se utiliza el análisis comparativo de las proyecciones de cada uno de los modelos para evaluar los Errores y el Sesgo Sistemático.
- Los componentes del error MSE permiten analizar aquellas condiciones donde los valores de las proyecciones del modelo sobrestiman o subestiman las condiciones de la demanda de energía eléctrica. Una de las técnicas, como el método de evaluación de pronósticos empleado por la EIA [2] es un muy buen referente para analizar el desempeño de los modelos.
- Los métodos empleados para la proyección de la demanda de energía eléctrica dependen de los datos, tales

## REFERENCIAS BIBLIOGRÁFICAS

- [1] **CASTAÑO V., ELKIN. (1994).** *“Combinación de pronósticos y variables predictoras con error”*. Revista Lecturas de Economía No. 41. Departamento de Economía, Universidad de Antioquia. Medellín, Colombia. ISSN 0120-2596, ISSNe 2323-0622. Páginas: 59 – 80. (Consulta, Junio de 2014).
- [2] **CONSIDINE, TIMOTHY J. & CLEMENTE, FRANK A. (2007).** *“Gas-Market Forecast: Betting on Bad Numbers”*. Páginas: 53 a 59. En línea: [http://peakwatch.typepad.com/Gas\\_Market\\_Forecasts.pdf](http://peakwatch.typepad.com/Gas_Market_Forecasts.pdf) (Consulta, Marzo de 2014).
- [3] **DANE. Departamento Administrativo Nacional de Estadística. (2014).** *“PIB”*. Bogotá, D.C., Colombia. En línea: <https://www.dane.gov.co/index.php/pib> (Consulta, Junio de 2014).
- [4] ----- **Departamento Administrativo Nacional de Estadística. (2014).** *“Población”*. Bogotá, D.C., Colombia, 2014. En línea: <https://www.dane.gov.co/index.php/poblacion> (Consulta, Junio de 2014).
- [5] **GREENE. W. H. (1999).** *“Análisis Econométrico”*. Tercera Edición, Editorial Prentice Hall, Madrid.
- [6] **GUJARATI, DAMODAR N. (2004).** *“Econometría”*. Cuarta Edición, Parte II y Parte I,. Capítulos 13.1 a 13.9, y 18.1 a 18.4. Editorial Mc Gr aw Hill. México. Páginas: 507 – 539 y 717 – 728. (Consulta, Junio de 2014).
- [7] **IDEAM. Instituto de Hidrología, Meteorología y Estudios Ambientales. (2013).** *“Bases de Datos de Temperaturas”*. Bogotá, D.C., Colombia. (Consulta: Abril – Mayo de 2013).
- [8] **JORBA CASELLAS, ORIOL. (2005).** *“Simulación de los campos de viento de la Península Ibérica y el área geográfica de Catalunya con alta resolución espacial para distintas situaciones meteorológicas típicas”*. Universitat Politècnica de Catalunya, Departament de Projectes d'Enginyeria, Tesis Doctoral, Barcelona. (Consulta, Marzo de 2014).
- [9] **MHCP. Ministerio de Hacienda y Crédito Público. (2014).** *“Presupuesto general de la nación 2014”*. Bogotá, D.C., Colombia. Página: 10. En línea: <http://www.minhacienda.gov.co/portal/page/portal/HomeMinhacienda/presupuestogeneraldeLANACION/ProyectoPGN/2014/PRESUPUESTO%20GRAL%202014.pdf> (Consulta, Junio de 2014).
- [10] **NOVALES, ALFONSO. (2013).** *“Modelos vectoriales autoregresivos (VAR)”*. Universidad de Complutense, Madrid,

España. Páginas: 1- 34. (Consulta, Marzo de 2014).

[m.co/demanda/paginas/default.aspx](http://m.co/demanda/paginas/default.aspx)  
(Consulta, Junio de 2014).

[11] **PÉREZ LÓPEZ, C. (2006).** *“Econometría. Conceptos y Problemas resueltos de Econometría”*. Capítulo 4. Madrid, España. ISBN:84-9732-376-9. (Consulta, Marzo de 2014).

[12] **STENGER, R. A. (2000).** *“Sensitivity studies on a limited area mesoscale model: an examination of lateral boundary placement, grid resolution and nesting type”*. Thesis for the degree of Master of Science in Meteorology. Air Force Institute Tecnology. Ohio, United States. En línea: <http://www.dtic.mil/dtic/tr/fulltext/u2/a384346.pdf> (Consulta, Marzo de 2014).

[13] **WHITE C., SMART R. P., STUTTER M., CRESSER M. S., BILLET M. F., ELIAS E. A., SOULSBY C., LANGAN S., EDWARDS A. C., WADE A., FERRIER R., NEAL C., JARVIE H. AND OWEN R. (1999).** *“A novel index of susceptibility of rivers and their catchments to acidification in regions subject to a maritime influence”*. Applied Geochemistry. Volume 14, Issue 8. Noviembre. Páginas:1093 a 1099. (Consulta, Junio de 2014).

[14] **XM. Compañía de Expertos en Mercados S.A. ESP. (2014).** Portal BI. Información Inteligente. *“Demanda”*. Medellín, Colombia. En línea: <http://informacioninteligente10.xm.co>

**Contacto:**  
Avenida Calle 26 # 69 D – 91  
Torre 1 Oficina 901  
**Pbx:** 222 06 01  
**Fax:** 221 95 37  
**Línea Gratuita Nacional:** 01800911729  
[www.upme.gov.co](http://www.upme.gov.co)  
**Síguenos en:** @UPMEOFICIAL