

# Cambio estructural

Randall Romero Aguilar, PhD  
[randall.romero@ucr.ac.cr](mailto:randall.romero@ucr.ac.cr)

EC4301 - Macroeconometría  
I Semestre 2020

Última actualización: 20 de mayo de 2020

**UCR**  
UNIVERSIDAD DE COSTA RICA

**ESCUELA de  
ECONOMÍA**  
UNIVERSIDAD DE COSTA RICA

# Tabla de contenidos

1. Introducción
2. La prueba de Chow
3. Cambio estructural y raíces unitarias: fecha conocida
4. Cambio estructural y raíces unitarias: fecha desconocida





# 1. Introducción

- ▶ En 1976 Lucas publicó una de las críticas más fuertes al enfoque de modelación económica de gran escala de la Comisión Cowles.
- ▶ Lucas criticó el supuesto de que muchos fenómenos económicos son estructurales.
- ▶ En esencia, argumentaba que cambios en las leyes y regulaciones afectaban el comportamiento humano, y que esto se reflejaría en los datos.
- ▶ Por ejemplo, en una estimación de consumo

$$c_t = \alpha + \beta y_t + \epsilon_t$$

la propensión marginal a consumir  $\beta$  podría cambiar con el tiempo.

# Cambio estructural en una serie de tiempo



## 2. La prueba de Chow

# Determinando si hay un cambio estructural

- ▶ Recordemos que podemos expresar una regresión lineal como

$$\begin{aligned}y_t &= \beta_1 x_{t,1} + \cdots + \beta_k x_{t,k} + \epsilon \\ &= [x_{t,1} \quad \cdots \quad x_{t,k}] \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_k \end{bmatrix} + \epsilon_t \\ &= x'_t \beta + \epsilon_t\end{aligned}$$

- ▶ Cuando apilamos todas  $T$  las observaciones

$$Y = \begin{bmatrix} y_1 \\ \vdots \\ y_T \end{bmatrix} = \begin{bmatrix} x'_1 \beta + \epsilon_1 \\ \vdots \\ x'_T \beta + \epsilon_T \end{bmatrix} = \begin{bmatrix} x'_1 \\ \vdots \\ x'_T \end{bmatrix} \beta + \begin{bmatrix} \epsilon_1 \\ \vdots \\ \epsilon_T \end{bmatrix} = X\beta + \epsilon$$

- ▶ La regresión  $Y = X\beta + \epsilon$  asume que el vector de coeficientes  $\beta$  es el mismo para toda la muestra.
- ▶ Supongamos que pensamos que durante el período conocido hubo un cambio estructural en la economía, por lo que el vector de parámetros fue  $\beta_0$  antes del cambio pero  $\beta_1$  después. Entonces:

$$\begin{cases} Y_1 = X_1\beta_1 + \epsilon_1, & \text{antes del cambio} \\ Y_2 = X_2\beta_2 + \epsilon_2, & \text{después} \end{cases}$$

$$\begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix} = \begin{bmatrix} X_1 & 0 \\ 0 & X_2 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \end{bmatrix} + \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \end{bmatrix}$$

- ▶ Por lo que el estimador de mínimos cuadrados ordinarios

$$\widehat{\begin{bmatrix} \beta_1 \\ \beta_2 \end{bmatrix}} = \begin{bmatrix} X_1'X_1 & 0 \\ 0 & X_2'X_2 \end{bmatrix}^{-1} \begin{bmatrix} X_1'Y_1 \\ X_2'Y_2 \end{bmatrix} = \begin{bmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{bmatrix}$$



- ▶ Esto nos dice que los parámetros  $\beta_1$  y  $\beta_2$  pueden estimarse por MCO separadamente.
- ▶ Planteamos la hipótesis nula de que no hay cambio estructural:  $\beta_1 = \beta_2$ . Entonces

$$\begin{cases} Y_1 = X_1\beta + \epsilon_1, & \text{antes del cambio} \\ Y_2 = X_2\beta + \epsilon_2, & \text{todo sigue igual} \end{cases}$$

$$\begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix} = \begin{bmatrix} X_1 \\ X_2 \end{bmatrix} \beta + \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \end{bmatrix}$$

- ▶ Esto corresponde a la regresión con todas las observaciones.
- ▶ La hipótesis  $\beta_1 = \beta_2$  puede comprobarse con un test de Wald.

- ▶ Sea  $S$  la suma de los cuadrados de los residuos de la regresión restringida, y  $S_i$  la suma de los cuadrados de los residuos de la regresión de la muestra  $i$ .

## Prueba de cambio estructural de Chow



¿Son los coeficientes  $\beta_1$  y  $\beta_2$  distintos?

$H_0$

$$\beta_1 = \beta_2$$

Test

$$\frac{\frac{S - S_1 - S_2}{k}}{\frac{S_1 + S_2}{T - 2k}} \sim F(k, T - 2k)$$



Si el estadístico es grande (mayor que el valor crítico), los modelos son distintos, por lo que sí hay cambio estructural.

Ejemplo 1:

# Cambio en la demanda por combustible



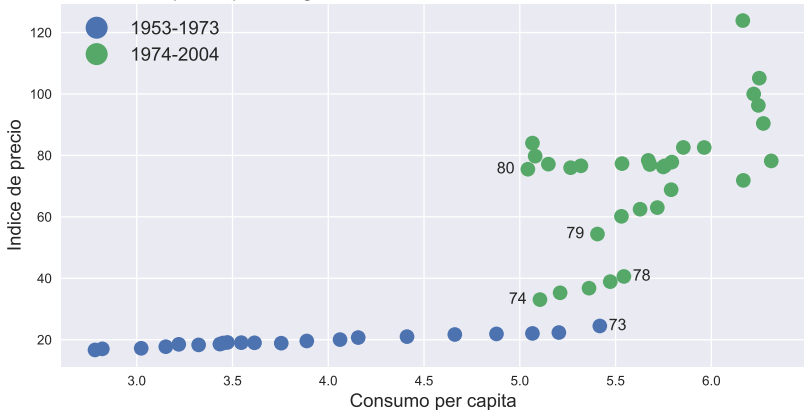
TableF2-2.txt

---




Greene-gas-market.ipynb

### Consumo per capita de gasolina versus Precio, Estados Unidos 1953–2004




## El mercado del petróleo tuvo un cambio significativo en 1973:



Antes de 1973, el comercio de petróleo estaba dominado por las “Siete Hermanas”, que controlaba  $\approx 85\%$  de las reservas de petróleo



Desde la guerra de Yom Kippur (oct-1973), la OPEP ha dominado activamente en la fijación del precio.



Greene (2012) estima el modelo el consumo per capita de combustible  $G$

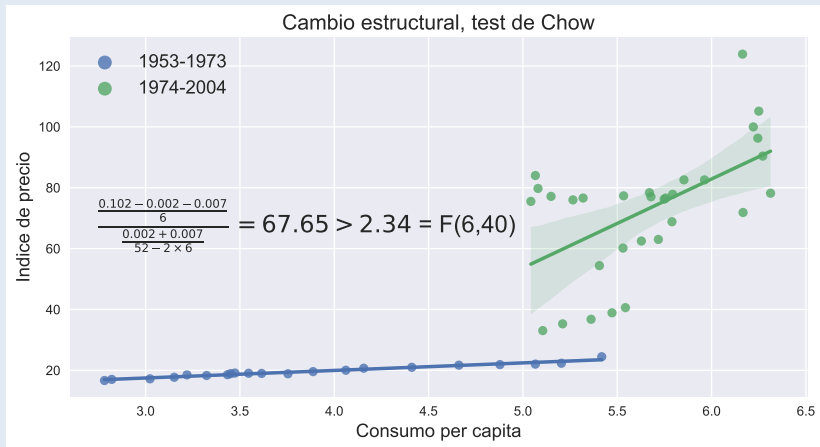
$$G_t = \beta_1 + \beta_2 I_t + \beta_3 PG_t + \beta_4 PNC_t + \beta_5 PUC_t + \beta_6 t + \epsilon_t$$

(todas las variables en logaritmo, excepto  $t$ ) y comprueba si hay un cambio estructural en 1974.

	1953-2004		1953-1973		1974-2004		descripción
intercepto	-12.863	*	-8.349	*	-1.513		intercepto
I	1.625	*	0.848	*	0.374	*	ingreso per capita
PG	-0.054		-0.032		-0.124	*	precio combustible
PNC	-0.083		0.699	*	-0.001		precio carro nuevo
PUC	-0.085		-0.291	*	-0.022		precio carro usado
t	-0.014	*	0.010	*	0.004		tendencia
$R^2$	0.965		0.997		0.953		$R^2$
S	0.102		0.002		0.007		suma residuos <sup>2</sup>

\* significativo al 5%

La prueba de Chow confirma que hay un cambio estructural en 1974: los parámetros de 1953-1973 son significativamente distintos a los de 1974-2004.



La prueba de Chow tiene algunas limitaciones importantes

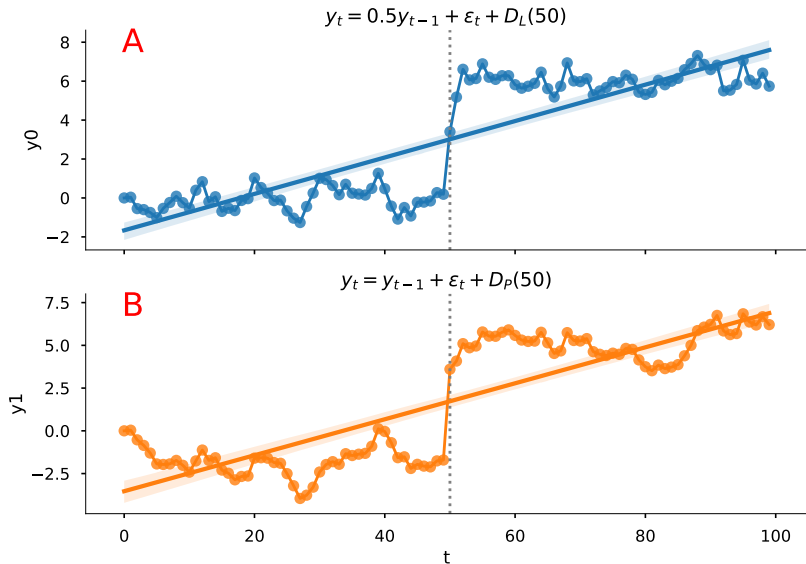
- ▶ Asume que el analista sabe la fecha en que ocurre el cambio estructural
- ▶ Asume que la varianza de los errores es la misma antes y después del cambio estructural.



### 3. Cambio estructural y raíces unitarias: fecha conocida

- ▶ Cuando se realizan pruebas de raíz unitaria, debe tenerse cuidado si se sospecha que ha ocurrido un cambio estructural.
- ▶ Cuando hay cambios estructurales, los estadísticos Dickey-Fuller están sesgados hacia no rechazar la hipótesis de que hay raíz unitaria.

# Ejemplos de cambios estructurales



- ▶ Los datos de la figura A fueron generados por

$$y_t = 0.5y_{t-1} + \epsilon_t + 3D_L(50)_t \quad (\text{AR}(1) + \text{cambio } \mu)$$
$$D_L(50)_t = I(t \geq 50) \quad (\text{dummy de nivel})$$

- ▶ La serie simulada parece tener una tendencia lineal.
- ▶ La manera apropiada de estimar este modelo es

$$y_t = \beta_0 + \beta_1 y_{t-1} + \delta D_L(50) + \epsilon_t$$

pero si estimamos

$$y_t = \alpha_0 + \alpha_1 t + \epsilon_t$$

el coeficiente  $\alpha_1$  tendería a ser positivo para capturar el salto en la serie.

- ▶ Suponga que por equivocación estimamos

$$y_t - y_{t-1} = c + \gamma y_{t-1} + \epsilon_t$$

lo que sería una caminata aleatoria con deriva si  $\gamma = 0$ .  
Entonces:

$$y_t = y_0 + ct + \sum_{i=1}^t \epsilon_i$$

- ▶ Esta ecuación describe los datos de manera similar a como lo hace  $y_t = \alpha_0 + \alpha_1 t + \epsilon_t$ , lo cual nos dice que la regresión Dickey-Fuller sesgaría los resultados hacia  $\gamma = 0$ , es decir, hacia no rechazar la presencia de una raíz unitaria.
- ▶ Perron (1989) demostró este sesgo con simulaciones de Monte Carlo.

- ▶ Ahora bien, una serie con raíz unitaria también puede presentar un cambio estructural, como en la figura B, generada por

$$y_t = y_{t-1} + \epsilon_t + 5D_P(50)_t \quad (\text{RW} + \text{cambio } \mu)$$
$$D_P(50)_t = I(t = 50) \quad (\text{dummy de impulso})$$

- ▶ Note que  $D_P(t)$  es igual a 1 solo en el período  $t$ : cualquier cambio aditivo a una caminata aleatoria tiene un efecto permanente sobre el nivel de la serie.
- ▶ La serie simulada parece tener una tendencia lineal.
- ▶ De hecho, no es sencillo distinguirla de la figura A a simple vista.

- ▶ ¿Cómo saber entonces si una serie con cambio estructural tiene raíz unitaria?
- ▶ Una opción, similar a lo que hace la prueba de Chow, es partir la muestra de datos en dos partes, y realizar pruebas de raíz unitaria en cada una por separado
- ▶ Lo malo de este procedimiento es que pierde muchos grados de libertad.
- ▶ Sería preferible tener un test que utilice toda la muestra

## ¿Caminata aleatoria o serie estacionaria alrededor de tendencia?

- ▶ Perron (1989) desarrolla un procedimiento formal para detectar raíces unitarias en presencia de un cambio estructural ocurrido en  $t = \tau$ .
- ▶ Las hipótesis nula y alternativa son

$$y_t = \alpha_0 + y_{t-1} + \mu_1 D_t^P(\tau) + \epsilon_t \quad (\text{nula})$$


$$y_t = \alpha_0 + \alpha_2 t + \mu_2 D_t^L(\tau) + \epsilon_t \quad (\text{alternativa})$$

- ▶ Es decir, la hipótesis nula es que hay un solo salto en una caminata aleatoria en el período  $\tau$ , la alternativa es que en esa misma fecha hay un solo salto en el intercepto de una serie estacionaria alrededor de tendencia.



- Observemos que

$$\sum_{k=1}^t D_p(\tau)_k = D_L(\tau)_t$$



- Integrando la hipótesis nula

$$y_t = y_0 + \alpha_0 t + \mu_1 D_L(\tau)_t + \sum_{k=0}^t \epsilon_k$$

vemos que es equivalente a la alternativa excepto por las perturbaciones.

## Modelo A: cambio de intercepto (crash)

$$y_t = \underbrace{\alpha_0 + \mu_1 D_t^P}_{\text{intercepto}} + y_{t-1} + \epsilon_t \quad (\text{nula})$$

$$y_t = \underbrace{\alpha_0 + \mu_2 D_t^L}_{\text{intercepto}} + \alpha_2 t + \epsilon_t \quad (\text{alternativa})$$

## Modelo B: cambio de tendencia (changing growth)

$$y_t = \underbrace{\alpha_0 + \mu_2 D_t^L}_{\text{intercepto}} + y_{t-1} + \epsilon_t \quad (\text{nula})$$

$$y_t = \alpha_0 + \underbrace{\alpha_2 t + \mu_3 D_t^T}_{\text{tendencia}} + \epsilon_t \quad (\text{alternativa})$$

donde  $D_t^T(\tau) = \max(t - \tau, 0)$

## Modelo C: cambio de intercepto y de tendencia

$$y_t = \underbrace{\alpha_0 + \mu_1 D_t^P + \mu_2 D_t^L}_{\text{intercepto}} + y_{t-1} + \epsilon_t \quad (\text{nula})$$

$$y_t = \underbrace{\alpha_0 + \mu_2 D_t^L}_{\text{intercepto}} + \underbrace{\alpha_2 t + \mu_3 D_t^T}_{\text{tendencia}} + \epsilon_t \quad (\text{alternativa})$$

Para implementar la prueba de Perron se siguen 3 pasos:

**Paso 1** Se estima la regresión correspondiente al modelo

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \alpha_2 t + \mu_1 D_t^P + \mu_2 D_t^L + \epsilon_t \quad (\text{A})$$

$$y_t = \alpha_0 + \alpha_2 t + \mu_3 D_t^T + \tilde{y}_t \quad \Rightarrow \quad \tilde{y}_t = \alpha_1 \tilde{y}_{t-1} + \epsilon_t \quad (\text{B})$$

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \alpha_2 t + \mu_1 D_t^P + \mu_2 D_t^L + \mu_3 D_t^L + \epsilon_t \quad (\text{C})$$

**Paso 2** Si los residuos de la regresión están autocorrelacionados, se estima la regresión ampliada, agregando  $p$  rezagos del cambio en la variable:

$$\text{A y C : } \sum_{i=1}^p \beta_i \Delta y_{t-1} \quad \text{B : } \sum_{i=1}^p \beta_i \Delta \tilde{y}_{t-1}$$

**Paso 3** Se calcula el estadístico  $t$  de la hipótesis  $a_1 = 1$ :

$$t_{\alpha_1} = \frac{\hat{\alpha}_1 - 1}{s.e.(\alpha_1)}$$

y se compara con el valor crítico de Perron.

- ▶ Si el estadístico estimado es menor que el valor crítico, se rechaza la hipótesis nula.
- ▶ El valor crítico depende de la proporción  $\lambda$  de observaciones que corresponden al periodo anterior al quiebre estructural.

Cuadro: Valores críticos de Perron

$\lambda$	Modelo A			Modelo B			Modelo C		
	1%	5%	10%	1%	5%	10%	1%	5%	10%
0.1	-4.30	-3.68	-3.40	-4.27	-3.65	-3.36	-4.38	-3.75	-3.45
0.2	-4.39	-3.77	-3.47	-4.41	-3.80	-3.49	-4.65	-3.99	-3.66
0.3	-4.39	-3.76	-3.46	-4.51	-3.87	-3.58	-4.78	-4.17	-3.87
0.4	-4.34	-3.72	-3.44	-4.55	-3.94	-3.66	-4.81	-4.22	-3.95
0.5	-4.32	-3.76	-3.46	-4.56	-3.96	-3.68	-4.90	-4.24	-3.96
0.6	-4.45	-3.76	-3.47	-4.57	-3.95	-3.66	-4.88	-4.24	-3.95
0.7	-4.42	-3.80	-3.51	-4.51	-3.85	-3.57	-4.75	-4.18	-3.86
0.8	-4.33	-3.75	-3.46	-4.38	-3.82	-3.50	-4.70	-4.04	-3.69
0.9	-4.27	-3.69	-3.38	-4.26	-3.68	-3.35	-4.41	-3.80	-3.46

Fuente: Perron (1989)

Ejemplo 2:

# Pruebas de cambio estructural



[NelsonPlosserData.dta](#)

---




[Perron1989.py](#)



## Perron analiza los datos de Nelson y Plosser.

Salarios nominales



Al estimar el modelo A encuentran

	$t$	$\lambda$	1%	5%	10%
Real GNP	-5.03	0.34	-4.39	-3.76	-3.46
Nominal GNP	-5.42	0.34	-4.39	-3.76	-3.46
Real per capita GNP	-4.09	0.34	-4.39	-3.76	-3.46
Industrial production	-5.47	0.63	-4.45	-3.76	-3.47
Employment	-4.51	0.49	-4.32	-3.76	-3.46
GNP deflator	-4.04	0.50	-4.32	-3.76	-3.46
Consumer prices	-1.28	0.63	-4.45	-3.76	-3.47
Wages	-5.41	0.42	-4.34	-3.72	-3.44
Money stock	-4.29	0.50	-4.32	-3.76	-3.46

A continuación vemos cómo replicar los resultados del modelo A de Perron, escribiendo un programa de Python.

```
import pandas as pd
import numpy as np
from statsmodels.formula.api import ols

NP = pd.read_stata('NelsonPlosserData.dta')
NP.set_index('year', inplace=True)
NP.index = NP.index.year
```

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \alpha_2 t + \mu_1 D_t^P + \mu_2 D_t^L + \sum_{i=1}^p \beta_i \Delta y_{t-1} + \epsilon_t$$

```
def Perron_testA(serie, k=8):
    dta = NP[[serie]].dropna()
    dta.rename(columns={serie:'y'}, inplace=True)
    dta['DL'] = (dta.index>1929)
    dta['DP'] = (dta.index==1930)
    dta['t'] = np.arange(dta.shape[0])
    dta['Ly'] = dta['y'].shift(1)
    dta['Dy'] = dta['y'].diff(1)
    for j in range(1, k+1):
        dta[f'D{j}y'] = dta['Dy'].shift(j)

    lags = '+' .join(dta.columns[-k:])

    modelo = ols('y ~ DL + DP + t + Ly + ' + lags, dta).fit()
    tval = ((modelo.params - 1)/modelo.bse).round(2)['Ly']
    lda = 1-dta['DL'].mean()
    crit = perron['Modelo A'].loc[np.round(lda, 1)]

    return {'$t$': tval, '$\lambda$': np.round(lda, 2), '1%':
            crit['1%'], '5%': crit['5%'], '10%': crit['10%']}
```

## 4. Cambio estructural y raíces unitarias: fecha desconocida

## ¿Cómo saber cuándo se produjo un cambio estructural?

- ▶ Un supuesto importante en la prueba de Perron (1989) es que el analista conoce la fecha en que se produjo el (único) cambio estructural.
- ▶ No obstante, esto no siempre es factible.
- ▶ Zivot y Andrews (1992) proponen una prueba de raíz unitaria similar a la de Perron, pero que asume que el momento del cambio estructural es desconocido.

## Una hipótesis nula, tres alternativas

$$y_t = \mu + y_{t-1} + \epsilon_t \quad (\text{nula})$$

$$y_t = \underbrace{\alpha_0 + \mu_2 D_t^L}_{\text{intercepto}} + \alpha_2 t + \epsilon_t \quad (\text{alternativa A})$$

$$y_t = \alpha_0 + \underbrace{\alpha_2 t + \mu_3 D_t^T}_{\text{tendencia}} + \epsilon_t \quad (\text{alternativa B})$$

$$y_t = \underbrace{\alpha_0 + \mu_2 D_t^L}_{\text{intercepto}} + \underbrace{\alpha_2 t + \mu_3 D_t^T}_{\text{tendencia}} + \epsilon_t \quad (\text{alternativa C})$$

Para implementar la prueba de Zivot y Andrews se siguen estos pasos:

**Paso 1** Se estima la regresión correspondiente al modelo

$$\begin{aligned} A : y_t &= \alpha_0 + \alpha_1 y_{t-1} + \alpha_2 t + \mu_2 D_t^L + \sum_{i=1}^p \beta_i \Delta y_{t-1} + \epsilon_t \\ B : y_t &= \alpha_0 + \alpha_1 y_{t-1} + \alpha_2 t + \mu_3 D_t^T + \sum_{i=1}^p \beta_i \Delta y_{t-1} + \epsilon_t \\ C : y_t &= \alpha_0 + \alpha_1 y_{t-1} + \alpha_2 t + \mu_2 D_t^L + \mu_3 D_t^T + \sum_{i=1}^p \beta_i \Delta y_{t-1} + \epsilon_t \end{aligned}$$

donde los términos  $D_t^L$  y  $D_t^T$  dependen de la proporción de datos  $\lambda$  anteriores al cambio estructural:

$$D_t^L(\lambda) = I(t > \lambda T) \quad D_t^T = \max(t - \lambda T, 0)$$



**Paso 2** Se calcula el estadístico  $t$  de la hipótesis  $a_1 = 1$ :

$$t_{\alpha_1} = \frac{\hat{\alpha}_1 - 1}{s.e.(\alpha_1)}$$

Observemos que el valor estimado  $\hat{\alpha}$  dependerá de  $\lambda$ ; por ello, escribimos  $t_{\alpha_1}(\lambda)$

**Paso 3** Se define el punto de quiebre  $\hat{\lambda}$  como aquel valor  $\lambda$  que hace más plausible la hipótesis alternativa

$$\hat{\lambda} \equiv \underset{\lambda \in (0,1)}{\operatorname{argmin}} \{t_{\alpha_1}(\lambda)\}$$

**Paso 4** Se compara el valor mínimo  $t_{\alpha_1}(\hat{\lambda})$  con el valor crítico de Zivot y Andrews. Si el estadístico estimado es menor que el valor crítico, se rechaza la hipótesis nula.

**Cuadro:** Valores críticos de Zivot y Andrews

Modelo	1%	5%	10%
A	-5.34	-4.80	-4.58
B	-4.93	-4.42	-4.11
C	-5.57	-5.08	-4.82

Fuente: Zivot y Andrews (1992)

Ejemplo 3:

# Pruebas de cambio estructural (continuación)



[NelsonPlosserData.dta](#)

---



[Perron1989.py](#)

Zivot y Andrews (1992) también analizan los datos de Nelson y Plosser. Al estimar el modelo A encuentran

	$\hat{T}_B$	$\alpha_1$	$t$
Real GNP	1929	0.267	-5.58
Nominal GNP	1929	0.532	-5.82
Real per capita GNP	1929	0.494	-4.61
Industrial production	1929	0.290	-5.95
Employment	1929	0.651	-4.95
GNP deflator	1929	0.786	-4.12
Consumer prices	1873	0.941	-2.76
Wages	1929	0.660	-5.30
Money stock	1929	0.823	-4.34

Recordemos los valores críticos

1%	5%	10%
-5.34	-4.80	-4.58

A continuación vemos cómo replicar los resultados del modelo A de Zivot y Andrews, escribiendo un programa de Python.

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \alpha_2 t + \mu_2 D_t^L + \sum_{i=1}^p \beta_i \Delta y_{t-1} + \epsilon_t$$

```

def ZivotAndrewsA(serie , k=8):
    dta = NP[[serie]].dropna()
    dta.rename(columns={serie:'y'}, inplace=True)
    dta['t'] = np.arange(dta.shape[0])
    dta['Ly'] = dta['y'].shift(1)
    dta['Dy'] = dta['y'].diff(1)
    for j in range(1, k+1):
        dta[f'D{j}y'] = dta['Dy'].shift(j)






    lags = '+' .join(dta.columns[-k:])

    a1vals = pd.Series(0.0, index=dta.index[12:-12])
    for tau in a1vals.index:
        dta['DL'] = (dta.index>tau)
        reg = ols('y ~ Ly + t + DL + ' + lags , dta).fit()
        a1vals[tau] = ((reg.params - 1)/reg.bse)['Ly']

    tauhat, tval = a1vals.idxmin(), a1vals.min()
    dta['DL'] = (dta.index>tauhat)
    reg = ols('y ~ Ly + t + DL + ' + lags , dta).fit()

    return {r'$\hat{T}_B$':tauhat, r'$\alpha_1$': reg.
            params['Ly'], r'$t$':tval}

```

-  Enders, Walter (2015). *Applied Econometric Time Series*. 4ª ed. Wiley. ISBN: 978-1-118-80856-6.
-  Greene, William H. (2012). *Econometric Analysis*. 7ª ed. Prentice Hall. ISBN: 978-0-13-139538-1.
-  Levendis, John D. (2018). *Time Series Econometrics. Learning Through Replication*. Springer. ISBN: 978-3-319-98281-6.
-  Perron, Pierre (nov. de 1989). "The Great Crash, the Oil Price Shock, and the Unit Root Hypothesis". En: *Econometrica* 57.6, pág. 13611401.
-  Zivot, Eric y Donald W. K. Andrews (jul. de 1992). "Further Evidence on the Great Crash, the Oil-Price Shock, and the Unit-Root Hypothesis". En: *Journal of Business & Economic Statistics* 10.3, págs. 251-270.