

**Modelando el Gas Entregado en Argentina: ¿Cuál es el Mejor Predictor?.**

Ivan Canay

Texto de Discusión N° 40

ISBN N° 987- 519-103-5

(Mayo 2002)

CEER

Centro de Estudios Económicos de la Regulación

Universidad Argentina de la Empresa

Lima 717, 1° piso

C1073AAO Buenos Aires, Argentina

Teléfono: 54-11-43797693

Fax: 54-11-43797588

E-mail: [ceer@uade.edu.ar](mailto:ceer@uade.edu.ar)

<http://www.uade.edu.ar/economia/ceer>

(Por favor, mire las últimas páginas de este documento por una lista de los Textos de Discusión y de la Working Paper Series del CEER e información concerniente a suscripciones).

El Centro de Estudios de Economía de la Regulación (CEER), es una organización dedicada al análisis de la regulación de los servicios públicos. El CEER es apoyado financieramente por el Banco Mundial, los Entes Reguladores de Agua, Telecomunicaciones y Electricidad de la República Argentina, y la Universidad Argentina de la Empresa (Buenos Aires), donde el CEER tiene su sede.

**Autoridades del CEER:**

Ing. Eduardo Cevallo, Presidente Ente Tripartito de Obras y Servicios Sanitarios. Lic. Enrique Devoto, Vicepresidente Primero Ente Nacional Regulador de la Electricidad (ENRE), Dr. Antonio Estache, World Bank Institute, Dr. Carlos Newland, Rector Universidad Argentina de la Empresa (UADE), Dr. Omar Chisari, Director Instituto de Economía (UADE).

Director Ejecutivo: Dr. Diego Petrecolla

INVESTIGADORES: Lic. Diego Bondorevsky, Lic. Ivan Canay, Dr. Omar Chisari, Lic. Gustavo Ferro, Dr. Diego Petrecolla, Dr. Martín Rodríguez Pardina, Lic. Carlos Romero; Lic. Christian Ruzzier.

Ayudante de Investigación: Lic. Mauricio Roitman.

# Modelando el Gas Entregado en Argentina: ¿Cuál es el mejor predictor?

Ivan A. CANAY<sup>1</sup>

Centro de Estudios Económicos de la Regulación - UADE, Argentina.

Departamento de Economía y Finanzas - UADE, Argentina.

## *Resumen*

En el presente trabajo se utilizan tres modelos alternativos para pronosticar las series de gas entregado a los usuarios residenciales y al total de usuarios en Argentina. Los resultados muestran que los modelos de series de tiempo son más adecuados para este fin que los modelos clásicos, no sólo por no necesitar predecir los valores de las variables exógenas, sino porque las evaluaciones del pronóstico los favorecen. Pese a que la mayoría de los modelos presenta persistentemente una subestimación en el período invernal, los errores para el volumen entregado anualmente no superan el 1%.

## *Abstract*

In this article three models are used to forecast the gas delivered to residential customers and to total customers. The results show that time series models are more precise than the classical models, not just because it is not necessary to forecast the future values of the exogenous variables, but because the forecast evaluation is better. Despite the fact that all the models show a persistent underestimation during the winter period, the error for the annual volume delivered does not exceed 1%.

*JEL classification:* L5, C5.

## **I. Introducción**

Las revisiones tarifarias constituyen una tarea habitual y cada vez más compleja dentro de la práctica regulatoria moderna. Estas revisiones requieren determinados insumos básicos para obtener una adecuada regulación y estos insumos dependen, entre otras cosas, del tipo de mecanismo regulatorio utilizado. Dentro de estos mecanismos, los más utilizados son la regulación por tasa de ganancia y por precios máximos. El primero de ellos es utilizado en EEUU y Japón, mientras que el mecanismo de precios máximos es utilizado en Gran Bretaña, Australia, Puerto Rico, Singapur y Argentina, entre otros países.

---

<sup>1</sup> El autor quisiera agradecer a Christian Ruzzier, Carlos Romero y Esteban Greco por sus sugerencias y útiles comentarios. Por supuesto, cualquier error es de mi total responsabilidad.

El mecanismo de precios máximos brinda a las empresas el máximo incentivo a reducir sus costos, ya que una caída en los mismos se ve reflejada en un aumento de los beneficios durante el período de vigencia de los precios máximos. En la práctica, los precios máximos son renegociados periódicamente, usualmente cada cinco años<sup>2</sup>, de manera tal de trasladar a los consumidores las ganancias de eficiencia obtenidas por las empresas. En general, el mecanismo de precios máximos se emplea juntamente con un sistema de RPI-X o RPI-X+K, por el cual el regulador permite que dentro del período de vigencia de los precios máximos, estos se incrementen de acuerdo a la evolución de un índice de precios reales (RPI), menos un factor de eficiencia (X)<sup>3</sup> que representa las reducciones de costos que se espera la empresa puede lograr, más un factor K, que será mayor cuanto mayores sean las inversiones que la empresa esté obligada a realizar.

Las tarifas ( $T_t$ ) deben fijarse de forma tal que el valor presente neto de los flujos de fondos se iguale al capital invertido en la firma al inicio del período de renegociación, de forma tal de asegurarle a los inversores una adecuada tasa de retorno (como muestra la ecuación 1). Esto implica que el punto de partida para la determinación de las nuevas tarifas durante una revisión tarifaria es la estimación de los futuros flujos de fondos.

$$VPN = \sum_{t=1}^K \frac{T_t V_t - C_t - I_t}{(1+r)^t} = \text{capital invertido}^4 \quad (1)$$

De esta forma, paralelamente a la proyección de los costos ( $C_t$ ), el costo de capital ( $r$ ) y las inversiones futuras ( $I_t$ ), se torna necesario pronosticar los valores para la demanda ( $V_t$ ). En el caso de la revisión quinquenal de las tarifas de gas que se realizó en 1997 en Argentina, el Enargas utilizó estimaciones del crecimiento de la demanda realizadas por la Secretaria de Energía y de las propias compañías. Luego, la información extraída fue utilizada para construir escenarios probables para las empresas. Esta revisión tarifaria reviste de importancia por haber sido la primera que un ente regulador condujo en nuestro país, y una de las primeras en un país en vías de desarrollo.

---

<sup>2</sup> Por ejemplo en el caso de gas el artículo 42 de la Ley N° 24.076 establece, “cada cinco (5) años el Ente Nacional Regulador del Gas revisará el sistema de ajuste de tarifas”. Estas revisiones determinan las tarifas máximas permitidas para cada una de las empresas transportistas y distribuidoras. La primera de estas revisiones se realizó durante 1996-97, y las nuevas tarifas comenzaron a regir en enero de 1998.

<sup>3</sup> La determinación del factor X constituye un ejemplo de uno de los insumos a determinar en la revisión tarifaria. Entre las herramientas principales para determinar este coeficiente se encuentra la llamada competencia por comparación propuesta originalmente por Schleifer (1985).

<sup>4</sup> El análisis del flujo de fondos debe extenderse hasta que la licencia expire. En el caso particular de la revisión quinquenal de tarifas de gas en Argentina este período fue igual a 35 años (Ver Gomez Lobo (1999) para un análisis detallado de la revisión)

La determinación de la demanda futura es un elemento de extrema importancia debido a que un mal cálculo puede afectar la sostenibilidad de la firma, así como también provocarle ingresos extraordinarios. No obstante, no existe un consenso absoluto sobre las herramientas de cálculo de la demanda futura y del resto de los elementos que intervienen en la revisión tarifaria (como el costo de capital de la firma, la determinación del factor X y del factor K), dando lugar a que continuamente se propongan nuevas alternativas que amplían las opciones actuales. En este marco de disenso, este artículo analiza tres modelos distintos intentando determinar sus ventajas y desventajas. Más allá de las ventajas en términos de calidad en la predicción, la conclusión a la que se arriba es que los modelos de series de tiempo pueden ser de gran utilidad en una revisión tarifaria debido a que presentan dos características deseables: simplicidad y objetividad.

La estructura del trabajo es la siguiente. En la sección II se detallarán algunos criterios básicos para caracterizar un buen modelo predictivo. En la sección III se pronosticará el gas entregado a usuarios residenciales; mientras que en la sección IV se hará lo mismo pero para el caso del gas total entregado. Finalmente, en la sección V se analizará si alguno de los pronósticos domina a los otros, para luego presentar las conclusiones en la sección VI.

## **II. Elementos a tener en cuenta para una buena predicción**

En general, cualquier tipo de predictor que uno elija para obtener valores futuros de una variable de interés va a estar sujeto a ventajas y desventajas. Por este motivo, un punto importante a la hora de elegir uno es decidir en base a qué indicadores uno va a medir sus propiedades: ¿Cómo puede cuantificarse un buen pronóstico o, en forma equivalente, los errores o pérdidas asociados a él?

Para responder esta pregunta es importante distinguir lo que podríamos llamar un pronóstico ex – post y uno ex – ante. En el primer caso se predicen valores de una variable, cuando los valores que se están prediciendo son de hecho conocidos porque ya sucedieron. Es decir, se utiliza información hasta el período t-j para predecir los j períodos hasta el período t (donde t denota el presente). Por otro lado, un pronóstico ex – ante se caracteriza por predecir valores futuros que aún no son conocidos debido a que no sucedieron. Evidentemente, el pronóstico ex – ante es el relevante para la aplicación, aunque el pronóstico ex – post es complementario debido a que permite “chequear” qué tan bueno puede llegar a ser un pronóstico ex – ante en caso de utilizarse el modelo elegido.

De esta forma, un pronóstico ex post, aunque no nos permita obtener valores “desconocidos” de la serie de interés, va a servir de herramienta para determinar qué es un pronóstico óptimo. Si llamamos  $y$  a la realización de nuestra variable de interés e  $\hat{y}^F$  al valor pronosticado, es posible definir el error de pronóstico:  $e = \hat{y}^F - y$ . Este error de pronóstico es el insumo básico para poder determinar la pérdida asociada a un mal pronóstico. En este punto es importante determinar si esta pérdida es o no simétrica. Esto

es, si las sobrepredicciones son penalizadas de igual forma que las subpredicciones.<sup>5</sup> En caso de considerar una pérdida simétrica, es sencillo definir una función de pérdida que nos permita “castigar” a los errores que cometamos. Por ejemplo, uno podría castigar por igual a los errores grandes y pequeños con una función del estilo  $L(e) = |e|$ ; o castigar más a los errores grandes por medio de una función  $L(e) = e^2$ . Este tipo de función de pérdida es la más utilizada en la práctica debido a que es consistente con los criterios estándares de regresión y permite utilizar muchas de las típicas herramientas de análisis (Granger, 1989). De esta forma, una respuesta inicial a la pregunta de cómo puede cuantificarse un buen pronóstico es afirmar que el mejor pronóstico será aquél con una función de pérdida esperada menor.<sup>6</sup>

Podría pensarse que el modelo que presente el mejor tipo de pronóstico sea uno extremadamente complejo e inmanejable. No obstante, el principio de parsimonia establece que, manteniendo el resto de las cosas iguales, los modelos simples son preferidos a los complejos; y este principio es altamente importante a la hora de construir un modelo predictivo. Diebold (1998) menciona algunas razones por las cuales los modelos simples muchas veces son preferibles a los complejos. En primer lugar, la simplicidad hace que los parámetros del modelo puedan ser estimados en forma más precisa. Segundo, dado que los modelos simples son más sencillos de comprender, los comportamientos anómalos son fácilmente visualizables. Finalmente, este principio reduce las posibilidades de generar un modelo que se adapte altamente al pasado de los datos pero cuyo poder predictivo sea pobre.

Otro aspecto importante a la hora de realizar la predicción es decidir si el valor futuro requerido es un valor puntual o si se desea un rango de valores donde razonablemente puede encontrarse el verdadero valor de la serie predicha. Más allá de que el pronóstico puntual tenga buenas propiedades, siempre van a existir shocks no nulos que pueden afectar el futuro de la serie. La existencia de estos shocks hace que los intervalos de confianza para el pronóstico sean de alta importancia. Estos intervalos deberían tener la propiedad de contener el verdadero valor futuro de la serie.

Finalmente, la elección de un buen predictor no es independiente de la cantidad y calidad de datos con la que se cuente. En general, para construir modelos predictivos más complejos es necesario contar con una cantidad de datos importante. Es decir, una condición necesaria para obtener un buen pronóstico es contar con mucha información pasada.

---

<sup>5</sup> Una forma alternativa de definir una pérdida simétrica es decir que si  $\delta$  es el costo asociado a una sobre predicción y  $\kappa$  el costo asociado a una sub predicción, entonces  $\delta = \kappa$ .

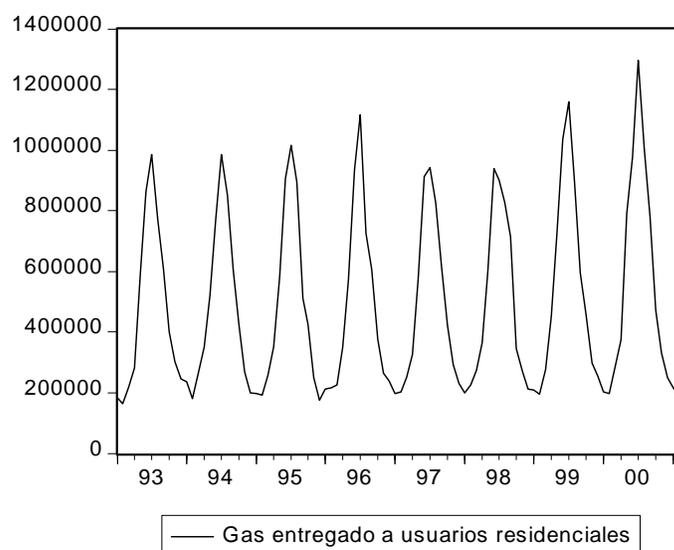
<sup>6</sup> Hay que tener en cuenta que la elección de un buen pronóstico también va a depender del horizonte del pronóstico. Es decir, un modelo puede ser un buen predictor a corto plazo pero no serlo a largo plazo.

En las siguientes secciones utilizaremos los pronósticos ex – post para analizar la calidad en la predicción de distintos modelos. Estos modelos serán evaluados según el ajuste que muestren y la pérdida en su predicción. La idea no es analizar todos los modelos que uno pueda imaginarse, sino más bien comparar los modelos clásicos que han sido utilizados muy frecuentemente en la práctica, con modelos univariados que deberían tener mejores propiedades predictivas. Veamos los resultados.

### III. Gas entregado a usuarios residenciales

Tanto los datos de gas entregado a usuarios residenciales como los de gas entregado al total de los clientes fueron extraídos de los informes trimestrales publicados por el Enargas. Estos datos son de frecuencia mensual, abarcan el período iniciado en Enero de 1993 hasta Marzo de 2001 y corresponden al gas entregado por el total de las ocho distribuidoras de gas existentes en Argentina<sup>7</sup>. El siguiente gráfico muestra el comportamiento del gas entregado a usuarios residenciales (GR):

**Figura 1**



En la figura 1 puede observarse un comportamiento muy estacional en la serie, y pese a que pueden detectarse picos más elevados en los inviernos del 99' y 00', no parece evidente la presencia de una tendencia creciente en el comportamiento de la serie.

A continuación se estimarán los siguientes modelos utilizando una sub-muestra que abarque el período comprendido entre Enero de 1993 y Mayo de 2000; dejando el resto de

---

<sup>7</sup> En realidad, el número de distribuidoras en nuestro país suman un total de nueve. No obstante, Gas NEA todavía no distribuye gas en su área de concesión.

los meses para chequear la calidad predictiva de cada uno de los modelos. Los tres modelos utilizados son:

$$(1) GR_t = \beta_0 + \beta_1 PBI_t + \sum_{i=2}^{12} \delta_i D_i + \varepsilon_t$$

$$(2) GR_t = \beta_0 + \beta_1 trend + \phi(L)y_t + \varepsilon_t$$

$$(3) VAR(p) \text{ entre } GR_t \text{ y } PBI_t$$

donde GR representa el gas entregado a usuarios residenciales,  $D_i$  son variables binarias que adoptan el valor 1 en el mes  $i$ , PBI es el producto bruto interno<sup>8</sup>, *trend* representa una variable de tendencia y  $\phi(L)$  es un polinomio de rezagos. El primer modelo corresponde a un modelo clásico que intenta explicar el gas entregado con algún otro conjunto de variables. En este caso se optó por incluir exclusivamente al producto bruto interno debido a que esta especificación es la más sencilla de las utilizadas. De todos modos, esto no elimina la opción de utilizar más variables que se crean relevantes. Los otros dos modelos los discutiremos previamente a su estimación.

## Modelo 1

El ajuste del modelo (1) (luego de ser corregido por autocorrelación) fue bueno. El coeficiente estimado de  $\beta_1$  arrojó un valor de 0.85<sup>9</sup>. Las variables dummies fueron significativas en su mayoría (excepto las correspondientes a los meses de Marzo y Diciembre), no se registran residuos *outliers*, y el  $R^2$  dio un valor de 0.97.

La figura 2 muestra la predicción de este modelo (GRF), los valores reales de la serie (GR) y el intervalo de confianza de la predicción del 95% (Lower y Upper representan las cotas inferiores y superiores del intervalo de confianza del pronóstico). A su vez se muestra el valor del coeficiente de Theil y su descomposición. Este coeficiente viene a representar la función de pérdida elegida para el análisis y su expresión es la siguiente:

$$Th = \frac{\sqrt{\frac{1}{h} \sum_{i=1}^h (y_i^F - y_i)^2}}{\sqrt{\frac{1}{h} \sum_{i=1}^h (y_i^F)^2} + \sqrt{\frac{1}{h} \sum_{i=1}^h (y_i)^2}}$$

---

<sup>8</sup> La serie de datos para el PBI es de frecuencia trimestral. Dado que los datos de GR son mensuales, se optó por mensualizar la serie de PBI suponiendo una tasa de crecimiento constante *dentro* de cada trimestre.

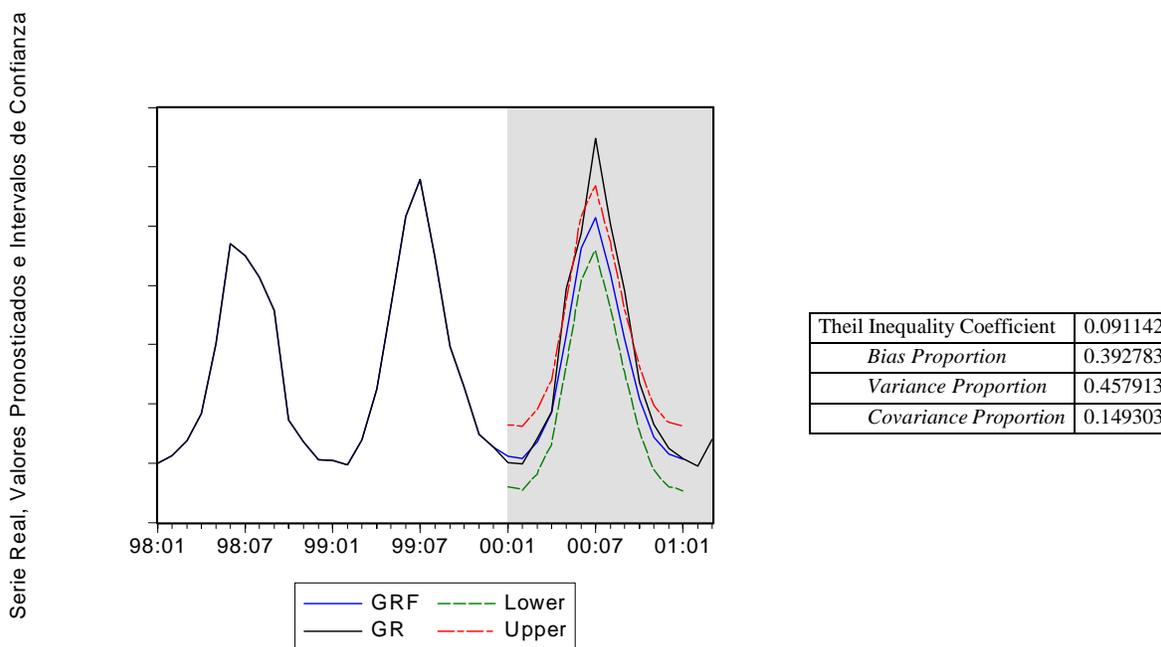
<sup>9</sup> Con un t-stat asociado igual a 1.82

Este coeficiente<sup>10</sup> puede descomponerse de una manera útil, estableciéndose qué proporciones de este coeficiente se deben a un error en el sesgo, a un error en la varianza y a un error en covarianza<sup>11</sup>, a través de la siguiente expresión:

$$\frac{1}{h} \sum_{t=1}^h (y_t^F - y_t)^2 = (\bar{Y}^F - \bar{Y})^2 + (\sigma_F - \sigma)^2 + 2(1 - \rho)\sigma_F\sigma$$

Volviendo a la figura 2, puede observarse que la predicción subestima el verdadero valor de la serie en todo el período de predicción, aunque la diferencia es más notoria en el pico invernal. Esto se manifiesta en la descomposición del coeficiente de Theil, ya que gran parte del error en la predicción se debe a un desvío sistemático entre los valores medios de las series (39%).

**Figura 2**



La tabla 1 muestra los valores pronosticados, los reales y la diferencia porcentual en el período.

<sup>10</sup> Obsérvese que este coeficiente adopta valores en el intervalo [0,1], donde 0 representa una predicción perfecta.

<sup>11</sup> Las proporciones en el sesgo y en la varianza son indicio de un error sistemático; mientras que la proporción en la covarianza es el componente que capta el error no sistemático.

**Tabla 1**

Período	Modelo (1) – GR			Período	GRF	GR	Error
	GRF	GR	Error				
<i>jun-00</i>	924936	975584	-5%	<i>oct-00</i>	417869	472685	-12%
<i>jul-00</i>	1028111	1295410	-21%	<i>nov-00</i>	287321	331386	-13%
<i>ago-00</i>	837974	1004805	-17%	<i>dic-00</i>	230085	250169	-8%
<i>sep-00</i>	619004	781733	-21%	<i>ene-01</i>	214285	216266	-1%

**Modelo 2**

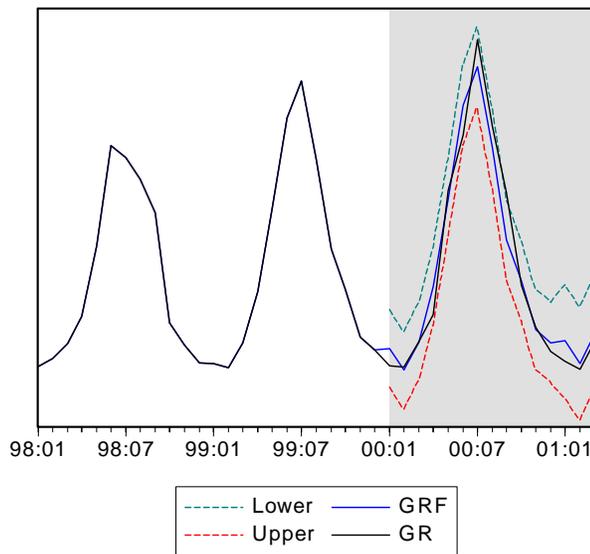
En el apéndice A se presenta el correlograma de la serie GR. En el mismo puede observarse que la serie presenta un comportamiento estacional importante. El movimiento de la ACF indica que hasta podría existir una raíz estacional. Tras probar con una serie de modelos alternativos, se decidió que la siguiente ecuación modela mejor la variable de interés (aquí  $\epsilon$  representa una variable aleatoria con media cero y varianza constante)

$$GR_t = \underset{(-0.40)}{-6182946} - \underset{(-0.76)}{15059 trend} + \underset{(33.32)}{1.026 GR_{t-12}} + \epsilon_t - \underset{(-2.23)}{0.255 * \epsilon_{t-4}}$$

Este modelo describe satisfactoriamente el comportamiento de la serie. Tanto el criterio de información de Akaike (AIC) como el criterio de Schwarz (SBC) eligen a este modelo como el más adecuado, y el correlograma de los residuos muestra que los mismos son ruido blanco. Esto no significa que este modelo sea la única opción para modelar (por ejemplo también está la opción de trabajar con la serie diferenciada estacionalmente).

**Figura 3**

Serie Real, Valores Pronosticados e Intervalos de Confianza



Theil Inequality Coefficient	0.055023
Bias Proportion	0.001331
Variance Proportion	0.178481
Covariance Proportion	0.820188

La figura 3 muestra la misma información que la figura 2 pero relativa al modelo 2. En este caso puede observarse que el pronóstico continúa subestimando el verdadero valor de la serie durante el período invernal, aunque la brecha es más chica que la del modelo 1. El coeficiente de Theil también muestra mejores resultados ya que es considerablemente inferior y gran parte de su descomposición se halla en la covarianza. Por otro lado, pese a que este modelo sobreestima en los meses de consumo más bajos (Diciembre, Enero y Febrero), una notable diferencia con respecto al modelo anterior es que la serie real se encuentra contenida en el intervalo de confianza del pronóstico lo cual representa un avance en términos relativos.

**Tabla 2**

<b>Modelo (2) – GR</b>							
<b>Período</b>	<b>GRF</b>	<b>GR</b>	<b>Error</b>	<b>Período</b>	<b>GRF</b>	<b>GR</b>	<b>Error</b>
<i>Jun-00</i>	1076110	975584	10%	<i>nov-00</i>	322741	331386	-3%
<i>Jul-00</i>	1204218	1295410	-7%	<i>dic-00</i>	278908	250169	11%
<i>ago-00</i>	931937	1004805	-7%	<i>ene-01</i>	284471	216266	32%
<i>sep-00</i>	625227	781733	-20%	<i>feb-01</i>	209650	190048	10%
<i>oct-00</i>	486621	472685	3%	<i>mar-01</i>	307581	281146	9%

En la tabla 2 puede verse que la subestimación del período invernal es inferior a la del modelo 1, aunque la sobreestimación en los meses de verano es considerable. No obstante, vale la pena señalar dos consideraciones. En primer lugar, las desviaciones en verano son más chicas (en volumen) que las invernales, aunque al tomar el porcentaje brindan un número mayor debido a que el volumen de gas es menor durante esos meses. En segundo lugar, en este punto es importante introducir una discusión similar a la de la simetría de la función de pérdida. Esto es, probablemente sea preferible un modelo que realice una mejor predicción en los meses de alta demanda (con errores en los meses de baja demanda), a un modelo que cometa errores en los meses de alta demanda (con buenas predicciones en los de baja demanda). Esta decisión es importante a la hora de evaluar un modelo frente al otro.

### *Modelo 3*

La opción en este caso será utilizar un modelo de Vectores Autoregresivos (VAR) entre la serie GR y el PBI. A través de los criterios de Akaike y Schwarz se arribó a que la mejor especificación fue un VAR(4) con una tendencia determinística, una constante y un término autoregresivo de orden 12 que capta la estacionalidad de las series. Los resultados fueron los siguientes:

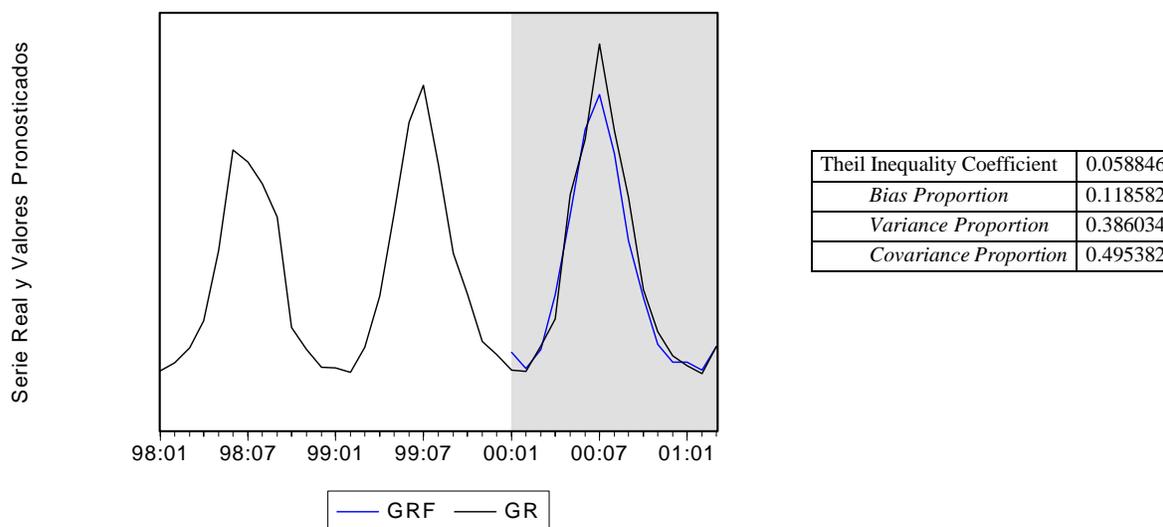
$$\begin{cases} PBI_t = 1.311PBI_{t-1} - 0.2146PBI_{t-2} - 0.842PBI_{t-3} + 0.754PBI_{t-4} - 0.1203PBI_{t-12} + 0.006GR_{t-1} \\ - 0.0073GR_{t-2} + 0.0068GR_{t-3} - 0.0116GR_{t-4} - 0.0032GR_{t-12} + 29255.12 + 74.466Trend \\ GR_t = -3.274PBI_{t-1} + 4.863PBI_{t-2} + 5.85PBI_{t-3} + 8.843PBI_{t-4} + 2.147PBI_{t-12} + 0.052GR_{t-1} \\ + 0.0462GR_{t-2} + 0.0522GR_{t-3} - 0.1876GR_{t-4} + 0.5709GR_{t-12} - 22130.15 - 111.439Trend \end{cases}$$

Los resultados completos de la estimación pueden consultarse en el anexo. Cabe resaltar que se ha optado utilizar un modelo VAR aunque las variables bajo análisis son variables no estacionarias. Esto igualmente no invalida la utilización de este modelo ya que la estacionariedad de las series, pese a ser una propiedad deseable, no es una condición necesaria para obtener estimaciones de los coeficientes de cada ecuación (ver Hamilton, 1994).

Esta especificación nos permite visualizar la dinámica del modelo, previamente a la realización del pronóstico. Por ejemplo, la descomposición de la varianza del error de pronóstico es una medida que nos muestra el porcentaje de esta varianza provocado por las innovaciones que se producen en cada variable. Para un horizonte de 12 períodos, se observa que el 30% de la varianza en el error de pronóstico de GR es explicada por las innovaciones en el PBI.<sup>12</sup> Esta es una buena razón para creer que el pronóstico brindado por la especificación del modelo VAR posea buenas propiedades.

La figura 4 y la tabla 3 resumen los resultados del pronóstico. Aquí puede observarse que nuevamente el pronóstico subestima el verdadero valor de la serie durante el período invernal. El coeficiente de Theil es similar al del modelo anterior, aunque una mayor proporción del error se presenta como sistemático (en media y varianza).

**Figura 4**



La subestimación en los meses de Julio, Agosto y septiembre es más pronunciada que la que pudo observarse en el modelo 2, aunque no existe una sobreestimación tan pronunciada

<sup>12</sup> Mientras que solo el 9% del error de pronóstico del PBI es explicado por innovaciones en GR.

durante los meses de verano. De hecho, como puede observarse en la tabla 3, la predicción para el mes de Marzo de 2001 es casi perfecta.

Al analizar los errores que comenten estos modelos hay que tener en cuenta dos aspectos. Por un lado, el gas entregado a usuarios residenciales es una variable que se mide en forma bimestral, con lo cual al ser un dato de frecuencia mensual estimada puede generar cierto ruido en la muestra que afecte la predicción. Por otro lado, el año 2000 se caracterizó por ser un año particularmente frío, factor que puede explicar la subestimación invernal de todos los modelos ya que la temperatura no está siendo tomada en cuenta.

**Tabla 3**

<b>Modelo (3) – GR</b>							
<b>Período</b>	<b>GRF</b>	<b>GR</b>	<b>Error</b>	<b>Período</b>	<b>GRF</b>	<b>GR</b>	<b>Error</b>
<i>Jun-00</i>	1008994	975584	3%	<i>Nov-00</i>	287100	331386	-13%
<i>Jul-00</i>	1127438	1295410	-13%	<i>dic-00</i>	229013	250169	-8%
<i>ago-00</i>	929182	1004805	-8%	<i>ene-01</i>	229273	216266	6%
<i>sep-00</i>	636840	781733	-19%	<i>feb-01</i>	202185	190048	6%
<i>oct-00</i>	445257	472685	-6%	<i>mar-01</i>	281827	281146	0%

Antes de finalizar esta sección es conveniente realizar dos comentarios. En primer lugar, habría que tener en cuenta los errores de predicción acumulados de cada uno de los tres modelos durante el período de predicción, debido a que desde el punto de vista de la sostenibilidad de la empresa puede llegar a ser más importante el volumen anual más que las oscilaciones mensuales. Así, con los datos de las tablas 1, 2 y 3 puede calcularse que el modelo 1 subestima el volumen anual en un 14%, el modelo 3 hace lo mismo pero en un 7%, mientras que el modelo 2 subestima únicamente en un 1%. En segundo lugar, hay que tener en cuenta las diferencias existentes entre el corto plazo y el largo plazo. Los modelos 2 y 3 se caracterizan por ser buenos predictores de corto plazo, aunque a largo plazo poseen una reversión hacia el valor medio. Esto implica que en un horizonte lo suficientemente lejano, el pronóstico sería igual al valor medio de la serie.<sup>13</sup> No obstante, presentan un gran ventaja con respecto a los modelos clásicos de regresión debido a que no es necesario establecer de alguna forma ad hoc los valores futuros de las variables explicativas.

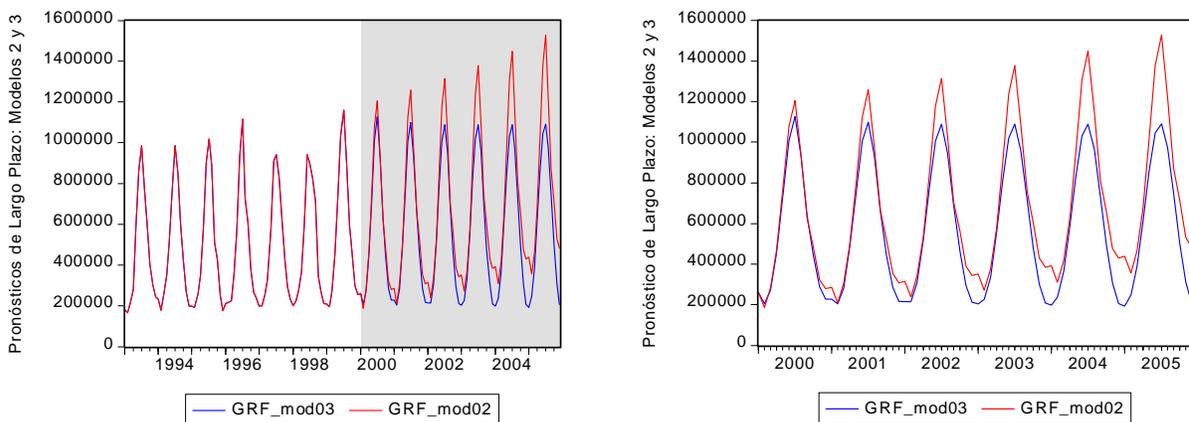
A continuación se muestran los pronósticos de largo plazo (hasta Diciembre de 2005) para los modelos 2 y 3. En la figura 5 puede observarse cómo el modelo VAR pronostica un comportamiento cíclico más estable del GR, mientras que el modelo 2 genera un comportamiento creciente entre año y año. En junio de 2005, el modelo 2 pronostica un 30% más de gas entregado a los usuarios residenciales que el modelo 3. Habría que ver que otros factores ayudan a determinar cuál de las dos opciones representa una alternativa más adecuada. En el peor de los casos, podrían considerarse estos pronósticos como una cota

---

<sup>13</sup> En este caso particular, hay que tener en cuenta que en el modelo 2 el valor estimado del coeficiente autorregresivo de orden 12 implica que el comportamiento del proceso es explosivo (no convergente), lo que da lugar al crecimiento que se muestra en la Figura 5.

inferior y superior. Por otro lado, en la sección V se analizarán herramientas para evaluar si vale la pena combinar ambos pronósticos.

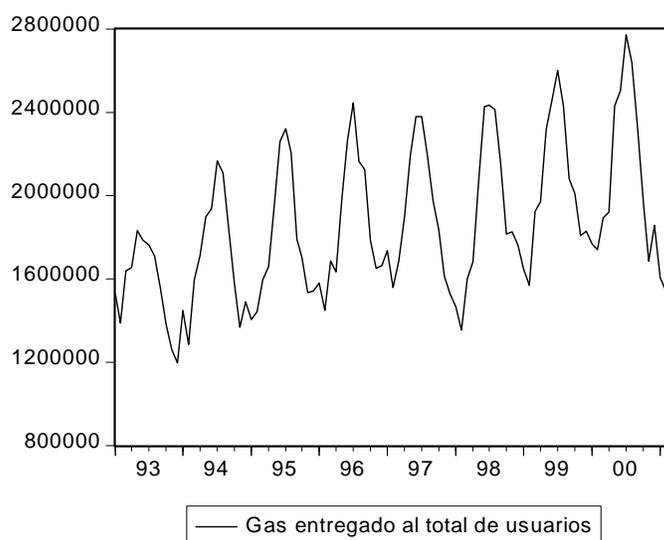
**Figura 5**



#### IV. Gas entregado al total de Usuarios

La figura 6 muestra el comportamiento del gas entregado al total de usuarios (GT). En dicha figura puede observarse que al igual que en la figura 1, el comportamiento estacional existe. Nos obstante, en este caso puede observarse una tendencia creciente, ya sea en los picos como en los valles.

**Figura 6**



Al igual que lo que se hizo en el caso del gas entregado a usuarios residenciales, se estimarán tres modelos alternativos utilizando los datos del período comprendido entre Enero de 1993 y Mayo de 2000; evaluando luego la calidad en la predicción de los modelos.

$$(1) GT_t = \beta_0 + \beta_1 PBI_t + \sum_{i=2}^{12} \delta_i D_i + \varepsilon_t$$

$$(2) GT_t = \beta_0 + \beta_1 trend + \phi(L)y_t + \varepsilon_t$$

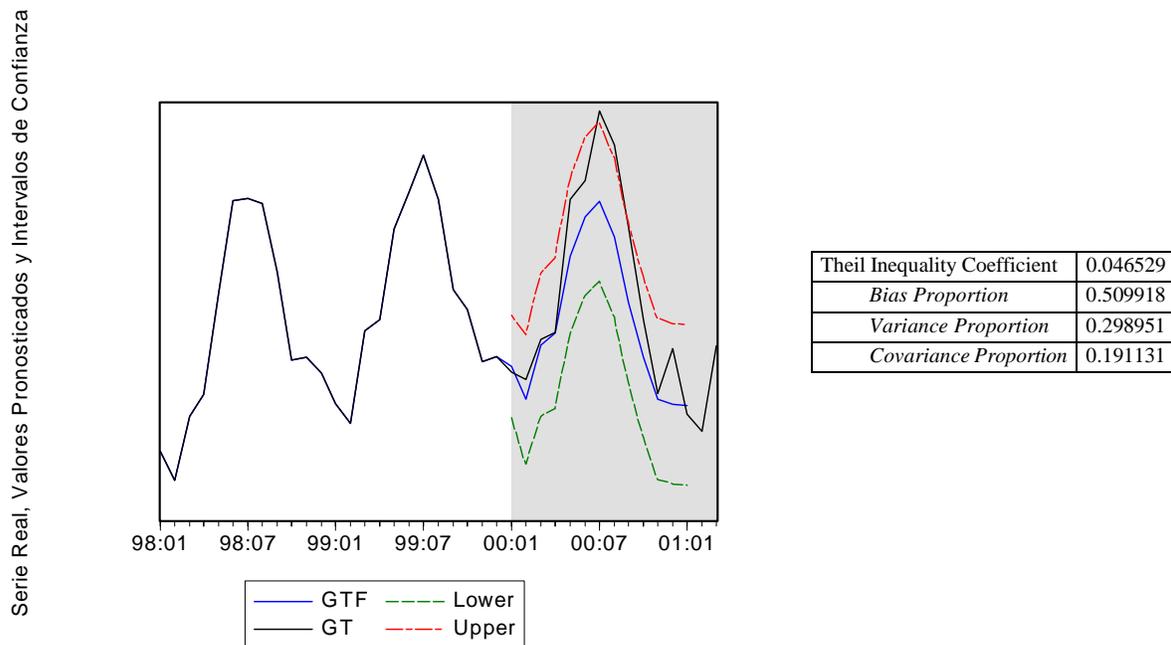
(3) VAR(p) entre  $GT_t$  y  $PBI_t$

Aquí GT representa el gas entregado al total de usuarios,  $D_i$  son variables binarias que adoptan el valor 1 en el mes  $i$ , PBI es el producto bruto interno<sup>14</sup>, *trend* representa una variable de tendencia y  $\phi(L)$  es un polinomio de rezagos.

### Modelo 1

El ajuste del modelo (1) (luego de ser corregido por autocorrelación) fue bueno. El coeficiente estimado de  $\beta_1$  arrojó un valor de 6.95<sup>15</sup>. Las variables dummies fueron significativas en su mayoría (excepto las correspondientes a los meses de Marzo, Abril, Noviembre y Diciembre), y el R<sup>2</sup> dio un valor de 0.93.

**Figura 7**



<sup>14</sup> La serie de PBI fue mensualizada de la misma forma que en el caso anterior.

<sup>15</sup> Con un t-stat asociado igual a 2.78

La figura 7 muestra la predicción de este modelo (GTF), los valores reales de la serie (GT) y el intervalo de confianza de la predicción del 95%. A su vez se muestra el valor del coeficiente de Theil y su descomposición.

Como puede observarse, el pronóstico de este modelo es regular aunque, al parecer, mejor que el pronóstico realizado por el mismo modelo para el caso de los consumidores residenciales. El coeficiente de Theil no es extremadamente alto, aunque el 80% del error del pronóstico se debe a un error sistemático (50% en el sesgo y 30% en la varianza). Aquí nuevamente se aprecia una subestimación en el período invernal, subestimación que se reduce a medida que se avanza hacia el verano. Asimismo, obsérvese que la serie real está contenida durante casi todo el período dentro del intervalo de confianza.

**Tabla 4**

Modelo (1) - GT							
Período	GRF	GR	Error	Período	GRF	GR	Error
<i>jun-00</i>	2362500	2500618	-6%	<i>oct-00</i>	1824991	1967821	-7%
<i>jul-00</i>	2421563	2769586	-13%	<i>nov-00</i>	1662664	1683327	-1%
<i>ago-00</i>	2284987	2637176	-13%	<i>dic-00</i>	1644408	1855960	-11%
<i>sep-00</i>	2033514	2322923	-12%	<i>ene-01</i>	1639207	1604707	2%

La tabla 4 muestra los valores pronosticados, los reales y los errores porcentuales. En ella podemos ver que, exceptuando el mes de enero de 2001, en el resto de los meses existe una subestimación considerable, resultado consistente con el gran porcentaje de error de pronóstico debido al sesgo. No obstante, el porcentaje máximo de error es 13%, magnitud relativamente menor con respecto al 21% del mismo modelo para el GR (ver tabla 1).

### Modelo 2

En el apéndice A se presenta el correlograma de la serie GT. En el mismo puede observarse que la serie presenta un comportamiento estacional importante al igual que la serie GR. Tras probar con una serie de modelos alternativos, se decidió que la siguiente ecuación modela mejor la variable de interés.

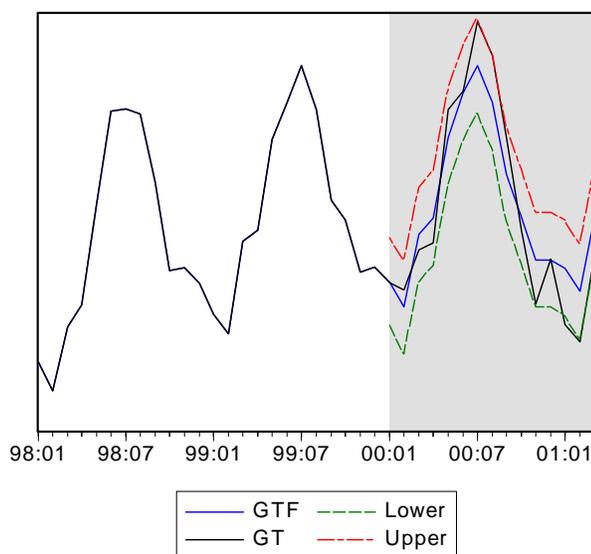
$$GT_t = 5483.5 \underset{(3194)}{trend} + 0.3898 \underset{(0.110)}{GT_{t-1}} + 1.0003 \underset{(0.0233)}{GT_{t-12}} + \varepsilon_t - 0.9170 \underset{(0.024)}{\varepsilon_{t-12}}$$

Este modelo describe satisfactoriamente el comportamiento de la serie. Tanto el criterio de información de Akaike (AIC) como el criterio de Schwarz (SBC) eligen a este modelo como el más adecuado, y el correlograma de los residuos muestra que los mismos son ruido blanco. En este caso también estaría la opción de trabajar con la serie diferenciada estacionalmente.

El gráfico muestra como la subestimación ahora es menor, además de presentar períodos de sobreestimación. La serie pronosticada cruza varias veces a la serie real, lo que hace que poca proporción del error de pronóstico se deba a un error sistemático en el valor medio; y los valores de la serie real se encuentran dentro del intervalo de confianza. El coeficiente de Theil (0.003098) es menor que el del modelo anterior y menor al del modelo 2 para el gas entregado a residenciales (aunque el denominado error sistemático es mayor).

**Figura 8**

Serie Real, Valores Pronosticados y Intervalos de Confianza



Theil Inequality Coefficient	0.030981
Bias Proportion	0.019562
Variance Proportion	0.551656
Covariance Proportion	0.428781

**Tabla 5**

<b>Modelo (2) – GT</b>							
<b>Período</b>	<b>GRF</b>	<b>GR</b>	<b>Error</b>	<b>Período</b>	<b>GRF</b>	<b>GR</b>	<b>Error</b>
<b>Jun-00</b>	2495485	2500618	0%	<b>nov-00</b>	1854534	1683327	10%
<b>Jul-00</b>	2598177	2769586	-6%	<b>dic-00</b>	1855219	1855960	0%
<b>ago-00</b>	2458560	2637176	-7%	<b>ene-01</b>	1820718	1604707	13%
<b>sep-00</b>	2182491	2322923	-6%	<b>feb-01</b>	1734474	1540278	13%
<b>oct-00</b>	2018476	1967821	3%	<b>mar-01</b>	2015201	1868826	8%

Los errores porcentuales de la tabla 5 muestran una subestimación invernal menor a la del modelo 1, y una sobreestimación en los primeros meses de 2001. Si comparamos esta tabla con la tabla correspondiente al mismo modelo para GR (tabla 2) podemos afirmar que el pronóstico en este caso está más balanceado, ya que el rango de los errores va desde -7% a 13%, mientras que el rango en la tabla 2 va de -20% a -32%. Hasta ahora puede decirse que este es el primer modelo que presenta subestimaciones bajas y parejas en el invierno.

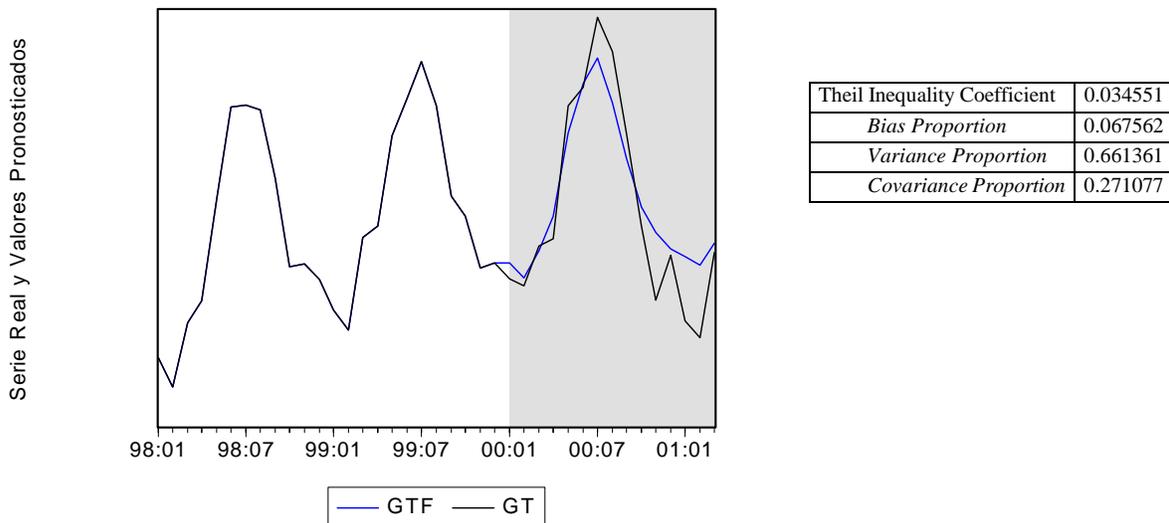
### Modelo 3

Nuevamente utilizaremos un modelo de Vectores Autoregresivos (VAR) entre la serie GT y el PBI. A través de los criterios de Akaike y Schwarz se arribó a que la mejor especificación fue un VAR(5) con una tendencia determinística, una constante y un término autoregresivo de orden 12 que capta la estacionalidad de las series. Los resultados fueron los siguientes<sup>16</sup>:

$$\begin{cases} PBI_t = 1.493PBI_{t-1} - 0.441PBI_{t-2} - 0.834PBI_{t-3} + 1.215PBI_{t-4} - 0.488PBI_{t-5} - 0.076PBI_{t-12} - 0.0009GT_{t-1} \\ + 0.0018GT_{t-2} - 0.002GT_{t-3} - 0.0018GT_{t-4} - 0.006GT_{t-5} - 0.005GT_{t-12} + 52536.61 + 172.85Trend \\ GT_t = 4.013PBI_{t-1} - 7.193PBI_{t-2} + 18.35PBI_{t-3} - 11.80PBI_{t-4} - 7.423PBI_{t-5} + 3.90PBI_{t-12} + 0.386GT_{t-1} \\ + 0.116GT_{t-2} - 0.046GT_{t-3} - 0.146GT_{t-4} - 0.091GT_{t-5} - 0.176GT_{t-12} + 1033197.5 + 3299.85Trend \end{cases}$$

La dinámica implícita en esta especificación difiere significativamente de la del modelo 3 de la sección anterior. La descomposición de la varianza provocada por las innovaciones de cada variable es relativamente simétrica. Para un horizonte de 12 períodos, se observa que el 37% de la varianza en el error de pronóstico de GT es explicada por las innovaciones en el PBI, mientras que el 40% del error de pronóstico del PBI es explicado por las innovaciones en GT. Este último aspecto difiere significativamente con respecto al modelo VAR de la sección anterior, ya que en aquel entonces este porcentaje era sólo 9%. Esto, sin embargo, es de esperar ya que el gas entregado al total de usuarios es un indicador que por sus características está mucho más vinculado al PBI que la serie correspondiente al volumen de gas residencial.

**Figura 9**



<sup>16</sup> Los resultados completos de la estimación pueden consultarse en el anexo.

La figura 9 y la tabla 6 resumen los resultados del pronóstico. El coeficiente de Theil es sólo levemente mayor al del modelo anterior. Al igual que en los otros dos modelos, el error sistemático es superior al 50%.

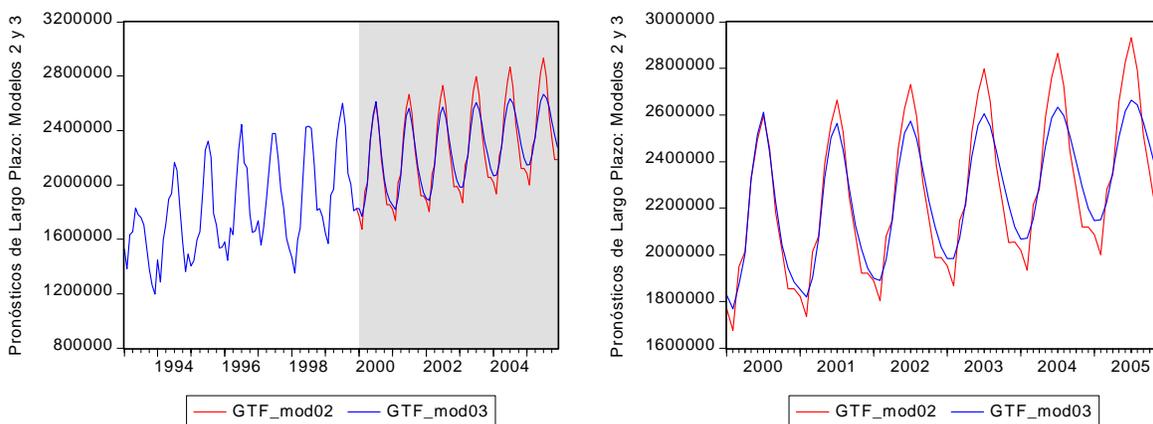
La subestimación invernal es muy similar a la del modelo 2, y también presenta la característica de ser bastante suave (la subestimación mayor se da en el mes de agosto con un valor de  $-7\%$ ). No obstante, pese a que el pronóstico invernal es muy similar al del modelo anterior, la sobreestimación en los meses de verano es más pronunciada en este caso.

**Tabla 6**

<b>Modelo (3) – GT</b>							
<b>Período</b>	<b>GRF</b>	<b>GR</b>	<b>Error</b>	<b>Período</b>	<b>GRF</b>	<b>GR</b>	<b>Error</b>
<b>Jun-00</b>	2515152	2500618	1%	<b>nov-00</b>	1943570	1683327	15%
<b>Jul-00</b>	2611812	2769586	-6%	<b>dic-00</b>	1882074	1855960	1%
<b>ago-00</b>	2440505	2637176	-7%	<b>ene-01</b>	1851138	1604707	15%
<b>sep-00</b>	2227687	2322923	-4%	<b>feb-01</b>	1818246	1540278	18%
<b>oct-00</b>	2042323	1967821	4%	<b>mar-01</b>	1902390	1868826	2%

Finalmente, vale la pena observar los errores de predicción acumulados de cada uno de los tres modelos durante el período de predicción. Con los datos de las tablas 4, 5 y 6 puede calcularse que el modelo 1 subestima el volumen anual en un 8%, mientras que los modelos 2 y 3 sobreestiman dicho volumen anual con un 1 y 2 por ciento, respectivamente. Así, estos resultados son mejores que los obtenidos en el caso del gas entregado a los usuarios residenciales.

**Figura 10**



La figura 10 muestra los pronósticos de largo plazo (hasta Diciembre de 2005) para los modelos 2 y 3. En la misma puede observarse cómo en este caso el modelo VAR pronostica un comportamiento cíclico que parece ir convergiendo en el largo plazo. Este resultado es consistente con el hecho de que todas las raíces del modelo VAR se encuentren dentro del círculo de la unidad (implicando la convergencia asintótica). Contrariamente, el modelo 2 muestra un patrón cíclico más o menos regular cuyo valor medio crece en el tiempo. En julio de 2005, el modelo 2 pronostica un 10% más de gas que el modelo 3 (magnitud menor que la obtenida para el gas residencial). Es evidente que en el muy largo plazo, no suena lógico trabajar con un modelo que implica que las oscilaciones estacionales desaparecerán. No obstante, puede ser que el pronóstico a corto o mediano plazo sea muy bueno. Esta es una muestra de cómo el horizonte de pronóstico es muy importante a la hora de elegir un buen predictor.

## V. Propiedades de una buena predicción

En las secciones anteriores pudo observarse cómo los modelos dos y tres producían mejores predicciones que el modelo uno, pero no quedaba del todo claro si uno de estos dos modelos era preferible al otro. En esta sección trataremos de hacer brevemente dos cosas: a) evaluar si estos dos modelos presentan predicciones óptimas; y b) comparar ambos modelos y decidir si hay ganancias en la combinación de ambos. Los análisis de esta sección se harán exclusivamente con los datos del gas entregado al total de usuarios simplemente por una cuestión de no extender el trabajo. Un análisis similar podría hacerse con los datos del gas entregado a los usuarios residenciales.

- *Un buen pronóstico debe ser insesgado y los errores de pronóstico 1 – período adelante son Ruido Blanco.*

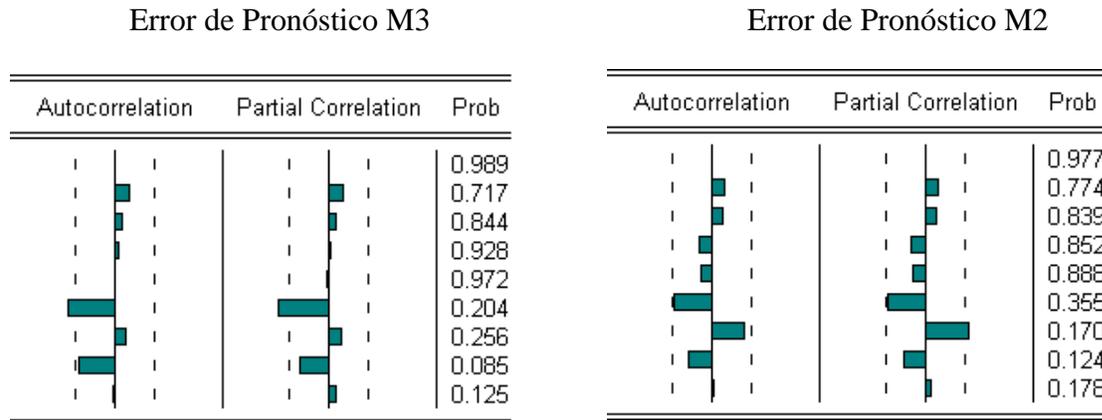
El hecho de que la predicción sea insesgada significa que los errores de pronóstico deben tener media nula. Por otro lado, una característica de un pronóstico óptimo es que los errores de pronóstico 1-período adelante son Ruido Blanco (ver Diebold). Para testear estas dos cosas se estimaron los modelos 2 y 3 varias veces y se obtuvieron predicciones un período hacia delante para ambos modelos durante el período 1999:01 – 2001:03.

A continuación se presentan los correlogramas de los errores de pronóstico 1 período hacia delante de los modelos 2 y 3. Tanto el análisis visual de la función de autocorrelación y la función de autocorrelación parcial como el p-value asociado al estadístico Q con 9 desplazamientos, muestran que no puede rechazarse la hipótesis nula de que los errores de pronósticos son Ruido Blanco.

Por otro lado, se corrieron dos regresiones de cada uno de los errores de pronóstico contra una constante. En el caso del modelo 2, el p-value asociado al estadístico t de la constante

fue igual a 0.55; mientras que el del modelo 3 fue igual a 0.86. Ambos resultados corroboran que no existen sesgos considerables en los errores de pronóstico un período hacia delante de los dos modelos. Así, tanto de análisis de los correlogramas como de las regresiones auxiliares podemos concluir que ambos modelos generan pronósticos óptimos.

**Figura 11**



➤ *El principio de impredecibilidad*

La idea de que los errores de pronóstico un período hacia delante deben ser ruido blanco proviene de un principio más general que establece que, si un pronóstico es óptimo, entonces no es posible mejorar el pronóstico con la información disponible al momento de hacer la predicción.

Una forma de testear si el pronóstico fue bueno de acuerdo a la información disponible es a través de la regresión de Mincer – Zarnowitz (1969). Esta regresión posee la siguiente forma:

$$y_{t+h} = \alpha + \beta y_{t+h,t} + u_t$$

donde si el pronóstico es óptimo de acuerdo al conjunto de información utilizado, debería esperarse que  $\alpha=0$  y  $\beta=1$ ; razón por la cual esta es la hipótesis nula del test. Los resultados de la regresión de Mincer –Zarnowitz para ambos modelos se presentan en la siguiente tabla.

Como podemos observar en la Tabla 7, ambos test no rechazan la hipótesis nula de que el pronóstico es óptimo para la información disponible. Así, hasta aquí podemos concluir que ambas predicciones presentan buenas propiedades y ninguna parecería ser mejor que la otra.

**Tabla 7**

<b>Mincer - Zarnowitz regression. Dependent Variable: TOTAL</b>							
	<i>Regression 1</i>				<i>Regression 2</i>		
	Coefficient	t-Stat	P-value		Coefficient	t-Stat	P-value
<b>C</b>	-155095.5	-1.192	0.2444	<b>C</b>	-780.445	-0.005	0.996
<b>Total - M2</b>	1.082	17.087	0.0000	<b>Total - M3</b>	0.998	13.270	0.000
	<i>R-squared</i>	0.921126			<i>R-squared</i>	0.875676	
	<i>D-W stat</i>	2.184475			<i>D-W stat</i>	1.969302	
Null H0:	$\alpha = 0$	F - stat	1.03931	Null H0:	$\alpha = 0$	F - stat	0.0145
	$\beta = 1$	P-value	0.36848		$\beta = 1$	P-value	0.9855

➤ *Comparación y combinación de pronósticos*

Dado que de los análisis anteriores no se detectaron ventajas de un modelo frente a otro, ahora trataremos de testear si alguno de ellos incorpora toda la información relevante del otro a través de un simple test. Si se llegase a la conclusión de que un modelo incorpora toda la información relevante del otro, no habría ganancias en intentar formar un pronóstico ponderado de los dos modelos. En cambio, si ninguno de los modelos abarca al otro, sería una señal de que formar un pronóstico ponderado podría generar ganancias de eficiencia en la predicción. Consideremos la siguiente regresión:

$$y_{t+h} = \beta y_{t+h,t}^{M2} + \gamma y_{t+h,t}^{M3} + u_t$$

En este caso, si alguno de los coeficientes ( $\beta$  o  $\gamma$ ) es uno y el otro es cero, esto significaría que uno de los modelos domina al otro. Si no se da ninguno de estos dos casos, entonces ningún modelo domina al otro y hay ganancias en combinarlos.

**Tabla 8**

<b>Combination Regression. Dependent Variable: TOTAL</b>				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
<b>Total - M2</b>	1.028787	0.293409	3.506318	0.0017
<b>Total - M3</b>	-0.020754	0.290699	-0.071394	0.9437
	<i>R-squared</i>	0.9211	<i>D-W stat</i>	2.1844
Null H0: $\beta = 1$ $\gamma = 0$				
F-statistic	0.3137		P-value	0.7335

Los resultados indican que el modelo 2 abarca al 3, con lo cual no existirían ganancias de combinar ambos modelos formando un promedio ponderado de ambos. Como conclusión, ambos modelos presentan propiedades óptimas, pero el modelo 2 incorpora toda la información del modelo 3. De todos modos, no debe olvidarse que la cantidad de datos disponible no es lo suficientemente grande como para extraer conclusiones totalmente concluyentes.

## **VI. Conclusiones**

En el presente trabajo se utilizaron tres modelos alternativos para pronosticar los valores de el gas entregado al total de usuarios de la red y el gas entregado a los usuarios residenciales. La motivación vino dada por la necesidad crucial de estimar la demanda de los servicios en las revisiones tarifarias que usualmente se realizan cada cinco años bajo un esquema de precios máximos. Como se argumentó al comienzo del trabajo, la intención no es concluir que estas herramientas son las que deben ser utilizadas a la hora de realizar el pronóstico, sino más bien sentar las bases de un análisis que tenga en cuenta las distintas particularidades de cada modelo predictivo, realizando una adecuada comparación entre los mismos.

Los resultados muestran que los modelos de series de tiempo superan al modelo clásico sobre la base de la evaluación de la predicción. No obstante, todos los modelos comparten la característica común de subestimar la demanda invernal.

En el caso del gas entregado a los usuarios residenciales las subestimaciones invernales oscilaron entre el 6 y el 20 por ciento. El segundo modelo utilizado fue el que realizó mejores pronósticos para el invierno, aunque durante los meses de verano se observó una sobreestimación superior a la de los otros modelos. Así, en este caso quedó abierta la discusión sobre la preferencia de un modelo que realice una mejor predicción en los meses de alta demanda (con errores en los meses de baja demanda) frente a otro que cometa errores en los meses de alta demanda (con buenas predicciones en los de baja demanda). Por otro lado, independientemente de las oscilaciones mensuales, se mostró que el error sobre el volumen entregado anualmente fue cercano al 1%. Si tenemos que cuenta que desde el punto de vista de la sostenibilidad de la empresa esta magnitud puede ser más importante que las oscilaciones estacionales dentro de cada año, los resultados parecerían ser bastante favorables.

Los resultados para el caso del gas entregado al total de usuarios fueron aún mejores. Las subestimaciones del período invernal provocadas por el segundo y tercer modelo estuvieron en torno al 5%, mostrando nuevamente la superioridad frente al modelo clásico que mostró una subestimación promedio invernal de 13%. De todos modos, nuevamente los errores para el volumen total anual fue cercano al 1% para estos dos modelos, mientras que la subestimación anual del primer modelo fue del orden del 8%.

La idea de este trabajo es mostrar que los modelos de series de tiempo pueden ser útiles a la hora de realizar una revisión tarifaria y pronosticar la demanda. Muchas veces se utilizan modelos de alta complejidad que, en última instancia, terminan dependiendo casi exclusivamente de las conjeturas que puedan hacerse sobre los acontecimientos futuros. Si bien esto estaría dentro del espíritu *forward looking* del esquema regulatorio, presenta la desventaja de ser altamente sensible a las subjetividades de cada parte en la negociación sobre los posibles acontecimientos. La herramienta aquí presentada se basa puramente en la historia pasada, y por este motivo presenta una objetividad que debería ser tenida en cuenta. Así, la conclusión no es que esta deba ser la única herramienta utilizada, sino que a la hora de armar distintos escenarios, ésta constituya uno de ellos.

## REFERENCIAS

Diebold, F. (1998): *Elements of Forecasting*, South-Western College Publishing, Cincinnati.

Gomez Lobo, A. And Foster, V. (1999): *The 1996-97 Gas Price Review in Argentina*, Public Policy for the Private Sector, Note N° 181

Granger, C. W. J. (1989): *Forecasting in Business and Economics*, second edition, Academic Press, San Diego.

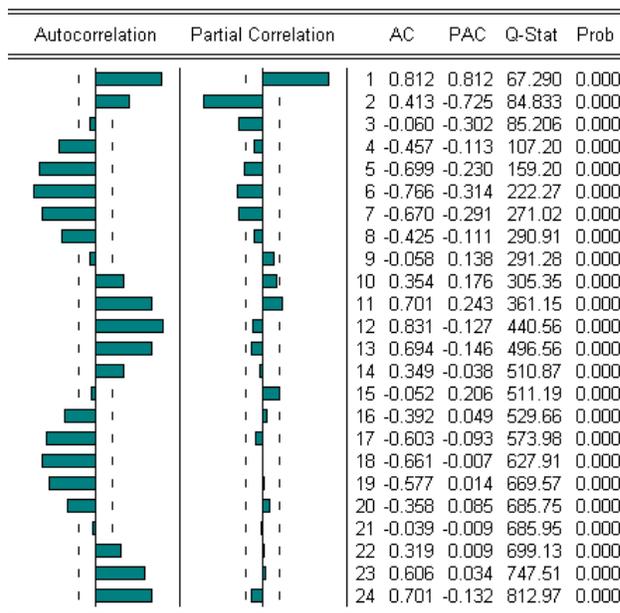
Hamilton, J. (1994): *Time Series Analysis*, Princeton University Press, Princeton NJ.

Mincer, J. and Zarnowitz, V. (1969): *The Evaluation of Economic Forecast*, in J. Mincer (ed.), *Economic Forecast and Expectations*. New York: National Bureau of Economic Research.

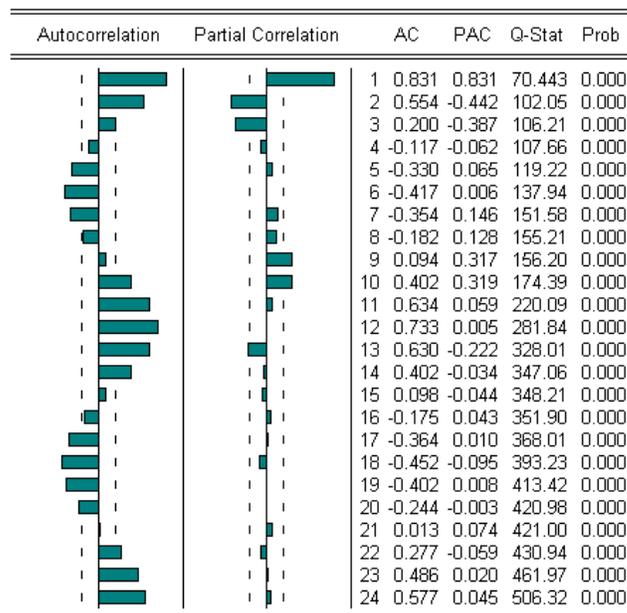
Shleifer, A. (1985): *A Theory of Yardstick Competition*, *Rand Journal of Economics*, Vol. 16, 3, Autumn, 319-327.

## ANEXO A

*Correlograma GR*



*Correlograma GT*



*VAR GR (sólo se muestran los resultados correspondientes a la ecuación de GR)*

Variable dependiente: GR						<i>R-squared</i>	0.961
<b>PBI(-1)</b>	-3.274001	<b>PBI(-12)</b>	2.147599	<b>GR(-4)</b>	-0.187594	<b>Det. Res. Cov.</b>	2.64E+16
	[-1.56825]		[ 2.38790]		[-2.18481]	<b>Log Likeli.</b>	-1674.348
<b>PBI(-2)</b>	4.863855	<b>GR(-1)</b>	0.295596	<b>GR(-12)</b>	0.570892	<b>Akaike</b>	44.113
	[ 1.34342]		[ 2.49245]		[ 5.10750]	<b>Schwarz</b>	44.844
<b>PBI(-3)</b>	5.850362	<b>GR(-2)</b>	-0.046209	<b>@trend</b>	-111.4392		
	[ 1.47251]		[-0.38982]		[-0.13791]		
<b>PBI(-4)</b>	-8.843338	<b>GR(-3)</b>	0.052239	<b>C</b>	-22130.16		
	[-3.00251]		[ 0.45568]		[-0.09399]		

Entre corchetes se presentan los estadísticos t.

Los criterios de información, el valor de la Log Likelihood y del determinante corresponden al sistema

VAR GT (sólo se muestran los resultados correspondientes a la ecuación de GR)

Variable dependiente: GT						<i>R-squared</i>	<b>0.913</b>
<b>GT(-1)</b>	0.38589 [ 2.95273]	<b>GT(-5)</b>	-0.091455 [-0.76871]	<b>PBI(-3)</b>	18.34718 [ 2.49643]	<b>C</b>	1.03E+06 [ 1.96482]
<b>GT(-2)</b>	0.11651 [ 0.89032]	<b>GT(-12)</b>	0.176031 [ 1.55121]	<b>PBI(-4)</b>	-11.79694 [-1.50228]	<b>@trend</b>	3299.858 [ 1.74430]
<b>GT(-3)</b>	-0.046201 [-0.35403]	<b>PBI(-1)</b>	4.013013 [ 0.80830]	<b>PBI(-5)</b>	-7.423222 [-1.29072]	<b>Det. Res. Cov.</b>	6.12E+16
<b>GT(-4)</b>	-0.146349 [-1.11027]	<b>PBI(-2)</b>	-7.193638 [-0.92864]	<b>PBI(-12)</b>	3.905755 [ 2.19483]	<b>Log Likel.</b>	-1706.68
						<b>Akaike</b>	45.056
						<b>Schwarz</b>	45.91

Entre corchetes se presentan los estadísticos t.

Los criterios de información, el valor de la Log Likelihood y del determinante corresponden al sistema

## Serie Textos de Discusión CEER

Para solicitar alguno de estos documentos o suscribirse a toda la Serie Textos de Discusión CEER, vea las instrucciones al final de la lista. Un listado comprehensivo de la Serie textos de Discusión CEER puede hallarse en nuestro web site.

STD 1. Laffont, Jean Jacques: Llevando los principios a la práctica en teoría de la regulación (marzo 1999)

STD 2. Stiglitz, Joseph: The Financial System, Bussiness Cycle and Growth (marzo 1999)

STD 3. Chisari, Omar y Antonio Estache: The Needs of the Poor in Infrastructure Privatization: The Role of Universal Service Obligations. The Case of Argentina (marzo 1999)

STD 4. Estache, Antonio y Martín Rossi: Estimación de una frontera de costos estocástica para empresas del sector agua en Asia y Región del Pacífico (abril 1999)

STD 5. Romero, Carlos : Regulaciones e inversiones en el sector eléctrico (junio 1999)

STD 6. Mateos, Federico: Análisis de la evolución del precio en el Mercado Eléctrico Mayorista de la República Argentina entre 1992 y 1997 (julio 1999).

STD 7. Ferro, Gustavo: Indicadores de eficiencia en agua y saneamiento a partir de costos medios e indicadores de productividad parcial (julio 1999)

STD 8. Balzarotti, Nora: La política de competencia internacional (septiembre 1999)

STD 9. Ferro, Gustavo: La experiencia de Inglaterra y Gales en micromedición de agua potable (septiembre 1999)

STD 10. Balzarotti, Nora: Antitrust en el mercado de gas natural (octubre 1999)

STD 11. Ferro, Gustavo: Evolución del cuadro tarifario de Aguas Argentinas: el financiamiento de las expansiones en Buenos Aires (octubre 1999)

STD 12. Mateos, Federico, Martín Rodríguez Pardina y Martín Rossi: Oferta y demanda de electricidad en la Argentina: un modelo de ecuaciones simultáneas (noviembre 1999)

STD 13. Ferro, Gustavo: Lecciones del Seminario Proyección de Demanda de Consumo de Agua Potable (noviembre 1999)

STD 14: Rodríguez Pardina, Martín y Martín Rossi: Medidas de eficiencia y regulación: una ilustración del sector de distribuidoras de gas en la Argentina (diciembre 1999)

STD 15: Rodríguez Pardina, Martín, Martín Rossi y Christian Ruzzier: Fronteras de eficiencia en el sector de distribución de energía eléctrica: la experiencia sudamericana (diciembre 1999)

STD 16: Rodríguez Pardina, Martín y Martín Rossi: Cambio tecnológico y catching up: el sector de distribución de energía eléctrica en América del Sur (marzo 2000)

STD 17: Ferro, Gustavo: El servicio de agua y saneamiento en Buenos Aires: privatización y regulación (abril 2000).

- STD 18: Celani, Marcelo: Reformas en la industria de las telecomunicaciones en Argentina (junio 2000).
- STD 19: Romero, Carlos: La desregulación de la comercialización de electricidad en Inglaterra y Gales (junio 2000).
- STD 20: Rossi, Martín: Midiendo el valor social de la calidad de los servicios públicos: el agua
- STD 21: Rodríguez Pardina, Martín: La concesión de Aguas Argentinas. (noviembre 2000).
- STD 22: Rossi, Martín e Iván Canay: Análisis de eficiencia aplicado a la regulación ¿Es importante la Distribución Elegida para el Término de Ineficiencia? (noviembre 2000)
- STD 23: Ferro, Gustavo: Los instrumentos legales de la renegociación del contrato de Aguas Argentinas (1997-99) (diciembre 2000).
- STD 24: Briggs, María Cristina y Diego Petrecollo: Problemas de competencia en la asignación de la capacidad de los aeropuertos. El Caso Argentino (marzo 2001).
- STD 25: Ferro, Gustavo: Riesgo político y riesgo regulatorio: problemas en la concesión de sectores de infraestructura (marzo 2001).
- STD 26: Ferro, Gustavo: Aguas del Aconquija: revisión de una experiencia fallida de privatización (abril 2001).
- STD 27: Ferro, Gustavo y Marcelo Celani: Servicio universal en telecomunicaciones: concepto y alcance en Argentina (junio 2001).
- STD 28: Bondorevsky, Diego: Concentración horizontal en el sector de distribución eléctrica en Argentina. (julio 2001).
- STD 29: Bondorevsky, Diego y Diego Petrecollo: Estructura del mercado de gas natural en Argentina e integración energética regional: Problemas de defensa de la competencia (julio 2001).
- STD 30: Ferro, Gustavo: Participación del Sector Privado y Regulación en Agua y Saneamiento en Argentina: Casos Seleccionados (julio 2001)
- STD 31: Ferro, Gustavo: Desempeño reseñado de la concesión de agua y saneamiento metropolitana durante 1993-2001
- STD 32: Bondorevsky Diego y Diego Petrecollo: Concesiones de agua y saneamiento en Argentina: Impacto en los sectores pobres (julio 2001).
- STD 34: Romero, Carlos: Servicio universal en el proceso de privatización de las empresas de telecomunicaciones y agua potable y alcantarillado en el Paraguay (septiembre 2001).
- STD 35-A: Bondorevsky, Diego y Romero Carlos: Fusiones y adquisiciones en el sector eléctrico: Experiencia internacional en el análisis de casos (diciembre 2001)
- STD 35-B: Canay, Iván: Eficiencia y Productividad en Distribuidoras Eléctricas: Repaso de la metodología y aplicación (febrero 2002).
- STD 36: Ullberg, Susann: El Apagón en Buenos Aires 1999 Manejo de crisis en los sectores privados y Públicos en la Argentina (marzo 2002).

STD 37: Celani Marcelo, Petrecolla Diego, Ruzzier, Christian: Desagregación de Redes en Telecomunicaciones: Una Visión desde la Política de Defensa de la Competencia (abril 2002).

STD 38: Bondorevsky Diego, Petrecolla Diego, Romero Carlos, Ruzzier Christian: Competencia por Comparación en el Sector de Distribución Eléctrica: El Papel de la Política de Defensa de la Competencia (abril 2002).

STD 39: Cardozo Javier, Devoto Alberto: La tarifa de distribución antes y después de la Reestructuración del Sector Eléctrico (mayo 2002).

STD 40: Canay, Iván: Modelando el Gas entregado en Argentina: ¿Cuál es el mejor Predictor? (mayo 2002).

## CEER Working Paper Series

To order any of these papers, or all of these, see instructions at the end of the list. A complete list of CEER Working Papers is displayed here and in our web site.

---

WPS 1. Laffont, Jean Jacques: Translating Principles Into Practice in Regulation Theory (March 1999)

WPS 2. Stiglitz, Joseph: Promoting Competition in Telecommunications (March 1999)

WPS 3. Chisari, Omar, Antonio Estache, y Carlos Romero: Winners and Losers from Utility Privatization in Argentina: Lessons from a General Equilibrium Model (March 1999)

WPS 4. Rodríguez Pardina, Martín y Martín Rossi: Efficiency Measures and Regulation: An Illustration of the Gas Distribution Sector in Argentina (April 1999)

WPS 5. Rodriguez Pardina, Martín Rossi and Christian Ruzzier: Consistency Conditions: Efficiency Measures for the Electricity Distribution Sector in South America (June 1999)

WPS 6. Gordon Mackerron: Current Developments and Problems of Electricity Regulation in the European Union and the United Kingdom (November 1999)

WPS 7. Martín Rossi: Technical Change and Efficiency Measures: The Post-Privatisation in the Gas Distribution Sector in Argentina (March 2000)

WPS 8. Omar Chisari, Martín Rodriguez Pardina and Martín Rossi: The Cost of Capital in Regulated Firms: The Argentine Experience (May 2000)

WPS 9. Omar Chisari, Pedro Dal-Bó and Carlos Romero: High Tension Electricity Network Expansions in Argentina: Decision Mechanisms and Willingness-to-Pay Revelation (May 2000).

WPS 10. Daniel A. Benitez, Antonio Estache, D. Mark Kennet, And Christian A. Ruzzier. Potential Role of Economic Cost Models in the Regulation of Telecommunications in Developing Countries (August 2000).

WPS 11. Martín Rodríguez Pardina and Martín Rossi. Technical Change and Catching-up: The Electricity Distribution Sector in South America

WPS 12. Martín Rossi and Iván Canay. Measuring Inefficiency in Public Utilities: Does the Distribution Matter?

WPS 13. Quesada, Lucía. Network Competition and Network Regulation (July, 2001).

WPS 14. Rossi, Martín and Christian Ruzzier: Reducing the Asymmetry of Information Through the Comparison of the Relative Efficiency of Several Regional Monopolies (July 2001).

WPS 15. Ferro, Gustavo: Political Risk and Regulatory Risk: Issues in Emerging Markets Infrastructure Concessions (August, 2001).



Centro de Estudios Económicos de la Regulación

Solicitud de incorporación a la lista de receptores de publicaciones del CEER

Deseo recibir los ejemplares correspondientes a la serie (marque con una cruz la que corresponda), que se publiquen durante 2001:

- a) Working Papers Series                      (...) impreso                      (...) e-mail, formato pdf
- b) Serie de Textos de Discusión                      (...) impreso                      (...) e-mail, formato pdf

Mi nombre es:.....

Ocupación:.....

Domicilio:.....

.....

Firma

Tenga a bien enviar esta solicitud por correo a:

SECRETARIA CEER

Lima 717, 1° piso

C1073AAO Buenos Aires - Argentina

Por fax, al 54-11-43797588

E-mail: [ceer@uade.edu.ar](mailto:ceer@uade.edu.ar)