



**FACULTAD DE CIENCIAS
ECONÓMICAS Y EMPRESARIALES**

GRADO EN ECONOMÍA

**Una introducción práctica al análisis econométrico de series
temporales**

Trabajo Fin de Grado presentado por Francisco Álvarez Sánchez, siendo el tutor del mismo el profesor Domingo Martín Martín.

Vº. Bº. del Tutor:

Alumno:

D. Domingo Martín Martín

D^a. Francisco Álvarez Sánchez

Sevilla, 2 de junio de 2017



GRADO EN ECONOMÍA
**FACULTAD DE CIENCIAS
ECONÓMICAS Y EMPRESARIALES**
TRABAJO FIN DE GRADO
CURSO ACADÉMICO [2016-2017]

TÍTULO:

**UNA INTRODUCCIÓN PRÁCTICA AL ANÁLISIS ECONOMÉTRICO DE SERIES
TEMPORALES**

AUTOR:

FRANCISCO ÁLVAREZ SÁNCHEZ

TUTOR:

DOMINGO MARTÍN MARTÍN

DEPARTAMENTO:

ECONOMÍA APLICADA I

ÁREA DE CONOCIMIENTO:

MÉTODOS CUANTITATIVOS PARA LA ECONOMÍA Y EMPRESA

RESUMEN:

Se pretende en este trabajo una introducción, que sirva de ampliación de conocimientos, al análisis de series temporales. Los conceptos tales como caminos aleatorios, estacionariedad, autorregresión y causalidad son incorporados a nuestro bagaje de conocimientos. Una aplicación empírica de estos procesos de modelización es llevada a cabo usando datos reales de la economía española y de secuencia trimestral.

PALABRAS CLAVE:

Series temporales, Modelos autorregresivos, Estacionariedad.

ÍNDICE

1. CAPÍTULO 1. INTRODUCCIÓN.....	Págs. 1
2. CAPÍTULO 2. CONCEPTOS ECONOMÉTRICOS EN SERIES TEMPORALES.....	Págs. 3
2.1. INTRODUCCIÓN DE CONCEPTOS.....	Págs. 3
2.2. MODELOS AUTORREGRESIVOS.....	Págs. 4
2.3. REGRESIÓN DE SERIES TEMPORALES CON PREDICTORES ADICIONALES Y MODELO AUTORREGRESIVO DE RETARDOS DISTRIBUIDOS	Págs. 6
2.4. AUSENCIA DE ESTACIONARIEDAD I: tendencias	Págs. 7
3. CAPÍTULO 3. ANÁLISIS EMPÍRICO.....	Págs. 15
3.1 ESTUDIADAS EN ESTE ANÁLISIS SERIES	Págs. 15
3.2. DIVERSOS INTENTOS DE MODELIZACIÓN.....	Págs. 17
4. CAPITULO 4.....	Págs. 31
CONCLUSIÓN.....	Págs. 31
BIBLIOGRAFÍA.....	Págs. 33
ANEXO.....	Págs. 33

CAPÍTULO 1

INTRODUCCIÓN

Como escribe Schmidt (2005), un punto en el que casi todos los economistas están de acuerdo es que, si se dejan solas, las economías experimentan ciclos. La existencia de ciclos económicos sugiere que el estado actual de la economía depende de donde ha estado recientemente. Una economía que ha comenzado a desacelerarse es probable que continúe desacelerándose por uno o dos años más, pero si ha estado lenta por más de ese tiempo, es probable que comience a recuperarse en el futuro cercano. Por el contrario, una economía que inicia un periodo de crecimiento es probable que lo mantenga unos cuantos años, pero eventualmente la recuperación terminará y el ciclo comenzará de nuevo. Si deseamos modelar la economía quizás hagamos bien en utilizar modelos en los que la condición presente de la economía sea una función de su pasado reciente.

En este trabajo se intenta dar un repaso a las técnicas clásicas dentro del contexto de la econometría para el análisis de series temporales (datos registrados para una única entidad individual para varios momentos del tiempo). Ese tipo de datos se pueden utilizar para responder a preguntas cuantitativas para las que los datos transversales o de sección cruzada son inadecuados. Por ejemplo, ¿cuál es el efecto causal sobre una variable de interés, Y , de una variación en el tiempo de otra variable X ? O sea, nos planteamos sobre el efecto causal dinámico de X sobre Y . La principal diferencia respecto al análisis de datos transversales la encontramos en la seguridad de que el supuesto de no autocorrelación de las perturbaciones aleatorias en el contexto de una serie temporal es difícil de sostener, lo que impone cambios importantes en los métodos de estimación, alejándonos del clásico Mínimos Cuadrados Ordinarios (MCO).

Entonces, con este trabajo se ha pretendido efectuar una ampliación de los conocimientos econométricos adquiridos durante los estudios del Grado en Economía, y nos hemos centrado en uno de los aspectos que más nos ha interesado: la ya citada modelización de series temporales.

Comenzando por introducir los conceptos básicos, hemos dado paso a las herramientas de regresión en este contexto: modelos autorregresivos de primer orden y de orden p , modelos con predictores adicionales (con retardos distribuidos), estacionariedad, contrastes de causalidad, tendencia, paseos aleatorios y raíz unitaria. Todo ello es analizado en el capítulo 2.

En el capítulo 3 pretendemos llevar a la práctica los contenidos del 2 usando datos reales extraídos del Instituto Nacional de Estadística y versados en la realidad económica española. No pretendemos, desde luego, formular hipótesis sobre dicha realidad, sino simplemente, usar las series temporales extraídas para ilustrar

modelizaciones. Como soporte, el software econométrico usado es GRET, que es de acceso libre y que incorpora casi todas las propuestas de modelización relacionadas con series temporales. Las series elegidas, de carácter trimestral y de ámbito nacional, son el PIB p.m., el número de ocupados según la EPA, el número de parados según la EPA, y el número de afiliados a la Seguridad Social en un sector tan importante para nuestro país como es el turismo. Las relaciones causa-efecto que se pueden dar entre estas variables son aquí analizadas.

Concluimos nuestro trabajo con un capítulo de conclusiones, que más bien son de reflexiones sobre lo aprendido con el desarrollo del mismo y con una bibliografía básica de econometría en español.

CAPÍTULO 2

CONCEPTOS ECONOMÉTRICOS EN SERIES TEMPORALES

2.1. INTRODUCCIÓN DE CONCEPTOS

La observación de una variable en una serie temporal Y , realizada en el momento t se expresa como Y_t , y el número total de observaciones como T . El intervalo entre observaciones, es decir, el periodo de tiempo entre una observación t y la observación $t+1$, viene dado mediante una unidad de tiempo, como puede ser una semana, mes, trimestre,.... Por ejemplo, los datos de la inflación, normalmente se analizan en trimestres.

Se utiliza una terminología y una notación particular para indicar los valores futuros y pasados de Y . El valor de Y en el periodo anterior se denomina el “valor de su primer retardo” o “primer retardo”, y se expresa como Y_{t-1} . El valor de su j -ésimo retardo es su valor hace j periodos, que se denota como Y_{t-j} . Y de forma análoga, Y_{t+1} indica el valor de Y en el periodo siguiente.

La variación en el valor de Y entre el periodo $t-1$ y el periodo t es $Y_t - Y_{t-1}$; esta variación se denomina **primera diferencia** de la variable y_t . En los datos de series temporales se utiliza la notación “ Δ ” para representar la primera diferencia, por lo que $\Delta Y_t = Y_t - Y_{t-1}$.

Las series temporales económicas a menudo son analizadas después de calcular sus logaritmos o las variaciones en sus logaritmos. Una razón para ello es que muchas series económicas, tales como el PIB, presentan un crecimiento que se aproxima al exponencial, es decir, a largo plazo la serie tiende a crecer a un determinado porcentaje medio anual; si es así, el logaritmo de la serie crece de forma lineal. Otra razón es que la desviación típica de muchas series temporales económicas es aproximadamente proporcional a su nivel, es decir, la desviación típica se puede expresar correctamente en un porcentaje del nivel de las series; si es así, entonces la desviación típica del logaritmo de la serie es constante.

Por tanto, resulta útil transformar las series para que las variaciones en las series transformadas seas variaciones proporcionales (o porcentuales) de la serie original, y esto se logra tomando el logaritmos de la series.

2.2. MODELOS AUTORREGRESIVOS

¿Cuál será el aumento de precio en el año siguiente?, ¿cuál será la tasa de inflación de los precios para el próximo año?

Para resolver estas preguntas se utilizan los modelos autorregresivos, que actúan a través de las predicciones de inflación para decidir la cantidad porcentual de los aumentos de los precios.

Estos modelos de autorregresión relacionan las variables de series temporales con sus valores pasados.

- **El modelo autorregresivo de primer orden**

Si se pretende predecir el futuro de una serie temporal, un buen punto de arranque es el pasado inmediato, es decir, se utiliza un método sistemático para predecir la variación en la variable ΔY_t , mediante la variación del periodo anterior ΔY_{t-1} , que consiste en estimar una regresión MCO de ΔY_t sobre ΔY_{t-1} . La regresión utiliza los datos que abarque el horizonte temporal T.

El modelo se representa mediante la ecuación:

$$\Delta Y_t = \beta_0 + \beta_1 \Delta Y_{t-1} + u_t$$

Se denomina autorregresivo de primer orden, porque se trata de una regresión de la serie sobre su propio retardo (ΔY_{t-1}), y es de primer orden ya que sólo utiliza un retardo como regresor.

Un modelo autorregresivo de primer orden se abrevia mediante AR (1), donde el <<1>> indica que es de primer orden. El modelo AR (1) poblacional de la serie Y_t es

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + u_t$$

donde u_t es un término error.

- **Predicciones y errores de predicciones**

Supongamos que se disponen de datos históricos sobre Y, y se desea predecir su valor futuro. Si Y_t sigue el modelo AR(1) y si β_0 y β_1 son conocidos, entonces la predicción de Y_{T+1} en base a Y_T es $\beta_0 + \beta_1 Y_T$.

En la práctica, β_0 y β_1 son desconocidos, por lo que las predicciones deben basarse en estimaciones de β_0 y β_1 . Se utilizan los estimadores MCO $\hat{\beta}_0$ (estimado) y $\hat{\beta}_1$ (estimada), que se calculan utilizando datos históricos. En general, $\hat{Y}_{T+1|T}$ indica la predicción de Y_{T+1} basada en la información hasta el periodo T utilizando un modelo estimado de datos hasta el periodo T. En consecuencia, la predicción basada en el modelo AR(1) es

$$\hat{Y}_{T+1|T} = \hat{\beta}_0 + \hat{\beta}_1 Y_T \quad \hat{Y}_{T+1|T} = \hat{\beta}_0 + \hat{\beta}_1 Y_T$$

donde $\hat{\beta}_0$ y $\hat{\beta}_1$ se calculan con los datos históricos disponibles hasta el periodo T.

El “error de predicción” es el error cometido en la predicción; es decir, la diferencia entre el valor de Y_{T+1} que realmente sucede y su valor de predicción basado en Y_t :

$$\text{Error de predicción} = Y_{T+1} - \hat{Y}_{T+1|T}$$

- **Predicciones vs valores de predicción**

La “predicción” se hace para algún periodo más allá del conjunto de datos utilizados para estimar la regresión, por lo que los datos sobre el valor real de la variable dependiente predicha no se encuentran en la muestra utilizada para estimar la regresión. Del mismo modo, el residuo MCO es la diferencia entre el valor real de Y y su valor de predicción para las observaciones de la muestra, mientras que el error de predicción es la diferencia entre el valor futuro de Y , que no está contenido en la muestra de la estimación, y la predicción de ese valor futuro. Dicho de otra manera, las “predicciones y los errores de predicción” se refiere a observaciones <<fuera de la muestra>>, mientras que los “valores de predicción y los residuos” se refieren a observaciones <<en la muestra>>.

- **Raíz del error cuadrático medio de predicción.**

La raíz del error cuadrático medio de predicción (RECMC) es una medida de la magnitud del error de predicción, es decir, de la magnitud de un error estándar cometido con un modelo de predicción. La RECMC es la raíz cuadrada de la media del error de predicción al cuadrado:

$$\text{RECMC} = \sqrt{E[(Y_{T+1} - \hat{Y}_{T+1|T})^2]}.$$

La RECMC tiene dos fuentes de error:

- 1/ El error que surge debido a que los valores futuros de u_t son desconocidos.
- 2/ Y el error cometido en las estimaciones de los coeficientes β_0 y β_1 .

Si la primera fuente de error es mucho mayor que la segunda fuente de error, es decir, esto ocurre cuando el tamaño de la fuente es muy grande, entonces la RECMC es aproximadamente la $\sqrt{\text{var}(u_t)}$, la desviación típica del error u_t de la autorregresión poblacional. La desviación típica de u_t se estima a su vez mediante el error estándar de la regresión.

Por lo tanto, si la incertidumbre que surge de la estimación de los coeficientes de regresión es lo suficientemente pequeña como para ser ignorada, la RECMC se puede estimar mediante el error estándar de la regresión.

- **El modelo autorregresivo de orden p**

A través del modelo AR(1) se pierde información verdaderamente útil debido al uso de un solo retardo (utiliza Y_{t-1} para predecir Y_t). Para no perder esa información se añaden al modelo AR(1) un mayor número de retardos, dando con ello lugar a un nuevo modelo autorregresivo de orden p, o modelo AR(p).

“El modelo AR(p)”, representa Y_t como una función lineal de sus primeros p valores retardados, es decir, los regresores son $Y_{t-1}, Y_{t-2}, Y_{t-3}, \dots, Y_{t-p}$, más un término

independiente. El número de retardos, p , incluido en el modelo $AR(p)$ se denomina orden, o longitud de los retardos, de la autorregresión.

2.3. REGRESIÓN DE SERIES TEMPORALES CON PREDICTORES ADICIONALES Y MODELO AUTORREGRESIVO DE RETARDOS DISTRIBUIDOS

- **El modelo autorregresivo de retardos distribuidos (ARD).**

El modelo es “autorregresivo” porque incluye los valores retardados de la variable dependiente como variable explicativa, es decir, como en una autorregresión, y contiene “retardos distribuidos” porque la regresión incluye asimismo varios retardos de un predictor adicional.

Se denomina modelo **ARD(p,q)** al modelo de autorregresión de retardos distribuidos con p retardos de la variable dependiente Y_t y q retardos de un predictor adicional X_t . El modelo viene dado mediante la siguiente ecuación:

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \delta_1 X_{t-1} + \delta_2 X_{t-2} + \dots + \delta_q X_{t-q} + u_t$$

donde $\beta_0, \beta_1, \dots, \beta_p, \delta_1, \dots, \delta_q$ son coeficientes desconocidos y u_t es el término de error con $E(u_t | Y_{t-1}, Y_{t-2}, \dots, X_{t-1}, X_{t-2}, \dots) = 0$

El supuesto de que los errores en el modelo ARD tiene media condicional igual a cero dado todos los valores pasados de Y y X , implica que ningún retardo adicional ni de Y ni de X pertenece al modelo ARD, es decir, las longitudes de los retardos p y q son las verdaderas longitudes de los retardos, y los coeficientes de los retardos adicionales son iguales a cero.

- **Estacionariedad**

La idea de que las relaciones históricas pueden generalizarse para el futuro está formalizada en el concepto de *estacionariedad*.

Por tanto, una serie temporal Y_t es estacionaria si su distribución de probabilidad no varía en el tiempo, es decir, si la distribución conjunta de $(Y_{s+1}, Y_{s+2}, \dots, Y_{s+T})$ no depende de “ s ” sea cual sea el valor de “ T ”; de lo contrario se dice que Y_t es *no estacionaria*.

Dos series temporales, X_t e Y_t , se dice que son *conjuntamente estacionaria* si la distribución conjunta de $(X_{s+1}, Y_{s+1}, X_{s+2}, Y_{s+2}, \dots, X_{s+T}, Y_{s+T})$ no depende de “ s ”, independientemente del valor de “ T ”. La estacionariedad requiere que el futuro sea igual que el pasado, al menos en un sentido probabilístico.

- **Regresión de series temporales con varios predictores**

El modelo general de regresión de series temporales permite k predictores adicionales, en el que incluyen q_1 retardos del primer predictor, q_2 retardos del segundo predictor, y así sucesivamente:

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \delta_{11} X_{1t-1} + \delta_{12} X_{1t-2} + \dots + \delta_{1q_1} X_{1t-q_1} + \dots + \delta_{k1} X_{kt-1} + \delta_{k2} X_{kt-2} + \dots + \delta_{kq_k} X_{kt-q_k} + u_t$$

donde los supuestos son:

1. $E(u_t | Y_{t-1}, Y_{t-2}, \dots, X_{1t-1}, X_{1t-2}, \dots, X_{kt-1}, X_{kt-2}, \dots) = 0$
2. (a) Las variables aleatorias $(Y_t, X_{1t}, \dots, X_{kt})$ presentan una distribución estacionaria, y
(b) $(Y_t, X_{1t}, \dots, X_{kt})$ y $(Y_{t-j}, X_{1t-j}, \dots, X_{kt-j})$ pasan a ser independientes cuando j se hace grande.
3. Los valores extremos elevados son poco probables: $X_{1t}, \dots, X_{kt}, Y_t$ presentan momentos de cuarto orden finitos y distintos de cero.
4. No existe multicolinealidad perfecta.

- **Inferencia estadística y contraste de causalidad de Granger.**

Bajo los supuestos mencionados anteriormente, la inferencia sobre los coeficientes de regresión utilizando MCO se realiza de la misma manera que es habitual para los datos de las secciones cruzadas.

Una aplicación útil del estadístico F para la predicción en series temporales consiste en contrastar si los retardos en uno de los regresores incluidos tienen contenido predictivo útil. El estadístico F para el contraste de esta hipótesis nula se denomina **estadístico de causalidad de Granger**, y el contraste asociado se denomina **contraste de causalidad de Granger**.

Por tanto, el estadístico para el contraste de causalidad de Granger es el estadístico F para el contraste de la hipótesis de que los coeficientes de todos los valores de una de las variables son iguales a cero. Esta hipótesis nula implica que estos regresores no tienen contenido predictivo para Y_t más allá del contenido en los otros regresores, y el contraste de esta hipótesis nula se denomina contraste de causalidad de Granger.

La causalidad de Granger significa que si X causa a Y en el sentido de Granger, entonces X es un predictor útil de Y , dadas las otras variables de la regresión.

2.4. AUSENCIA DE ESTACIONARIEDAD: TENDENCIAS

Una **tendencia** es un movimiento persistente a largo plazo de una variable en el tiempo. Una variable de series temporales fluctúa en torno a una tendencia.

- **Tendencias determinística y estocásticas:**

Existe la posibilidad de observar dos tipos de tendencias en datos de series temporales, como son las tendencias determinísticas y las tendencias estocásticas

Una *tendencia determinística* es una función no aleatoria del tiempo. Puede ser lineal en el tiempo, es decir, que las variaciones de la tendencia son proporcionales para el periodo del tiempo. En cambio, una *tendencia estocástica* es aleatoria y varía en el tiempo, es decir, las variaciones de la tendencia podría simultanearse tanto los crecimientos, como los decrecimientos de un periodo a otro.

- **El modelo de paseo aleatorio para la tendencia.**

Se dice que una serie temporal Y_t sigue un **paseo aleatorio** si la variación de Y_t es i.i.d., es decir, si

$$Y_t = Y_{t-1} + u_t , \quad (*)$$

donde u_t es i.i.d. No obstante, utilizaremos el término de paseo aleatorio en un sentido más general para referirnos a una serie temporal, donde u_t presenta una media condicional igual a cero; es decir, $E(u_t|Y_{t-1}, Y_{t-2}, \dots) = 0$.

La idea principal de un paseo aleatorio es que el valor de la serie mañana es su valor hoy, más una variación impredecible. La media condicional de Y_t basada en los datos hasta el periodo $t-1$ es Y_{t-1} ; es decir, debido a que $E(u_t|Y_{t-1}, Y_{t-2}, \dots) = 0$, entonces $E(Y_t|Y_{t-1}, Y_{t-2}, \dots) = Y_{t-1}$, por tanto, si Y_{t-1} sigue un proceso de paseo aleatorio, entonces la mejor predicción del valor de mañana es su valor en la actualidad.

Algunas series presentan una tendencia obviamente creciente, en cuyo caso el mejor pronóstico de la serie debe incluir un ajuste por el aumento tendencial de la serie. Este ajuste lleva a una extensión del modelo de paseo aleatorio para incluir un movimiento tendencial, o <<deriva>>, en una dirección u otra. Esta extensión se conoce como **paseo aleatorio con deriva**:

$$Y_t = \beta_0 + Y_{t-1} + u_t ,$$

donde $E(u_t|Y_{t-1}, Y_{t-2}, \dots) = 0$ y β_0 es la deriva del paseo aleatorio. Si β_0 es positivo, entonces Y_t aumenta en promedio. En el modelo de paseo aleatorio con deriva, la mejor predicción de la serie mañana es el valor de la serie hoy, más la deriva β_0 .

- **Un paseo aleatorio es no estacionario.**

Si Y_t sigue un paseo aleatorio, entonces “*no es estacionaria*”: la varianza de un paseo aleatorio aumenta en el tiempo, por lo que la distribución de Y_t cambia en el tiempo.

Una forma de comprobarlo es observando la incorrelación de u_t con Y_{t-1} a través de la ecuación (*), donde la $\text{var}(Y_t) = \text{var}(Y_{t-1}) + \text{var}(u_t)$; pero para que Y_t sea estacionaria la $\text{var}(Y_t)$ no puede depender del tiempo, por lo que, debe cumplirse que la $\text{var}(Y_t) = \text{var}(Y_{t-1})$, pero esto solo puede ocurrir si la $\text{var}(u_t) = 0$

Otra forma de comprobarlo es sabiendo que u_t está serialmente incorrelado, la $\text{var}(Y_t) = \text{var}(u_1 + u_2 + \dots + u_t) = t\sigma_u^2$. Por tanto, la varianza de Y_t depende de t ; de

hecho aumenta a medida que t aumenta. Debido a que la varianza de Y_t depende de t , su distribución depende de t , es decir, es no estacionaria.

Debido a que la varianza de un paseo aleatorio aumenta sin límite, sus autocorrelaciones *poblacionales* no están definidas. Sin embargo, una característica de un paseo aleatorio es que sus autocorrelaciones *muestrales* suelen ser próximas a 1; de hecho, la j -ésima autocorrelación muestral de un paseo aleatorio converge a 1 en probabilidad.

- **Tendencias estocásticas, modelos autorregresivos, y raíz unitaria.**

El modelo de paseo aleatorio es un caso particular del modelo del modelo AR(1). Por tanto, si Y_t sigue un proceso AR(1) con $\beta_1=1$, entonces Y_t presenta una tendencia estocástica y es no estacionaria. Sin embargo, si $|\beta_1|<1$, y u_t es estacionario, entonces la distribución conjunta de y_t y sus retardos no dependen de t , por lo que Y_t es estacionaria.

La condición análoga para que un proceso AR(p) sea estacionario es más complicada que la condición $|\beta_1|<1$ para un AR(1). Su enunciado formal implica que las raíces del polinomio, $1 - \beta_1 z - \beta_2 z^2 - \beta_3 z^3 - \dots - \beta_p z^p = 0$. Para que un proceso AR(p) sea estacionario, todas las raíces de este polinomio deben ser mayores que 1 en valor absoluto. En el caso particular de un proceso AR(1), la raíz es el valor de z que resuelve la ecuación $1 - \beta_1 z = 0$, por lo que la raíz es $z = 1/\beta_1$. Por lo que la afirmación de que la raíz debe ser mayor que 1 en valor absoluto equivale a que $\beta_1 < 1$.

Si el proceso AR(p) tiene una raíz que es igual a 1, se dice que la serie presenta una *raíz unitaria autorregresiva*. Si Y_t presenta una raíz unitaria, entonces presenta una tendencia estocástica. Si Y_t es estacionaria, no presenta una tendencia estocástica.

- **Problemas ocasionados por las tendencias estocásticas.**

Si un regresor presenta una tendencia estocástica (tiene raíz unitaria), entonces el estimador MCO de su coeficiente y su estadístico t MCO pueden presentar una distribución no estándar (es decir, distinta de la normal), incluso en muestras grandes.

Se analizan tres aspectos específicos de este problema:

1. **Coeficientes autorregresivos que están sesgados hacia cero.**

Supongamos que Y_t sigue un paseo aleatorio, pero que esto es desconocido por el econométra, que en su lugar estima el modelo AR. Debido a que y_t es no estacionaria, los supuestos de mínimos cuadrados para la regresión de series temporales no se cumplen, por lo que, con carácter general, no puede confiarse en los estimadores y los estadísticos de contraste presenten sus distribuciones normales habituales para grandes muestras. Esto se traduce en un gran sesgo para los tamaños muestrales.

Una consecuencia de este sesgo hacia cero es que si Y_t sigue un paseo aleatorio, entonces las predicciones basadas en el modelo AR(p) pueden

comportarse de modo sustancialmente peor que las basadas en el modelo de paseo aleatorio, que impone el verdadero valor $\beta_1=1$.

2. **Distribuciones no normales del estadístico t.** Si un regresor presenta una tendencia estocástica, entonces su estadístico t MCO habitual puede presentar, bajo hipótesis nula, una distribución distinta de la normal, incluso en muestras grandes. Esta distribución no normal significa que no son válidos los intervalos de confianza habituales y los contrastes de hipótesis no pueden llevarse a cabo como de costumbre. En general, la distribución de este estadístico t no está tabulada debido a que la distribución depende de la relación entre el regresor en cuestión y el resto de los regresores.
3. **Regresión espuria.** Las tendencias estocásticas pueden originar que dos series temporales parezcan estar relacionadas cuando en realidad no lo están, un problema que se denomina regresión espuria.

Ar

➤ **Detención de tendencias estocásticas: contraste de raíz unitaria
AR**

Las tendencias en los datos de series temporales pueden detectarse mediante métodos formales e informales. Los *métodos informales* incluyen la inspección de los gráficos de los datos de series temporales y el cálculo de los coeficientes de autocorrelación. Sin embargo, si existiesen dudas se utilizaran los *procesos estadísticos formales*, que pueden utilizarse para contrastar la hipótesis de que exista una tendencia estocástica en la serie frente a la alternativa de que no exista ninguna tendencia.

Para contrastar la presencia de una tendencia estocástica se utiliza el contraste de Dickey-Fuller, no siendo el único contraste para detectar dichas tendencia, pero si el más utilizado en la práctica y uno de los más fiables.

• **El contraste de Dickey-Fuller en el modelo AR(1).**

El punto de partida del **contraste de Dickey-Fuller** es el modelo autoregresivo, siendo el paseo aleatorio de la ecuación $Y_t = \beta_0 + Y_{t-1} + u_t$ un caso particular del modelo AR(1) con $\beta_1 = 1$. Si $\beta_1 = 1$, Y_t es no estacionaria y contiene una tendencia (estocástica). Por tanto, el modelo AR(1), la hipótesis de que Y_t tiene una tendencia puede ser contrastada mediante el contraste:

$$H_0: \beta_1=1 \quad \text{vs} \quad H_1: \beta_1<1 \quad \text{en} \quad Y_t = \beta_0 + Y_{t-1} + u_t.$$

Si $\beta_1=1$, el AR(1) tiene raíz autorregresiva igual a 1, por lo que la hipótesis nula de la ecuación anterior es que el AR(1) tiene raíz unitaria, y la alternativa es que es estacionario.

Este contraste resulta más fácil de llevar a la práctica mediante la estimación de una versión modificada de la ecuación anteriormente mencionada. Para ello se debe

de restar Y_{t-1} a ambos lados de dicha ecuación. Sea $\delta = \beta_1 - 1$; por tanto la ecuación se convierte en

$$H_0: \delta=0 \text{ vs } H_1: \delta<0 \text{ en } \Delta Y_t = \beta_0 + \delta Y_{t-1} + u_t \quad (**)$$

El estadístico t MCO para contrastar $\delta=0$ de la ecuación (**) se denomina **estadístico de Dickey-Fuller**. La formulación de la ecuación (**) resulta más útil debido a que los software de regresión reportan automáticamente el estadístico t para contrastar $\delta=0$.

- **El contraste de Dickey-Fuller en el modelo AR(p).**

El estadístico de Dickey-Fuller presentado mediante la ecuación (**) solamente resulta útil para un modelo AR(1), ya que en algunas series el modelo AR(1) no capta toda la correlación serial de Y_t , en cuyo caso, resulta más apropiado un modelo autorregresivo de orden superior.

La extensión del contraste de Dickey-Fuller al modelo AR(p) se resume en el concepto clave 14.8. Bajo la hipótesis nula, $\delta=0$ y ΔY_t es un proceso AR(p) estacionario. Bajo las hipótesis alternativas, $\delta<0$, por lo que Y_t es estacionario. Debido a que el modelo de regresión para calcular esta versión del estadístico de Dickey-Fuller se ve aumentado por los retardos de ΔY_t , el estadístico t resultante se denomina **estadístico de Dickey-Fuller aumentado (ADF)**.

En general, la longitud del retardo p es desconocida, pero puede estimarse mediante un criterio de información aplicado a las regresiones para distintos valores de p. Los estudios del estadístico ADF sugieren que es mejor tener demasiados retardos que demasiados pocos, por lo que se recomienda la utilización del criterio de información AIC en lugar del criterio de información BIC para estimar p para el estadístico ADF.

- **El contraste de Dickey-Fuller aumentado para raíz unitaria autorregresiva.**

El contraste de Dickey-Fuller aumentado (ADF) para una raíz unitaria autorregresiva, contrasta la hipótesis nula $H_0: \delta=0$ frente a la hipótesis alternativa $H_1: \delta<0$ en la regresión

$$\Delta Y_t = \beta_0 + \delta Y_{t-1} + Y_1 \Delta Y_{t-1} + Y_2 \Delta Y_{t-2} + \dots + Y_p \Delta Y_{t-p} + u_t$$

Bajo la hipótesis nula, Y_t tiene una tendencia estocástica; la bajo la hipótesis alternativa, Y_t es estacionaria. El estadístico ADF es el estadístico t MCO para contrastar $\delta=0$ en la ecuación anterior.

Si en su lugar, la hipótesis alternativa es que Y_t es estacionaria en torno a una tendencia temporal lineal determinística, entonces debe añadirse esta tendencia, $\langle t \rangle$ (número de observaciones), como regresor adicional, en cuyo caso la regresión Dickey-Fuller se convierte en

$$\Delta Y_t = \beta_0 + \alpha t + \delta Y_{t-1} + Y_1 \Delta Y_{t-1} + Y_2 \Delta Y_{t-2} + \dots + Y_p \Delta Y_{t-p} + u_t$$

donde α es un coeficiente desconocido y el estadístico ADF es el estadístico t MCO para contrastar $\delta=0$

La longitud del retardo, p , se puede estimar utilizando el criterio BIC o AIC mencionado en el contraste de Dickey-Fuller en el modelo AR(p). Cuando $p=0$, no se incluyen retardos de ΔY_t como regresores en las ecuaciones expuestas, y el contraste ADF se simplifica al contraste de Dickey-Fuller en el modelo AR(1). El estadístico ADF *no* sigue una distribución normal, incluso en muestras grandes.

- **Contraste frente a la alternativa de estacionariedad en torno a una tendencia temporal determinística.**

Hasta ahora no hemos considerado crecimientos a largo plazo en las series temporales y por tanto la hipótesis alternativa de estacionariedad era adecuada. Sin embargo, otras series temporales muestran crecimientos a largo plazo, y para tales series la alternativa de estacionariedad sin tendencia no es apropiada. En cambio, una alternativa que se utiliza habitualmente es que las series sean estacionaria alrededor de una tendencia temporal determinística, es decir, una tendencia que sea una función determinística del tiempo.

Una formulación específica de esta hipótesis alternativa es que la tendencia temporal es lineal, es decir, la tendencia es una función lineal de t ; por lo tanto, la hipótesis nula es que la serie tiene una raíz unitaria, y la alternativa es que no tiene una raíz unitaria, pero tiene una tendencia temporal determinística. La regresión de Dickey-Fuller debe modificarse para contrastar la hipótesis nula de una raíz unitaria frente a la alternativa de que es estacionaria alrededor de una tendencia temporal lineal.

- **Valores críticos para el estadístico ADF.**

Bajo la hipótesis nula de existencia de una raíz unitaria, el estadístico ADF *no* tiene una distribución normal, incluso en muestras grandes. Debido a que su distribución no es estándar, no pueden ser utilizados los valores críticos habituales de la distribución normal cuando se utiliza el estadístico ADF para el contraste de raíz unitaria; debe utilizarse en su lugar un conjunto particular de valores críticos, basado en la distribución del estadístico ADF bajo la hipótesis nula.

Los valores críticos para muestras grandes del estadístico Dickey-Fuller aumentado son:

Tabla 2.1. Valores crítico para muestras grandes del estadístico Dickey-Fuller aumentado

Regresores determinísticos	10%	5%	1%
Solamente término independiente	-2,57	-2,86	-3,43
Término independiente y	-3,12	-3,41	-3,96

tendencia temporal			
--------------------	--	--	--

Fuente: manual introducción a la econometría Stock-Watson 3ª edición

CAPÍTULO 3

ANÁLISIS EMPÍRICO

3.1. ESTUDIADAS EN ESTE ANÁLISIS SERIES

Para el análisis empírico hemos usado las siguientes series: número de ocupados y número de parados, según la Encuesta de Población Activa (EPA) de publicación trimestral, (ambas series expresadas en miles de personas). Como posibles variables explicativas, hemos seleccionado el PIB p.m. (a precio corriente y expresado en millones de €) y el número de afiliados a la Seguridad Social en el sector turístico, en número de personas, datos que como se ha dicho han sido extraídos del Instituto Nacional de Estadística. Las series se inician en el primer trimestre del año 2002.

Tabla 3.1. Datos de ocupados, parados, PIB p.m. y trabajadores afiliados a la Seguridad Social en el sector turístico

Ocupados, parados ambos sexos. Valores absolutos				
Unidad: miles de personas				
PIB p.m. (precios corrientes)				
Unidad: millones de €				
Trabajadores afiliados en alta laboral en las actividades características del turismo, según alta en la Seguridad Social.				
Unidad: personas				
AÑO/TRIMESTRE	AMBOS SEXOS			TRABAJADORES AFILIADOS A LA SEG. SOC. EN TURISMO
	OCUPADOS	PARADOS	PIB p.m.	
2002 T1	16.482,30	2.152,80	178.035	4.470.407
2002 T2	16.766,90	2.103,30	189.241	4.808.259
2002 T3	16.919,30	2.196,00	183.483	4.966.604
2002 T4	16.991,90	2.232,40	198.529	4.623.781
2003 T1	17.092,70	2.328,50	191.429	4.614.368
2003 T2	17.423,20	2.216,00	202.696	4.974.439
2003 T3	17.646,00	2.247,50	196.584	5.098.490
2003 T4	17.740,50	2.276,70	212.763	4.781.509
2004 T1	17.770,20	2.309,80	204.597	4.787.539
2004 T2	18.018,90	2.247,60	217.279	5.117.232
2004 T3	18.289,10	2.199,80	210.830	5.246.536
2004 T4	18.490,80	2.176,90	228.714	4.963.828
2005 T1	18.736,10	2.121,30	220.699	4.950.769
2005 T2	19.160,60	1.969,10	235.441	5.333.705
2005 T3	19.422,10	1.783,50	227.156	5.553.493
2005 T4	19.509,20	1.860,30	247.270	5.274.302
2006 T1	19.578,40	1.942,80	239.893	5.259.287
2006 T2	19.891,60	1.834,40	254.684	5.648.162
2006 T3	20.091,00	1.766,90	245.818	5.788.844
2006 T4	20.195,40	1.819,40	267.579	5.467.226
2007 T1	20.267,50	1.863,20	257.880	5.530.127
2007 T2	20.580,90	1.773,20	273.403	5.915.203
2007 T3	20.753,40	1.806,20	262.365	5.998.687
2007 T4	20.717,90	1.942,00	287.159	5.802.493

2008 T1	20.620,00	2.190,50	270.108	5.703.258
2008 T2	20.646,90	2.385,70	285.570	6.028.750
2008 T3	20.556,40	2.600,70	272.100	6.060.619
2008 T4	20.055,30	3.206,80	288.429	5.722.064
2009 T1	19.284,40	4.018,20	261.272	5.600.268
2009 T2	19.154,20	4.139,60	274.441	5.858.288
2009 T3	19.098,40	4.121,40	262.355	5.916.985
2009 T4	18.890,40	4.335,00	280.966	5.633.318
2010 T1	18.652,90	4.617,70	260.239	5.592.145
2010 T2	18.751,10	4.655,30	275.120	5.905.524
2010 T3	18.819,00	4.585,40	263.756	6.005.290
2010 T4	18.674,90	4.702,20	281.798	5.683.728
2011 T1	18.426,20	4.921,20	260.813	5.581.525
2011 T2	18.622,00	4.844,20	273.433	5.989.620
2011 T3	18.484,50	4.998,00	261.202	6.110.675
2011 T4	18.153,00	5.287,30	274.965	5.698.668
2012 T1	17.765,10	5.667,90	255.036	5.587.376
2012 T2	17.758,50	5.731,00	264.212	5.968.416
2012 T3	17.667,70	5.824,20	255.227	6.088.663
2012 T4	17.339,40	6.021,00	265.283	5.570.053
2013 T1	17.030,20	6.278,20	248.162	5.501.232
2013 T2	17.160,60	6.047,30	260.089	5.933.696
2013 T3	17.230,00	5.943,40	252.108	6.132.629
2013 T4	17.135,20	5.935,60	265.275	5.667.141
2014 T1	16.950,60	5.933,30	249.091	5.604.512
2014 T2	17.353,00	5.622,90	261.926	6.176.402
2014 T3	17.504,00	5.427,70	255.338	6.357.192
2014 T4	17.569,10	5.457,70	270.670	5.879.280
2015 T1	17.454,80	5.444,60	256.800	5.879.325
2015 T2	17.866,50	5.149,00	271.769	6.446.396
2015 T3	18.048,70	4.850,80	265.678	6.613.040
2015 T4	18.094,20	4.779,50	281.392	6.181.257
2016 T1	18.029,60	4.791,40	265.060	6.166.780
2016 T2	18.301,00	4.574,70	282.943	6.740.394
2016 T3	18.527,50	4.320,80	274.862	6.949.741
2016 T4	18.508,10	4.237,80	290.986	6.467.852
2017 T1	18.438,30	4.255,00	---	6.434.079

Fuente: Elaboración propia a partir de datos del INE.

3.2. DIVERSOS INTENTOS DE MODELIZACIÓN

Como ya hemos comentado, este análisis empírico no trata de dar una perfecta situación sobre la realidad de las variables tratada, ya que sólo son estudiadas a un

nivel de trabajo de fin de grado, y de ilustración de una forma de modelizar, y por tanto, no trata de incidir con la mayor profundidad científica sobre las variables objeto de nuestro empirismo.

Para la realización del estudio econométrico sobre las series temporales se ha utilizado el programa GRETL, de acceso libre, el cual nos ha proporcionado las estimaciones de las que a continuación pasaremos a analizar los más relevantes.

El estudio se ha realizado mediante dos regresiones lineales separadas (ocupados y parados), y en las cuales se ha realizado estimaciones y contraste a través de modelos econométricos para series temporales. Los modelos utilizados son: los modelos de series temporales mediante AR (1) para “ocupados y parados”: Cochrane-Orcutt, Prais-Winsten y Hildreth-Lu. Además se han extraído gráficos de cada uno de los modelos sobre los residuos contra el tiempo, para que con ello se pueda tener una visión econométrica más certera sobre los datos estudiados. También se han llevado a cabo los contrastes aumentados de Dickey-Fuller para ocupados y parados, y contrastes de Dickey-Fuller mediante AR (p) con 4 retardos para ambos.

En cuanto a los datos más relevantes para la regresión de “ocupados”, se observa que dichas regresiones son significativas al 1% para los modelos Cochrane-Orcutt, Prais-Winsten y Hildreth-Lu, por lo tanto, los datos estudiados gozan de gran veracidad. Siguiendo con el análisis, se observa como el coeficiente de determinación (R^2) es muy cercano a la unidad para los tres modelos analizado, por lo cual se deduce que los regresores estudiados son buenos al predecir los valores de la variable dependiente en las muestras. Además las pendientes de los modelos son positivas, ya que ante aumentos en las variables explicativas (PIB p.m. y TUR) hace que aumente la variable objetivo (ocupados).

Por otra parte, en el análisis de los datos para la regresión de “parados”, se observa que también es significativo al 1% para Cochrane-Orcutt, Prais-Winsten y Hildreth-Lu. Además se observa un R^2 muy cercano a 1 para los tres modelos tratados, por lo que se consideran que los regresores estudiados son buenos al predecir los valores de la variable. En cambio, con respecto a las pendientes, ésta es totalmente inversa a la de los modelos de la regresión para los ocupados, es decir, la pendiente es negativa, por lo cual ante disminuciones del PIB p.m. y del turismo los parados aumentan, algo muy predecible ya que la variable actúa inversamente.

Mostramos en primer lugar la gráfica de la serie temporal correspondiente al número de ocupados:

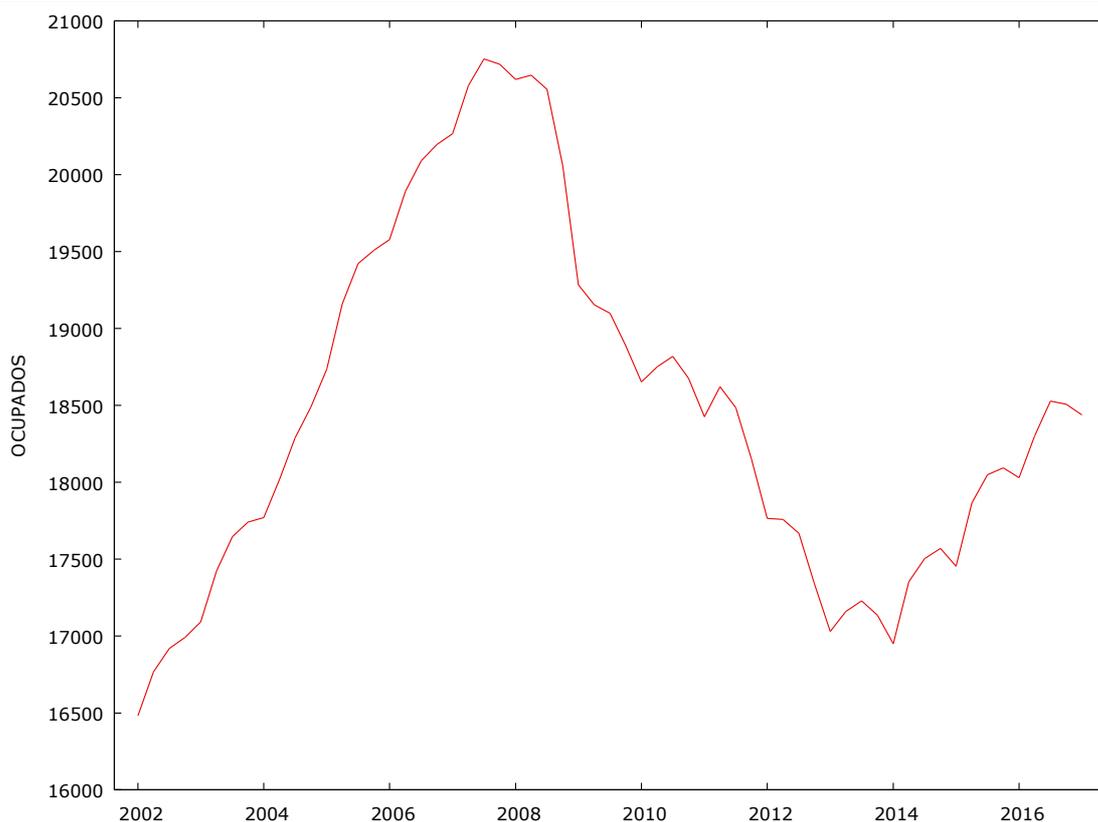


Figura 3.1. Gráfico de series temporales del modelo sobre ocupados. Fuente: Elaboración propia a partir de los datos del INE y proporcionada por Gretl.

Contraste aumentado de Dickey-Fuller para ocupados

Incluyendo 10 retardos de $(1-L)OCUPADOS$

(el máximo fue 10, el criterio AIC)

tamaño muestral 50

hipótesis nula de raíz unitaria: $\alpha = 1$

contraste con constante

modelo: $(1-L)y = b_0 + (a-1)y(-1) + \dots + e$

valor estimado de $(a - 1)$: -0.0601041

Estadístico de contraste: $\tau_c(1) = -2.70195$

valor p asintótico 0.07363

Coef. de autocorrelación de primer orden de e : -0.070

diferencias retardadas: $F(10, 38) = 16.754$ [0.0000]

con constante y tendencia

modelo: $(1-L)y = b_0 + b_1*t + (a-1)y(-1) + \dots + e$

valor estimado de $(a - 1)$: -0.0766161

Estadístico de contraste: $\tau_{ct}(1) = -2.90976$

valor p asintótico 0.1592

Coef. de autocorrelación de primer orden de e : -0.056

diferencias retardadas: $F(10, 37) = 15.721$ [0.0000]

El contraste realizado tiene como hipótesis nula $\beta = 1$, o sea, que se trata de un paseo aleatorio. En este caso, como se ve en el valor p , se rechaza dicha hipótesis y se acepta que se trata de un proceso estacionario.

Nos proponemos a continuación modelizar dicho número de ocupadas a partir de las variables explicativas propuestas.

Modelos de series temporales mediante AR (1) para ocupados : Cochrane-Orcutt, Prais-Winsten y Hildreth-Lu

Modelo 1: **Cochrane-Orcutt**, usando las observaciones 2002:2-2016:4 (T = 59)
Variable dependiente: **OCUPADOS**
 $\rho = 0.983462$

	<i>Coefficiente</i>	<i>Desv. Típica</i>	<i>Estadístico t</i>	<i>valor p</i>	
const	14722.8	1616.58	9.107	<0.0001	***
PIBpm	0.00594074	0.00160322	3.705	0.0005	***
TUR	0.474759	0.0784935	6.048	<0.0001	***

Estadísticos basados en los datos rho-diferenciados:

Media de la vble. dep.	18512.49	D.T. de la vble. dep.	1154.170
Suma de cuad. residuos	1680045	D.T. de la regresión	173.2074
R-cuadrado	0.978532	R-cuadrado corregido	0.977765
F(2, 56)	23.86103	Valor p (de F)	3.20e-08
rho	0.664397	Durbin-Watson	0.672277

Observamos un coeficiente de autocorrelación entre perturbaciones aleatorias próximo a 1. Las dos variables explicativas son significativas y de pendientes positivas. El modelo es globalmente significativo. La única duda que plantea es la que nos genera el valor del estadístico de Durbin-Watson, que toma un valor más próximo a cero que a dos, lo que nos hace pensar que el problema de la autocorrelación aún no ha sido resuelto. La gráfica que sigue nos confirma este hecho, pues se dan secuencias largas de residuos positivos y de residuos negativos. Destacamos el importante peso que tiene el empleo en el sector turístico sobre el empleo en general en la economía española.

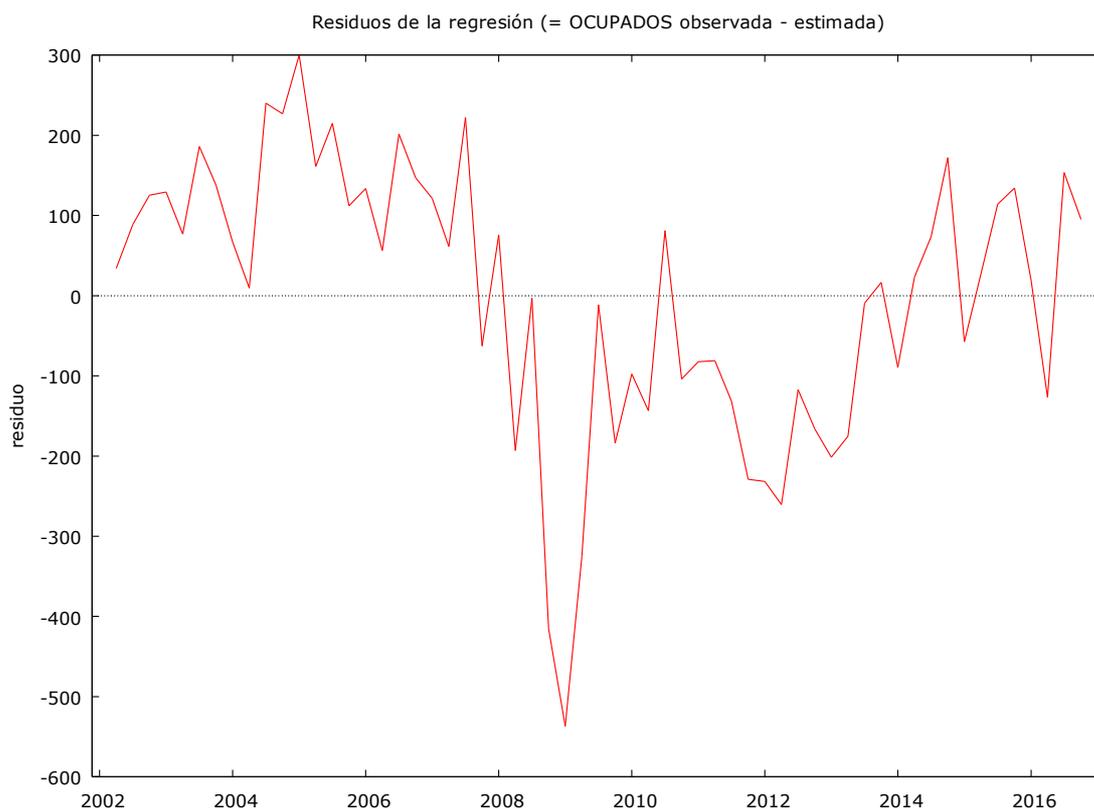


Figura 3.2. Gráfico de los residuos de la regresión contra el tiempo en el modelo Cochrane-Orcutt para ocupados. Fuente: Elaboración propia a partir de los datos proporcionados por Gretl.

A continuación procedemos a estimar el mismo modelo usando el procedimiento de Prais-Winsten:

Modelo 2: **Prais-Winsten**, usando las observaciones 2002:1-2016:4 (T = 60)

Variable dependiente: **OCUPADOS**

$\rho = 0.990199$

	<i>Coefficiente</i>	<i>Desv. Típica</i>	<i>Estadístico t</i>	<i>valor p</i>	
const	13579.5	1230.02	11.04	<0.0001	***
PIBpm	0.00616395	0.00156686	3.934	0.0002	***
TUR	0.484523	0.0770317	6.290	<0.0001	***

Estadísticos basados en los datos rho-diferenciados:

Media de la vble. dep.	18478.65	D.T. de la vble. dep.	1173.978
Suma de cuad. residuos	1695025	D.T. de la regresión	172.4450
R-cuadrado	0.979656	R-cuadrado corregido	0.978943
F(2, 57)	96.38539	Valor p (de F)	5.16e-19
rho	0.646919	Durbin-Watson	0.706902

En cuanto al modelo 2 (Prais-Winsten) observamos que es globalmente significativo. El único valor de dicha regresión que nos genera dudas es el valor del estadístico de Durbin-Watson, que toma un valor más próximo a cero que a dos, por lo que se

deduce que el problema de la autocorrelación aún no ha sido resuelto. Además la gráfica que siguiente nos confirma este hecho, pues se dan secuencias largas de residuos positivos y de residuos negativos. Destacamos el importante peso que tiene el empleo en el sector turístico sobre el empleo en general en la economía española.

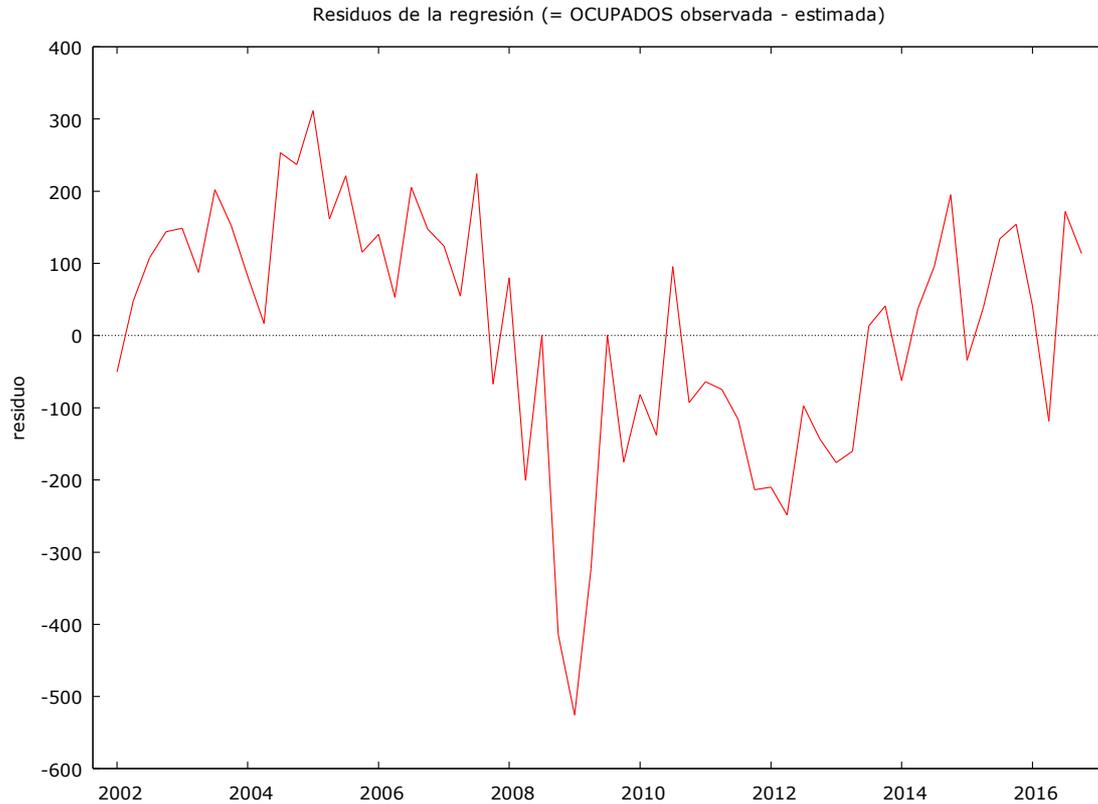


Figura 3.3. Gráfico de los residuos de la regresión contra el tiempo en el modelo Prais-Winsten para ocupados. Fuente: Elaboración propia a partir de los datos proporcionados por Gretl.

A continuación procedemos a estimar el mismo modelo usando el procedimiento de Hildreth-Lu

Modelo 3: **Hildreth-Lu**, usando las observaciones 2002:2-2016:4 (T = 59)

Variable dependiente: **OCUPADOS**

$\rho = 0.983462$

	<i>Coefficiente</i>	<i>Desv. Típica</i>	<i>Estadístico t</i>	<i>valor p</i>	
const	14722.8	1616.58	9.107	<0.0001	***
PIBpm	0.00594074	0.00160322	3.705	0.0005	***
TUR	0.474759	0.0784935	6.048	<0.0001	***

Estadísticos basados en los datos rho-diferenciados:

Media de la vble. dep.	18512.49	D.T. de la vble. dep.	1154.170
------------------------	----------	-----------------------	----------

Suma de cuad. residuos	1680045	D.T. de la regresión	173.2074
R-cuadrado	0.978532	R-cuadrado corregido	0.977765
F(2, 56)	23.86103	Valor p (de F)	3.20e-08
rho	0.664397	Durbin-Watson	0.672277

Al igual que los modelos mencionados anteriormente, este modelo también es globalmente significativo, teniendo las mismas dudas en cuanto al valor proporcionado por el estadístico Durbin-Watson, ya que está más próximo a cero que a dos, por lo que se deduce que el problema de autocorrelación aún no ha sido resuelto. Además la gráfica siguiente nos proporciona los datos más explícitos, pues se observa unas secuencias largas de residuos positivos y de residuos negativos.

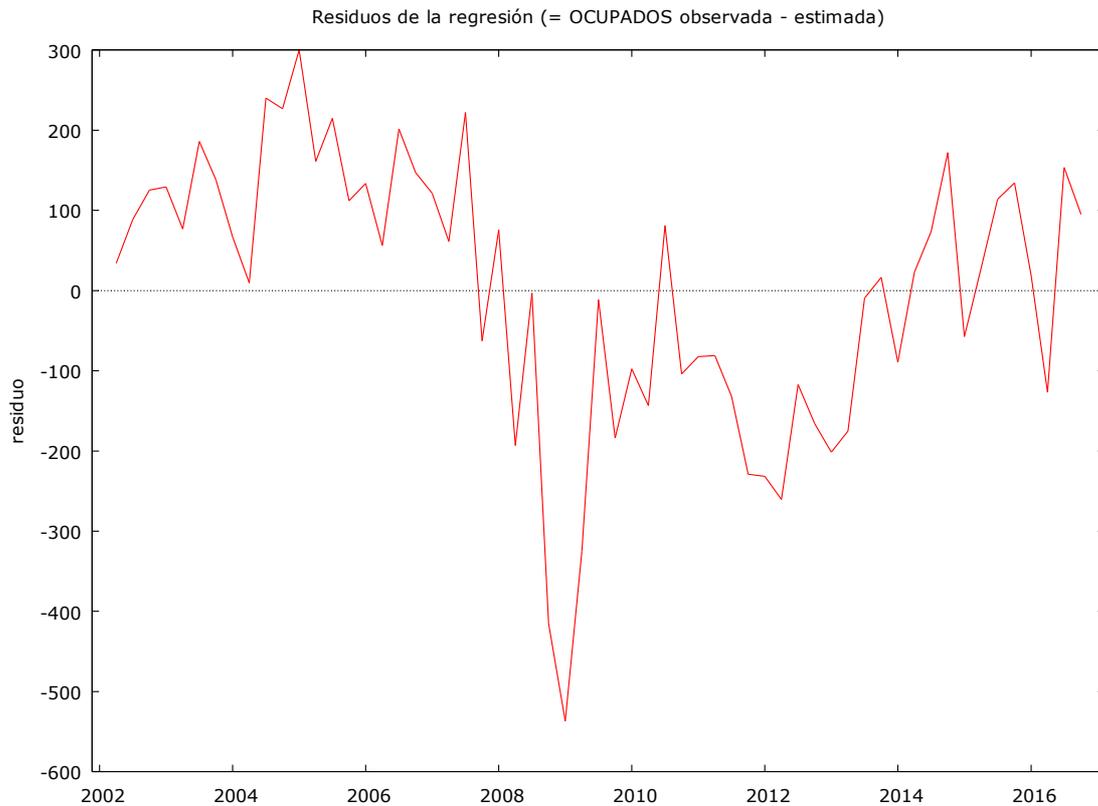


Figura 3.4. Gráfico de los residuos de la regresión contra el tiempo en el modelo Hildreth-Lu para ocupados. . Fuente: Elaboración propia a partir de los datos proporcionados por Gretl.

Contraste de Dickey-Fuller mediante AR (p) con 4 retardos

Contraste KPSS para OCUPADOS

T = 61

Parámetro de truncamiento de los retardos = 4

Estadístico de contraste = 0.28204

10% 5% 1%

Valores críticos: 0.351 0.462 0.728

Valor p > .10

Modelo autoregresivo de serie temporales con 4 retardos para ocupadosModelo : **AR**, usando las observaciones 2003:1-2016:4 (T = 56)Variable dependiente: **OCUPADOS**

	<i>Coefficiente</i>	<i>Desv. Típica</i>	<i>Estadístico t</i>	<i>valor p</i>	
const	10688.7	1147.99	9.311	<0.0001	***
PIBpm	0.0200668	0.00259433	7.735	<0.0001	***
TUR	0.448812	0.0284293	15.79	<0.0001	***
u(-1)	1.14073	0.136777	8.3401	<0.0001	***
u(-2)	0.688513	0.141688	4.8594	<0.0001	***
u(-3)	-1.11751	0.145921	-7.6583	<0.0001	***
u(-4)	0.270649	0.139152	1.9450	0.0572	*

Estadísticos basados en los datos rho-diferenciados:

Media de la vble. dep.	333.9656	D.T. de la vble. dep.	280.0059
Suma de cuad. residuos	682377.0	D.T. de la regresión	113.4682
R-cuadrado	0.990266	R-cuadrado corregido	0.989899
F(2, 53)	140.9629	Valor p (de F)	6.06e-22
rho	0.091100	Durbin-Watson	1.748159

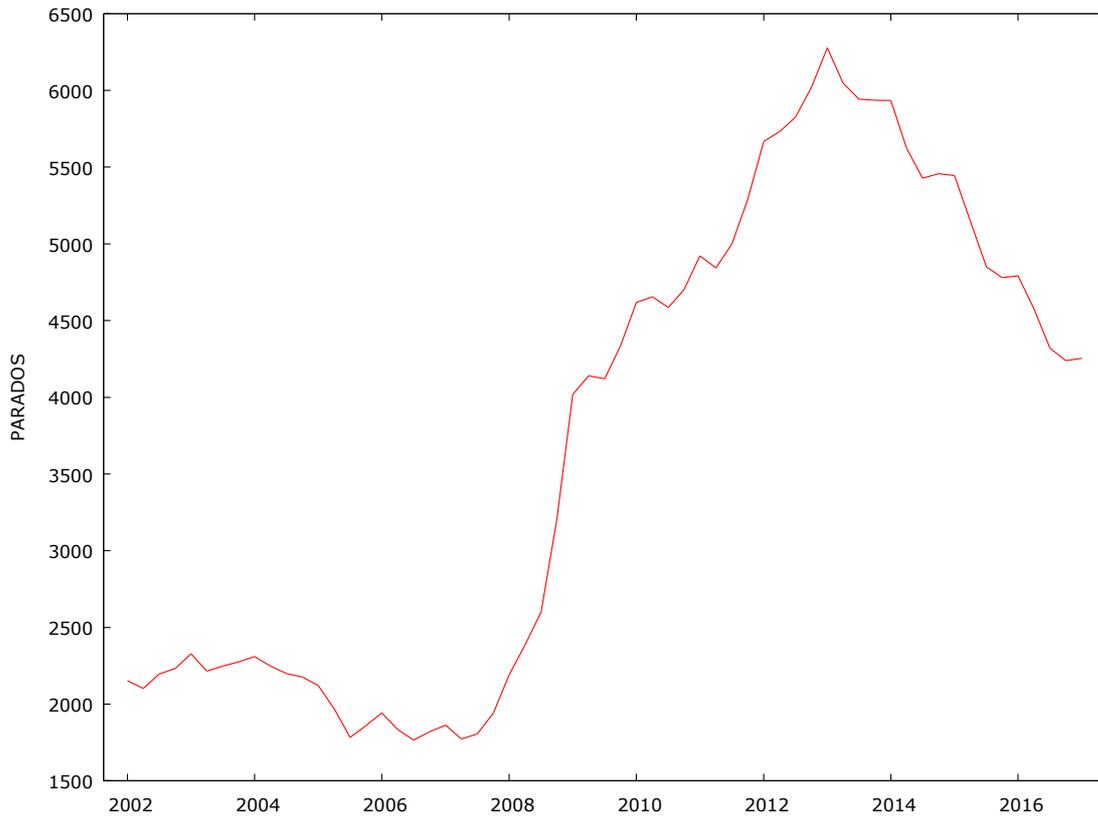


Figura 3.5. Gráfico de series temporales del modelo sobre parados. Fuente: Elaboración propia a partir de los datos proporcionados por Gretl.

Contraste aumentado de Dickey-Fuller para parados

Contraste aumentado de Dickey-Fuller para PARADOS
 testing down from 10 lags, criterion AIC
 tamaño muestral 55
 hipótesis nula de raíz unitaria: $a = 1$

contraste con constante
 incluyendo 5 retardos de $(1-L)PARADOS$
 modelo: $(1-L)y = b_0 + (a-1)y(-1) + \dots + e$
 valor estimado de $(a - 1)$: -0.0164311
 Estadístico de contraste: $\tau_c(1) = -1.44319$
 valor p asintótico 0.5626
 Coef. de autocorrelación de primer orden de e: 0.008
 diferencias retardadas: $F(5, 48) = 19.174 [0.0000]$

con constante y tendencia
 incluyendo 5 retardos de $(1-L)PARADOS$
 modelo: $(1-L)y = b_0 + b_1t + (a-1)y(-1) + \dots + e$
 valor estimado de $(a - 1)$: -0.0391709
 Estadístico de contraste: $\tau_{ct}(1) = -1.46364$
 valor p asintótico 0.842
 Coef. de autocorrelación de primer orden de e: 0.026
 diferencias retardadas: $F(5, 47) = 18.683 [0.0000]$

Modelos de series temporales mediante AR (1) para parados: Cochrane-Orcutt, Prais-Winsten y Hildreth-Lu

Modelo 1: **Cochrane-Orcutt**, usando las observaciones 2002:2-2016:4 (T = 59)

Variable dependiente: **PARADOS**

$\rho = 0.983724$

	<i>Coefficiente</i>	<i>Desv. Típica</i>	<i>Estadístico t</i>	<i>valor p</i>	
const	10147.2	1567.78	6.472	<0.0001	***
PIBpm	-0.00416692	0.00153499	-2.715	0.0088	***
TUR	-0.353962	0.0751543	-4.710	<0.0001	***

Estadísticos basados en los datos rho-diferenciados:

Media de la vble. dep.	3740.081	D.T. de la vble. dep.	1585.721
Suma de cuad. residuos	1540582	D.T. de la regresión	165.8626
R-cuadrado	0.989438	R-cuadrado corregido	0.989061
F(2, 56)	14.03856	Valor p (de F)	0.000011
rho	0.629398	Durbin-Watson	0.749134

Con respecto a la regresión para la variable dependiente de parados se observa un coeficiente de autocorrelación entre perturbaciones aleatorias próximo a 1. Las dos variables explicativas (PIBpm y TUR) son significativas y de pendientes negativa. El modelo es globalmente significativo. El principal problema de este modelo es el que nos proporciona el estadístico de Durbin-Watson, que toma un valor más próximo a cero que a dos, lo que nos hace pensar que el problema de la autocorrelación aún no ha sido resuelto. La gráfica que sigue nos confirma este hecho, pues se dan secuencias largas de residuos positivos y de residuos negativos alternándose dicha positividad y negatividad de los residuos. Además destacamos que ante descensos del PIBpm y TUR el paro aumenta considerablemente, es decir, las variables actúan inversamente.

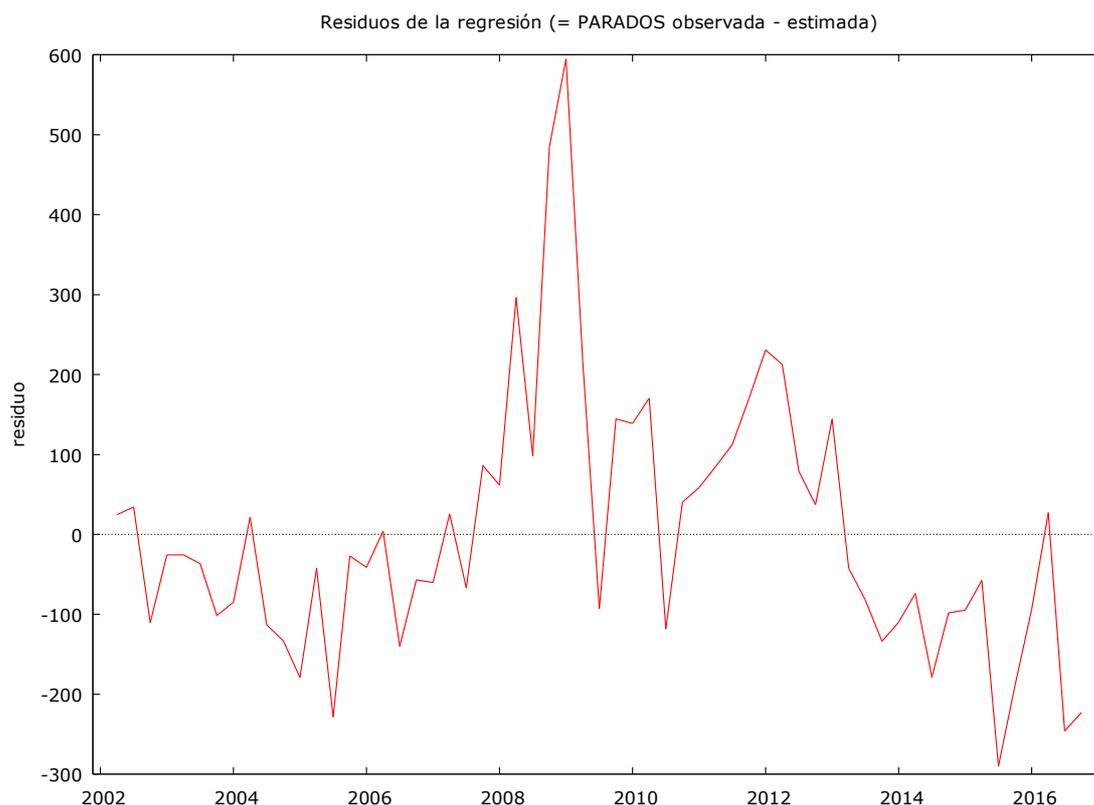


Figura 3.6. Gráfico de los residuos de la regresión contra el tiempo en el modelo Cochrane-Orcutt para parados. Fuente: Elaboración propia a partir de los datos proporcionados por Gretl.

Modelo 2: **Prais-Winsten**, usando las observaciones 2002:1-2016:4 (T = 60)
 Variable dependiente: **PARADOS**
 $\rho = 0.993874$

	<i>Coefficiente</i>	<i>Desv. Típica</i>	<i>Estadístico t</i>	<i>valor p</i>	
const	5850.19	1587.26	3.686	0.0005	***
PIBpm	-0.00339175	0.00160759	-2.110	0.0393	**
TUR	-0.321781	0.0790123	-4.073	0.0001	***

Estadísticos basados en los datos rho-diferenciados:

Media de la vble. dep.	3713.627	D.T. de la vble. dep.	1585.524
Suma de cuad. residuos	1786678	D.T. de la regresión	177.0458
R-cuadrado	0.989127	R-cuadrado corregido	0.988745
F(2, 57)	9.102146	Valor p (de F)	0.000371
rho	0.677775	Durbin-Watson	0.631702

En cuanto al modelo Prais-Winsten, se observa que es similar al anterior modelo tratado (Cochrane-Orcutt), es decir, es globalmente significativo y presenta un valor del estadístico Durbin-Watson muy cercano a cero, por lo tanto se deduce que no se ha corregido el problema de autocorrelación. Por otra parte, la gráfica es similar y presenta las mismas secuencias de positividad y negatividad de los residuos, alternándose igualmente.

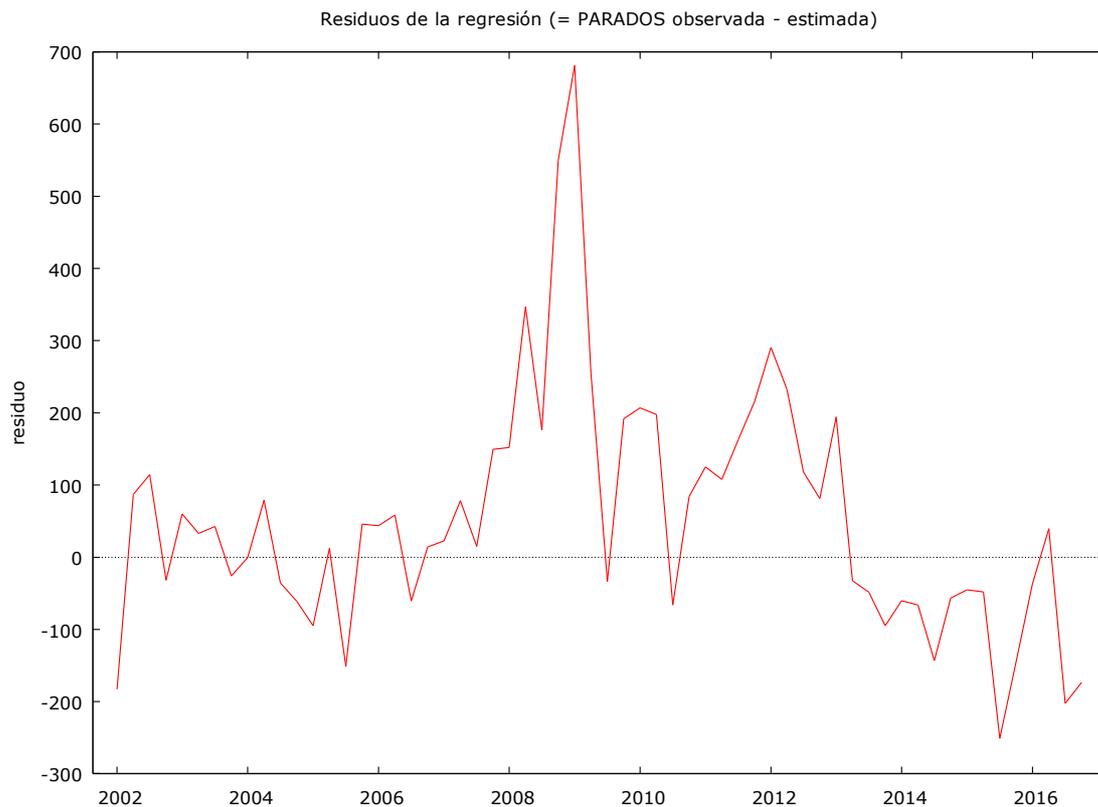


Figura 3.7. Gráfico de los residuos de la regresión contra el tiempo en el modelo Prais-Winsten para parados. Fuente: Elaboración propia a partir de los datos proporcionados por Gretl.

Modelo 3: **Hildreth-Lu**, usando las observaciones 2002:2-2016:4 (T = 59)
Variable dependiente: **PARADOS**
 $\rho = 0.983723$

	<i>Coefficiente</i>	<i>Desv. Típica</i>	<i>Estadístico t</i>	<i>valor p</i>	
const	10147.0	1567.70	6.473	<0.0001	***
PIBpm	-0.00416692	0.00153499	-2.715	0.0088	***
TUR	-0.353962	0.0751543	-4.710	<0.0001	***

Estadísticos basados en los datos rho-diferenciados:

Media de la vble. dep.	3740.081	D.T. de la vble. dep.	1585.721
Suma de cuad. residuos	1540582	D.T. de la regresión	165.8626
R-cuadrado	0.989438	R-cuadrado corregido	0.989061
F(2, 56)	14.03856	Valor p (de F)	0.000011
rho	0.629398	Durbin-Watson	0.749134

Por último el modelo Hildreth-Lu es globalmente significativo y aunque tiene el mayor valor con respecto a un coeficiente de autocorrelación entre perturbaciones aleatorias

de los tres modelos tratados sigue siendo próximo a cero, por lo cual se deduce que el problema de autocorrelación persiste. Se observa que el gráfico es muy similar a los mencionados en los dos modelos anteriores, y por tanto se deduce que las variables actúan del mismo modo.

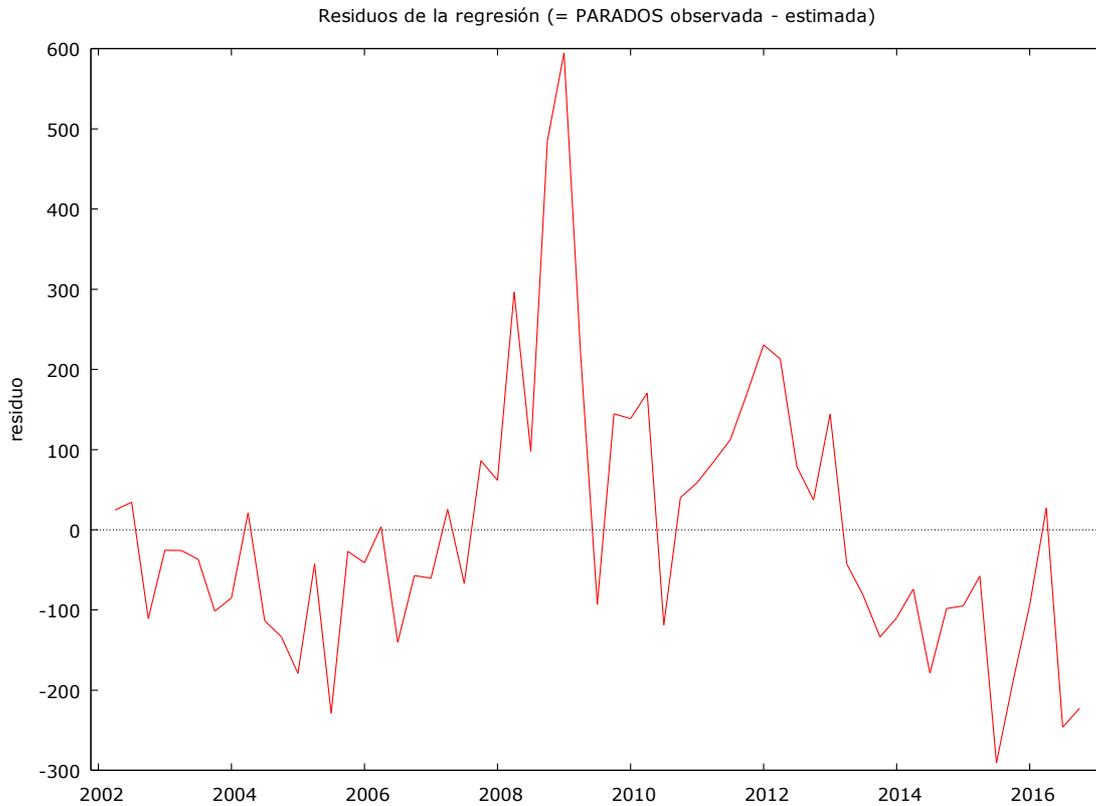


Figura 3.8. Gráfico de los residuos de la regresión contra el tiempo en el modelo Hildreth-Lu para parados. . Fuente: Elaboración propia a partir de los datos proporcionados por Gretl.

Contraste de Dickey-fuller mediante AR (p) con 4 retardos

Contraste KPSS para PARADOS

T = 61

Parámetro de truncamiento de los retardos = 4

Estadístico de contraste = 1.03978

	10%	5%	1%
Valores críticos:	0.351	0.462	0.728
Valor p < .01			

Modelo autoregresivo de serie temporales con 4 retardos para parados.

Modelo 4: AR, usando las observaciones 2003:1-2016:4 (T = 56)
Variable dependiente: PARADOS

	<i>Coefficiente</i>	<i>Desv. Típica</i>	<i>Estadístico t</i>	<i>valor p</i>	
const	6463.48	1121.12	5.765	<0.0001	***
PIBpm	-0.00204749	0.000487108	-4.203	0.0001	***
TUR	-0.300543	0.0645330	-4.657	<0.0001	***
u(-1)	1.71524	0.128608	13.3370	<0.0001	***
u(-2)	-0.998345	0.254209	-3.9273	0.0003	***
u(-3)	0.604658	0.257026	2.3525	0.0225	**
u(-4)	-0.336684	0.129169	-2.6065	0.0119	**

Estadísticos basados en los datos rho-diferenciados:

Media de la vble. dep.	61.38176	D.T. de la vble. dep.	148.9778
Suma de cuad. residuos	728785.8	D.T. de la regresión	117.2633
R-cuadrado	0.994723	R-cuadrado corregido	0.994524
F(2, 53)	17.88659	Valor p (de F)	1.16e-06
rho	-0.029979	Durbin-Watson	1.968319

CAPÍTULO 4

CONCLUSIÓN

La econometría dispone de un importante instrumental para la modelización de series temporales, tanto de serie única como de serie explicada por otros factores relacionados. De hecho, parece ser que el origen histórico de la econometría fue el estudio de estos comportamientos. El objetivo de este trabajo ha sido de aprendizaje de estas técnicas, no de todas ellas, y sí de las más conocidas. La idea de camino aleatorio, de tendencia de autorregresión y de estimaciones de modelos con estas características temporales es el objetivo a adquirir. A nivel empírico, y con datos de la economía española proporcionados por el INE mostramos cómo llevar a cabo modelizaciones en las que la variable objetivo es el empleo (a nivel trimestral) y el desempleo (También trimestral) a partir de variables claramente explicativas como el PIB y el empleo en el sector turístico, con lo que comprobamos el peso que tiene este sector en nuestra economía.

Bibliografía

Enders, W. (2004), *Applied Econometric Time series*. Wiley & Sons.

Espasa, A. y J.R. Cancelo (eds) (1993), *Métodos cuantitativos para el análisis de la coyuntura económica*, Alianza, capítulos 2 y 3.

Greene W.(1998). *Análisis Económico*. 3ª edición. Prentice Hall.

Gujarati, D. (1997), *Econometría*. Ed. McGraw-Hill.

Lütkepohl, H. y M. Kratzig. (2004), *Applied Time Series Econometrics*, Cambridge University Press

Maddala, G. S. (1996). *Introducción a la Econometría*. Ed. McGraw-Hill.

Novalés, A. (1998). *Econometría*. Ed. McGraw-Hill. 4ª Edición.

Peña, D. (2005), *Análisis de Series Temporales*. Alianza Editorial.

Pindyck R. y Rubinfeld, D. L. (2000). *Econometría: modelos y pronósticos*. Ed. MacGraw-Hill.

Pulido, A. (2001). *Modelos Económicos*. Ed. Pirámide.

Schmidt, S. J. (2005). *Econometría*. Ed. MacGraw-Hill.

Stock, J. H. y Watson, M. M. (2012). *Introducción a la Econometría*. 3ª edición. Pearson.

Wooldridge, J.M. (2005). *Introducción a la Econometría. Un enfoque moderno*. Ed. Thomson.