



Blaconá, María Teresa*

Bussi, Javier**

Ventroni, Nora**

**Instituto de Investigaciones Teóricas y Aplicadas de la Escuela de Estadística, Facultad de Ciencias Económicas y Estadística. Consejo de Investigaciones, Universidad Nacional de Rosario. E-mail: mblacona@agatha.unr.edu.ar*

*** Instituto de Investigaciones Teóricas y Aplicadas de la Escuela de Estadística, Facultad de Ciencias Económicas y Estadística, Universidad Nacional de Rosario.*

ANÁLISIS DE LAS TASAS DE DESOCUPACIÓN DEL GRAN ROSARIO Y GRAN BUENOS AIRES A TRAVÉS DE MODELOS UNIVARIADOS DE SERIES DE TIEMPO (1º 1974 – 2º 2002)

I. INTRODUCCIÓN

Una de las características de la serie tasa de desocupación en los aglomerados Gran Rosario (GR) y Gran Buenos Aires (GBA), es que presentan puntos de quiebre en su comportamiento, en la segunda onda de 1994, como muestra el trabajo realizado para los aglomerados urbanos de Argentina, período 1974-1998, por Arrufat et al. (1999).

En este trabajo se analizan las series de tasa de desocupación de GR y GBA. El enfoque propuesto privilegia el tratamiento de dos aspectos:

- i) probar las bondades de distintos modelos para explicar principalmente los cambios de estructura;
- ii) determinar a partir de dichos modelos cuáles son los aspectos más relevantes que se presentan en los dos aglomerados, como así también sus coincidencias y diferencias.

Las tasas corresponden a la información bianual provista por la Encuesta Permanente de Hogares (EPH-INDEC) en los meses de mayo y octubre (1ra. y 2da. onda respectivamente). Con el fin de determinar si existen otros cambios de estructuras en los dos aglomerados mencionados desde la 1era. onda de 1974 hasta la 2da. onda de 2002, se analizan las series en forma univariada. Se emplearán dos tipos de modelos: i) modelos de espacio de estado (Harvey, 1981) y, ii) ARIMA (Box and Jenkins, 1970).

Los modelos de espacio de estado permiten modelar la tendencia y estacionalidad, aceptando la posibilidad de que sean estocásticas. Así mismo, permiten detectar cambios en la estructura de las series y modelarlos en forma sencilla.



Al trabajar con procesos ARIMA, se desarrollan los modelos propuestos por Franses (1998) que modelan puntos aberrantes, cambios de nivel y/o de tendencia. Se intenta determinar además si las series poseen raíz unitaria, teniendo en cuenta que si se ignoran las características enumeradas, se pueden aceptar raíces unitarias no existentes (Perron, 1990).

En la Sección II de este trabajo se definen los conceptos de puntos aberrantes y cambios de estructura. En la Sección III se presentan los modelos de espacio de estado y se postulan modelos para las series de tasa de desocupación. En la Sección IV se describe en forma breve la construcción de modelos ARIMA con puntos aberrantes, cambios de nivel y/o tendencia y se realiza el estudio empírico sobre las tasas de desocupación probando la presencia de raíces unitarias. Por último en la Sección V se presenta una discusión de los resultados hallados.

II. PUNTOS ABERRANTES Y CAMBIOS DE ESTRUCTURA

En la mayoría de los casos, las series económicas presentan observaciones que son notoriamente distintas del resto de las de la serie, en consecuencia el modelo subyacente de la serie no se adapta a dichas observaciones. Estas últimas son llamadas puntos aberrantes u outliers. Existen dos clases de puntos aberrantes en el análisis de series de tiempo que se modelan de forma distinta.

Outlier Aditivo (AO): En este caso el punto aberrante es considerado una observación genuina de la serie más un cierto valor. Este valor adicionado puede responder a distintas razones, pero ellas no dependen del proceso económico que genera la serie (Franses, 1998).

Outlier Innovador (IO): Este valor aberrante produce un cambio en el comportamiento de la serie que afecta las observaciones en el momento del impacto y tiene un efecto sobre los momentos posteriores. Se lo suele modelar incorporándolo al proceso ruido. El IO se puede interpretar en algunos casos como un cambio de estructura en la serie, como puede ser un cambio en el nivel y/o en la pendiente de la misma.

Cambio de nivel: El impacto producido en un momento en la serie produce un cambio de nivel permanente o transitorio de la misma.

Cambio de pendiente: En ciertos eventos, por ejemplo una crisis económica, cambia la estructura en forma tal que la tendencia antes del evento es diferente de la tendencia después del mismo.

Los puntos aberrantes y cambios de estructura pueden ser modelados. La forma de hacerlo varía según se usen modelos de espacio de estado o modelos ARIMA. Una de las consecuencias de ignorarlos cuando se utilizan estos últimos es que pueden hallarse raíces unitarias espúreas, en otras palabras, hallar raíces unitarias cuando en realidad no existen.



III. MODELO DE ESPACIO DE ESTADO

Los modelos de espacio de estado, también conocidos como modelos estructurales, pueden ser interpretados como regresiones sobre funciones del tiempo en las cuales los parámetros varían en el tiempo. Esto hace que sean un vehículo natural para tratar series con cambios de nivel y/o tendencia.

III.1 MODELO BÁSICO DE ESPACIO DE ESTADO

El modelo básico de espacio de estado (MBEE), que también se conoce como modelo lineal Gaussiano de espacio de estado, se puede expresar como

$$\begin{aligned} \mathbf{y}_t &= \mathbf{Z}_t \boldsymbol{\alpha}_t + \boldsymbol{\varepsilon}_t, & \boldsymbol{\varepsilon}_t &\sim \text{NID}(\mathbf{0}, \mathbf{H}_t), \\ \boldsymbol{\alpha}_t &= \mathbf{T}_t \boldsymbol{\alpha}_{t-1} + \mathbf{R}_t \boldsymbol{\eta}_t, & \boldsymbol{\eta}_t &\sim \text{NID}(\mathbf{0}, \mathbf{Q}_t). \end{aligned} \quad (\text{III.1.1})$$

Donde \mathbf{y}_t es un vector de orden $p \times 1$ de observaciones, $\boldsymbol{\alpha}_t$ es un vector de orden $m \times 1$ no observable denominado vector de estado, las matrices $\mathbf{Z}_t(p \times m)$, $\mathbf{T}_t(m \times m)$ y $\mathbf{R}_t(m \times g)$ son conocidas y $\boldsymbol{\eta}_t$ es un vector aleatorio de orden $g \times 1$. Se introduce la matriz \mathbf{R}_t como matriz de selección, está formada de ceros y unos de acuerdo a si los $\boldsymbol{\eta}$ son determinísticos o aleatorios.

A la primera ecuación de (III.1.1) por lo general se la llama ecuación de medida y a la segunda, ecuación de transición. El desarrollar la teoría de los modelos de espacio de estado a partir del modelo general (III.1.1) puede resultar dificultoso, por ello en las secciones siguientes se especificará un modelo estructural adecuado para las series de tasas de desocupación.

III.2 MODELO ESTRUCTURAL BÁSICO

Dada una serie de tiempo y_1, \dots, y_T , el modelo estructural básico (BSM) se formula en términos de los componentes tendencia, estacionalidad e irregular. El modelo se puede escribir

$$y_t = \mu_t + \gamma_t + \varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma_\varepsilon^2) \quad t=1, \dots, T, \quad (\text{III.3.1})$$

donde μ_t , γ_t y ε_t representan a la tendencia, estacionalidad e irregular, respectivamente.

La idea central de los modelos estructurales se basa en el hecho de que, en muchas aplicaciones como la que nos ocupa, la tendencia y los efectos estacionales conforman los aspectos más destacables de las series de tiempo. Es por ello, que la construcción del modelo está orientada a la estimación y análisis de estos componentes.

La especificación de los componentes μ_t , γ_t , ε_t se basa en el conocimiento que se tenga acerca del proceso que se analiza y en técnicas estadísticas. Por ejemplo, para el caso de



las tasas de desocupación, se puede pensar un modelo general con nivel, pendiente y estacionalidad aleatorias como sigue:

$$\begin{aligned}y_t &= \mu_t + \gamma_t + \varepsilon_t, & \varepsilon_t &\sim N(0, \sigma_\varepsilon^2) & t=1, \dots, T, \\ \mu_t &= \mu_{t-1} + \beta_{t-1} + \eta_t, & \eta_t &\sim N(0, \sigma_\eta^2), \\ \beta_t &= \beta_{t-1} + \xi_t, & \xi_t &\sim N(0, \sigma_\xi^2), \\ \gamma_t &= -\gamma_{t-1} + \omega_t & \omega_t &\sim N(0, \sigma_\omega^2).\end{aligned}\tag{III.2.2}$$

La estacionalidad se puede representar por variables "dummy". Un punto importante es que, aunque el componente estacional sea no estacionario, tiene la propiedad de que el valor esperado de la suma de los s períodos ($s=2$ en este caso) es cero. Esto asegura que el efecto estacional no se confunda con la tendencia y también que los pronósticos del componente estacional deberán sumar cero sobre cualquier período anual.

Para estimar los componentes se aplica el filtro de Kalman que utiliza un procedimiento en tres etapas, consistente en: filtrado, iniciación y suavizado. El supuesto básico del filtro de Kalman es que los disturbios y el vector de estado inicial son gaussianos. Entonces, basado en la distribución normal multivariada, se puede calcular recursivamente la distribución de α en el modelo (III.1.1), condicionada a la información en el tiempo t , para todo $t = 1, 2, \dots, T$. Como a su vez estas distribuciones condicionales son gaussianas, sus matrices de medias y variancias están completamente especificadas.

La serie de errores de la etapa de suavizado se utiliza para la construcción de pruebas de diagnóstico para puntos aberrantes y cambios de nivel.

Para la estimación de las variancias, llamadas hiperparámetros, se utiliza el método de máxima verosimilitud, en el cual se puede realizar la maximización por el algoritmo EM.

En caso de que algún componente resulte no significativo, se lo excluye del modelo. Por otro lado, si el componente es significativo, según sea la variancia del error correspondiente, dicho componente se considera fijo (variancia=0) o estocástico (variancia $\neq 0$). Por ejemplo si $\sigma_\omega^2 = 0$, el componente estacional será considerado determinístico.

III.3 PUNTOS ABERRANTES, CAMBIOS DE NIVEL Y/O TENDENCIA EN MODELOS DE ESPACIO DE ESTADO

Las definiciones de puntos aberrantes, cambios de nivel y/o tendencia se formularon en la sección II.



En el marco de los modelos de espacio de estado se puede pensar que una observación atípica contiene un valor inusualmente grande (en valor absoluto) en el disturbio ε_t del modelo (III.2.2); un cambio de nivel, un valor inusualmente grande en el disturbio η_t y un cambio de pendiente, un disturbio grande ξ_t .

La rutina del programa STAMP 5.0 utiliza los residuos auxiliares para detectar los puntos aberrantes o cambios de estructura. Por ejemplo, para realizar el test de punto aberrante, la estadística se construye a partir de los residuos suavizados de los irregulares y viene definida por:

$$\varepsilon_e = \frac{\hat{u}_t}{\hat{\sigma}_u}, \text{ donde } \hat{u}_t \text{ son los residuos suavizados estimados del irregular.}$$

III.4 MODELOS DE ESPACIO DE ESTADO PARA LAS SERIES TASAS DE DESOCUPACIÓN

En esta sección se presentan los modelos ajustados a las series de tasa de desocupación de GR y GBA, destacando sus principales características.

III.4.1 SERIE TASA DE DESOCUPACIÓN GRAN ROSARIO

El modelo de espacio de estado que ajusta esta serie es el siguiente:

$$y_t = \mu_t + \gamma_t + Ir_{89.1} + \varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma_\varepsilon^2), \quad t = 74.1 \text{ al } 02.2,$$

$$\mu_t = \mu_{t-1} + CN_{95.1} + CN_{97.1} + CN_{01.2} + \eta_t, \quad \eta_t \sim N(0, \sigma_\eta^2),$$

$$\gamma_t = -\gamma_{t-1}, \tag{III.4.1.1}$$

Ir: punto aberrante, CN: cambio de nivel.

La serie presenta nivel aleatorio, estacionalidad determinística, un punto aberrante en la 1er. onda de 1989 y tres cambios de nivel en 1er. onda de 1995, 1er. onda de 1997 y 2da. onda de 2001. Los coeficientes estimados del nivel (al final del vector de estado), el componente estacional, punto aberrante y cambios de nivel se presentan en la Tabla III.4.1.1.

Las medidas de bondad de ajuste de normalidad (test de Bowman y Shenton, test F de heterocedasticidad, test de Durbin-Watson de presencia de errores autocorrelacionados de primer orden y test de Ljung-Box de residuos autocorrelacionados) son satisfactorias. El criterio de Akaike resulta AIC=1.1049 (el menor valor de los modelos postulados).



Tabla III.4.1.1: Coeficientes estimados del modelo para la serie tasa de desocupación de Gran Rosario

Coeficiente	Estimación	Desvío st.	Valor t	Prob. asoc.
Nivel (μ_t)	20.74	0.7431	27.9	0.0000
Estacional. (γ_t)	0.566	0.1424	3.98	0.0002
$Ir_{89.1}$	5.54	1.3244	4.18	0.0001
$CN_{95.1}$	7.11	1.5646	4.55	0.0000
$CN_{97.1}$	-3.86	1.5646	-2.47	0.0165
$CN_{01.2}$	4.03	1.5655	2.57	0.0127

$$\sigma_\varepsilon = 0.875, \sigma_\eta = 1.1556.$$

El nivel estocástico al final del periodo llega a 20.74. Los coeficientes estacionales determinísticos son 0.57 para la primera onda y -0.57 para la segunda. El punto atípico correspondiente a la primer onda de 1989 es 5.54 puntos superior al valor esperado. El cambio de nivel de la primer onda de 1995 incrementa a éste en 7.11 puntos mientras que el de la primera onda de 1997 disminuye al mismo en 3.86 y por último, en la segunda onda de 2001 se incrementa en 4.03 puntos.

III.4.2 SERIE TASA DE DESOCUPACIÓN GRAN BUENOS AIRES

Esta serie se representa por el siguiente modelo

$$y_t = \mu_t + \gamma_t + \varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma_\varepsilon^2), \quad t = 74.1 \text{ al } 02.2,$$

$$\mu_t = \mu_{t-1} + CN_{94.2} + CN_{95.1} + CN_{97.1} + CN_{01.2} + \eta_t, \quad \eta_t \sim N(0, \sigma_\eta^2),$$

$$\gamma_t = -\gamma_{t-1}, \tag{II.4.2.1}$$

CN: cambio de nivel.

La serie presenta nivel aleatorio, estacionalidad fija y cambios de nivel en la 2da. onda de 1994, 1er. onda de 1995, 1er. onda de 1997 y 2da. onda de 2001. Los coeficientes estimados del nivel (al final del vector de estado), el componente estacional y cambios de nivel se presentan en la Tabla III.4.2.1.

Las medidas de bondad de ajuste resultaron buenas y el criterio de Akaike fue el más chico de los modelos postulados, $AIC=0.2964$.



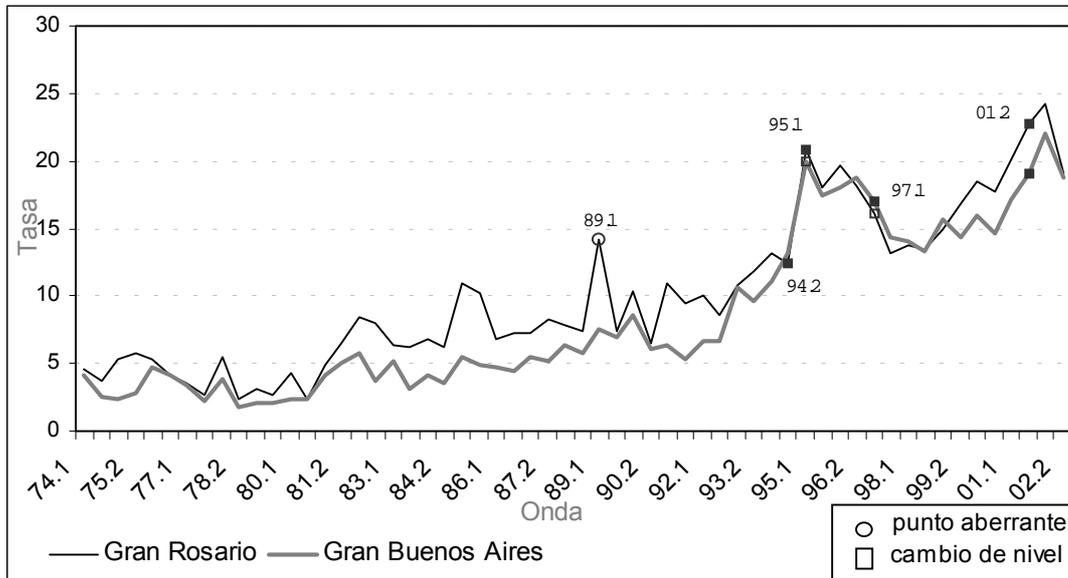
Tabla III.4.2.1: Coeficientes estimados del modelo para la serie tasa de desocupación de Gran Buenos Aires

Coeficiente	Estimación	Desvío st.	Valor t	Prob. asoc.
Nivel (μ_t)	19.41	0.1751	110.8	0.0000
Estacional. (γ_t)	0.563	0.0761	7.40	0.0000
CN _{94.2}	3.134	1.0957	2.86	0.0059
CN _{95.1}	5.94	1.095	5.42	0.0000
CN _{97.1}	-2.92	1.095	-2.67	0.0100
CN _{01.2}	2.996	1.095	2.74	0.0083

$$\sigma_\varepsilon = 0.161, \sigma_\eta = 1.0617.$$

El nivel estocástico al final del periodo llega a 19.41. Los coeficientes estacionales determinísticos son 0.56 para la primera onda y -0.56 para la segunda. El cambio de nivel se presenta a partir de la segunda onda de 1994 en forma gradual, aumentando en ésta en 3.13 puntos y en la siguiente 5.94, mientras que en la primera onda de 1997 disminuye en 2.92. Y por último en la segunda onda de 2001, se incrementa nuevamente en 3.00 puntos.

Gráfico III.4.3.1: Puntos aberrantes y cambios de nivel de las series Tasas de desocupación de Gran Rosario y Gran Buenos Aires





IV. RAÍCES UNITARIAS CON PRESENCIA DE PUNTOS ABERRANTES Y CAMBIOS DE ESTRUCTURA

En esta sección se analiza cómo se incorporan los puntos aberrantes y cambios de estructura en la modelación ARIMA y en la determinación de la presencia de raíces unitarias. Teniendo en cuenta que ignorar la presencia de puntos aberrantes y/o cambios de estructura puede conducir a raíces unitarias espúreas (Perron, 1989, 1990) e ignorar los AO conduce a encontrar estacionariedad espúrea (Franses and Haldrup, 1994). Por ello en este trabajo se utilizan los tests de raíz unitaria que tienen en cuenta la presencia de observaciones de este tipo.

Existen métodos recursivos para encontrar el momento de los puntos de quiebre. Por ejemplo el trabajo de Arrufat (1999) presenta el método de Zivot and Andrews (1992) para determinar los puntos de quiebre en la tasa de desocupación de los aglomerados urbanos de Argentina (incluyendo información hasta el año 1998). En dicho trabajo, Arrufat ajusta sendos modelos para ambos aglomerados (GR y GBA) en donde no se rechaza la hipótesis de presencia de raíz unitaria, teniendo en cuenta la presencia de un quiebre en la segunda onda de 1994. Para el aglomerado GBA, las variables explicativas incluyen intercepto, una variable indicadora que toma el valor 1 a partir del punto de quiebre, tendencia lineal, la propia variable rezagada un período y k términos rezagados de las diferencias de orden 1. El modelo para GR incluye además un cambio en la tendencia lineal a partir del punto de quiebre.

Por otro lado, a partir de los resultados obtenidos por modelos de espacio de estado para los dos aglomerados en estudio con información hasta la segunda onda del 2002, se encuentra un cambio de nivel para GBA en la segunda onda de 1994 (coincidiendo con el trabajo antes mencionado) pero además otros cambios: en la primer onda de 1995, en la primer onda de 1997 y en la segunda onda del 2001. Mientras que en GR se encuentra un punto aberrante en la primer onda de 1989 y cambios de nivel en: la primer onda de 1995, la primer onda de 1997 y la segunda onda del 2001.

Se plantea la presencia de raíz unitaria probando distintos modelos, teniendo en cuenta los quiebres encontrados en los modelos del punto II y los hallados por Arrufat. Se trabaja con los puntos de quiebre proporcionados por los modelos estructurales de GR y GBA, ya que presentan mejores ajustes según el criterio de Akaike.

IV.1 TEST DE RAÍZ UNITARIA CON DATOS IRREGULARES

Como se expresó anteriormente, cuando la serie presenta cambios de estructura y/o observaciones aberrantes, en muchos casos no es fácil decidir si una serie tiene o no, raíz unitaria.

IV.1.1 TEST DE RAÍZ UNITARIA

En el caso de un proceso AR(p):



$\phi_p(B)y_t = \varepsilon_t$, donde ε_t es ruido blanco.

Si el polinomio $\phi_p(B)=1-\phi_1B-\dots-\phi_pB^p = 0$ presenta una raíz unitaria, la serie es integrada de orden 1, I(1). Dickey y Fuller (1979) proponen probar la existencia de raíz unitaria en un proceso AR(p) a partir de:

$$\Delta_1 y_t = \rho y_{t-1} + \alpha_1 \Delta_1 y_{t-1} + \dots + \alpha_{p-1} \Delta_1 y_{t-(p-1)} + \varepsilon_t \quad (\text{IV.1.1.1})$$

La hipótesis de interés es:

$H_0) \rho=0$, siendo la alternativa $H_1) \rho < 0$.

Si la hipótesis nula no se rechaza, se concluye que la serie posee raíz unitaria. La estadística deducida por Phillips (1987) para realizar el test es: $t(\rho)$, la cual posee una distribución asintótica que no resulta ser una t de student estándar. Sus valores se determinan a través de simulaciones. Intuitivamente, bajo la hipótesis nula, la serie contiene una tendencia estocástica, haciendo que las variancias y covariancias dependan del tiempo. El denominador de la estadística t incluye una función de tales variancias, por lo tanto su distribución no es normal. La hipótesis nula se rechaza cuando el valor de la estadística es menor que el valor crítico.

Outlier Aditivo (AO)

Una manera de describir un AO es:

$$y_t = x_t + \omega I_t[t = \tau] \quad (\text{IV.1.1.2})$$

donde $I_\tau[.]$ es una variable indicadora que toma el valor 1 en el momento que se presenta la observación aberrante; x_t es el valor de la serie no observado, mientras que y_t es el valor observado. En la práctica, el tamaño del outlier denotado por ω puede ser estocástico y puede desconocerse el momento de su ocurrencia.

En caso de, por ejemplo, un proceso AR(1), ignorar un AO produce un sesgo hacia abajo en la estimación del parámetro, en consecuencia, aún cuando el verdadero valor del parámetro sea uno, la estimación puede ser menor que uno.

En consecuencia, el parámetro ρ en la regresión de Dickey Fuller se vuelve muy grande en valor absoluto y negativo. esto puede conducir a un valor significativo de la estadística $t(\rho)$, dependiendo del número de observaciones y la variancia del proceso ε_t . En otras



palabras, la distribución asintótica de la estadística se vuelve más asimétrica a la izquierda cuando se ignora un AO. Franses y Haldrup (1994) recomiendan incluir variables dummy para los AO detectados en la regresión auxiliar del test de Dickey-Fuller. Se puede demostrar que la estadística del test basado en la regresión ampliada asintóticamente sigue una distribución de Dickey Fuller.

Outlier Innovador (IO)

En un proceso ARMA(p,q) un IO se puede describir de la siguiente manera:

$$\phi_p(B)y_t = \theta_q(B)(\varepsilon_t + \omega I_t(t = \tau)), \quad (IV.1.1.3)$$

donde $I_t(\cdot)$ se suma al proceso error (o innovación).

Un IO en el tiempo τ puede resultar en un cambio permanente en el nivel de la serie de tiempo.

Por ejemplo, en un proceso AR(1) el cambio de nivel puede ser generado por:

$$y_t = \phi_1 y_{t-1} + \omega I_t(t \geq \tau) + \varepsilon_t \quad (IV.1.1.4)$$

Por lo tanto, un valor grande de ω parecería mostrar una tendencia creciente, y entonces puede ser dificultoso seleccionar entre un modelo de tendencia estocástica o determinística. Perron (1989) muestra que para valores grandes de ω , $\hat{\phi}_1$ se aproxima a 1 cuando se ignora el cambio de nivel. En otras palabras, no es fácil rechazar que ϕ_1 es igual a 1 cuando el cambio de nivel es permanente. También se pueden describir patrones que están entre un cambio de nivel permanente y un conjunto de IO o AO, los cuales en el contexto económico se pueden interpretar como un cambio de nivel transitorio.

Los casos de cambios de nivel se pueden incluir en la regresión de DF, por ejemplo:

$$\Delta_1 y_t = \rho y_{t-1} + \omega I_t(t \geq \tau) + \lambda_1 I_t(t = \tau) + \lambda_2 I_t(t = \tau + 1) + \varepsilon_t, \quad (IV.1.1.5)$$

donde las variables dummy en τ y en $\tau+1$ aseguran un cambio de nivel gradual. Para este caso, Perron (1990) muestra que la distribución asintótica de $t(\rho)$ depende solamente de λ . Cuando se incluye información en la regresión del test, el valor crítico se corre a la izquierda. Intuitivamente se podría interpretar como que, incluir más información en el modelo de regresión favorece la hipótesis alternativa, en consecuencia favorece el rechazo de la hipótesis nula de una raíz unitaria.



Los valores de la distribución asintótica del test $t(\rho)$ para el caso de distintos puntos de quiebre fueron hallados por estudios de simulación. Para propósitos prácticos, suponiendo un modelo general, se puede usar la siguiente regla aproximada para un nivel del 5%: si el valor de la estadística es menor que -5.08 se puede concluir que no existe raíz unitaria; en el caso de que el valor de la estadística sea mayor que -3.75 existe raíz unitaria; cualquier valor entre esos dos puede ser visto como una región inconclusa con respecto al test.

IV.1.2 MODELO PARA LA TASA DE DESOCUPACIÓN DE GRAN ROSARIO

Sobre la base del outlier y los cambios de nivel encontrados en la sección III.4.1, se plantea la siguiente regresión ampliada para el test de DF:

$$\Delta_1 y_t = \rho y_{t-1} + \alpha_1 \Delta_1 y_{t-1} + \omega_1 I_{89-t}(t = \tau) + \omega_2 I_{89-2}(t = \tau) + \lambda_1 I_{95-1}(t = \tau) + \lambda_2 I_{97-1}(t = \tau) + \lambda_3 I_{01-2}(t = \tau) + \varepsilon_t \quad (IV.1.2.1)$$

ω_1 y ω_2 miden el impacto del punto aberrante de la 1er. onda de 1989, se deben incorporar dos indicadores, porque se está trabajando con la primer diferencia de la serie por lo tanto el punto aberrante se percibe en dos diferencias sucesivas ($y_{89-1}-y_{88-2}$, $y_{89-2}-y_{89-1}$);

λ_1 , λ_2 , λ_3 representan los cambios de nivel de la 1er. onda de 1995, 1er. onda de 1997 y 2da. onda 2001, respectivamente.

Tabla IV.1.2.1: Coeficientes estimados del modelo de regresión ampliada para el test de DF para Gran Rosario

Coeficiente	Estimación	Desvío Estándar	T	P
ρ	0.005181	0.016788	0.308635	(*)
α	-0.52898	0.134915	-3.921124	0.0003
AO89_1	5.9320	1.792102	3.310087	0.0018
AO89_2	-5.3066	1.805396	-2.939315	0.0050
IO95_1	6.9164	1.684507	4.105885	0.0002
IO97_1	-4.0895	1.72045	-2.377001	0.0214
IO01_2	4.0795	1.739081	2.345787	0.0231

(*) no se expresa la probabilidad asociada debido a que la estadística no se distribuye de manera convencional.

Todos los coeficientes resultan significativos a excepción de ρ , cuyo valor es mayor que el valor crítico hallado por simulación del test de raíz unitaria de DF ampliado por los puntos aberrantes y cambios de nivel, como se expresa en la sección IV.1.1. En consecuencia la serie Tasa de Desocupación del Aglomerado GR es integrada de orden 1.



IV.1.3 MODELO PARA LA TASA DE DESOCUPACIÓN DE GRAN BUENOS AIRES

En base a los cambios de nivel encontrados en la sección iii.4.2, se plantea la siguiente regresión ampliada para el test de DF:

$$\Delta_1 y_t = \rho y_{t-1} + \alpha_1 \Delta_1 y_{t-1} + \lambda_1 I_{94-2}(t = \tau) + \lambda_2 I_{95-1}(t = \tau) + \lambda_3 I_{97-1}(t = \tau) + \lambda_4 I_{01-2}(t = \tau) + \varepsilon_t \quad (IV.1.3.1)$$

donde λ_1 , λ_2 , λ_3 y λ_4 representan los cambios de nivel de la 2da. onda de 1994, 1ra. onda de 1995, 1ra. onda de 1997 y 2da. onda de 2001, respectivamente.

Tabla IV.4.3.1: Coeficientes estimados del modelo de regresión ampliada para el test de DF para Gran Buenos Aires

Coeficiente	Estimación	Desvío Estándar	t	P
ρ	0.004829	0.013503	0.357627	(*)
α	-0.605372	0.119071	-5.084112	0.0000
IO94_2	3.455122	1.294170	2.669760	0.0102
IO95_1	5.084736	1.318620	3.856105	0.0003
IO97_1	-2.807330	1.243442	-2.257708	0.0284
IO01_2	4.081389	1.231324	3.314635	0.0017

(*) no se expresa la probabilidad asociada debido a que la estadística no se distribuye de manera convencional.

De manera similar al análisis para GR, todos los coeficientes resultan significativos excepto el correspondiente a ρ , cuyo valor es mayor que el valor crítico del test de raíz unitaria de DF ampliado por los puntos aberrantes y cambios de nivel (sección IV.1.1). En consecuencia la serie Tasa de Desocupación del Aglomerado GBA es integrada de orden 1.

V. DISCUSIÓN

El análisis realizado en este trabajo muestra que los modelos de espacio de estado son un método de análisis de series de tiempo que se adapta bien al estudio de las tasas de desocupación de los aglomerados GR y GBA, debido a su flexibilidad para reflejar los cambios que se van produciendo a través del tiempo.

Por otro lado, permiten detectar los momentos en que se presentan puntos aberrantes y cambios de estructura. Esto es importante no sólo porque posibilitan explicar comportamientos de interés en la serie, sino también porque conocer dichos momentos facilita plantear la regresión ampliada de Dickey Fuller para realizar el test de raíz unitaria de las respectivas series.



En este trabajo se muestra que las series de tiempo de las tasas de desocupación de los aglomerados en estudio presentan varias características similares, como son:

a) nivel aleatorio, con un valor estimado al final del período levemente superior para GR y tendencia similar en ambas series (Gráfico III.4.3.1);

b) estacionalidad determinística, con coeficientes prácticamente iguales (alrededor de 0.56 para la 1er. onda), lo que expresa que el comportamiento estacional en ambos aglomerados es similar presentando la desocupación un leve crecimiento en la 1er. onda;

c) GR muestra mayor inestabilidad que GBA, ya que en la década del 80 el primero presenta un punto aberrante positivo en la 1er. onda del 1989, mientras que el segundo no manifiesta ningún punto atípico. Por otro lado, en la década del 90 el cambio de nivel en GBA representa un crecimiento más gradual ya que se produjo por un cambio en la 2da. onda de 1994 y otro en la 1er. onda de 1995, en cambio en GR el cambio se produjo en forma más abrupta a partir de la 1er. onda de 1995. Los dos acusan un cambio de nivel equivalente hacia abajo en la 1er. onda de 1997. Por último, los dos evidencian un cambio de nivel positivo en la 2da. onda de 2001 (Gráfico III.4.3.2).

En base a los modelos propuestos, no se rechaza la presencia de raíces unitarias para las series de ambos aglomerados, aún considerando los puntos aberrantes y los cambios de estructura. Existen algunas discrepancias con respecto a los resultados hallados por Arrufat (1999) respecto del punto de quiebre. En el aglomerado GBA se coincide sobre el momento del punto de quiebre en la 2da. onda de 1994 pero además se encuentran otros cambios de nivel en la 1ra. onda del 95, 1ra. del 97 y 2da. del 2001, mientras que para GR no existe ninguna coincidencia sobre los momentos de ruptura. Estas discrepancias se pueden deber no sólo a que se utilizan métodos diferentes sino también a que el período de estudio fue ampliado 4 años.

Este trabajo es un estudio de serie de tiempo preliminar necesario para poder realizar un análisis de cointegración (Engle y Granger, 1987) para tratar de determinar el comportamiento a largo plazo de las tasas de desocupación, siendo ésta la próxima etapa del proyecto de investigación.

VI. REFERENCIAS BIBLIOGRÁFICAS

Arrufat, J.L., Diaz Cafferata, A.M., Figueras, A.J., Utrera, G.E. (1999). "Hysteresis and Structural Breacks in Regional Unemployment. Argentina 1980-1998". *Asociación Argentina de Economía Política XXXIVa Reunión Anual*.

Box, G.E.P., Jenkins, G.M., (1970). "*Time Series Analysis, Forecasting and Control*". San Francisco: Holden-Day.

Engle, R.F., Granger, C.W.J., (1987): "Co.integration and error correction:representation, estimation and testing". *Econometrica* 55, 251-276.



Eviews (1997). User`s Guide, Quantitative Micro Software, Irvine CA.

Franses, P.H., Haldrup, M., (1994). "The Effects of Additive Outliers on Test for Unit Roots and Cointegration". *Journal of Business and Economic Statistics* 12, 471-478.

Harvey, A.C. (1989). "*Forecasting Structural Time Series and the Kalman Filter*". Cambridge, U.K. Cambridge, University Press.

Perron, P., (1989). "The Great Crash, the Oil Price Shock, and the Unit Root Hypothesis", *Econometrica*, 57, 1361-1401.

(1990). "Testing for a Unit Root in a Time Series with a Changing Mean". *Journal of Business and Economic Statistics*, Vol. 8, pp. 153-162.

Phillips, P. C. B., (1987), "Time Series Regression with a Unit Root", *Econometrica*, 55, 277-301.

STAMP 5.0, London School of Economics, UK.

Zivot, Eric and Andrews, Donald W.K. (1992), "Further Evidence on the Great Crash, the Oil-Price Shock and the Unit-Root Hypothesis", *Journal of Business & Economic Statistics*, July, Vol 10, No 3, July, pp 251-270.