GRADO EN ADMINISTRACIÓN Y DIRECCIÓN DE EMPRESAS

2015/2016

TRABAJO FIN DE GRADO

ANÁLISIS Y PREDICCIÓN DE SERIES TEMPORALES MÚLTIPLES: UNA APLICACIÓN A LAS PRUEBAS DE RESISTENCIA BANCARIA.

TIME SERIES ANALYSIS AND PREDICTION: AN APPLICATION TO BANK TEST STRESS

RAMÓN SOTA MUÑOZ

TUTOR: JOSÉ LUIS GALLEGO GÓMEZ

FECHA

30/06/2016

ÍNDICE

1. Resumen **3**

2. Introducción **3**

3. Marco teórico **5**
3.1 Definición de los tests de stress 5
3.2 Simulación de escenarios teóricos 5
3.3 Datos 6
3.4 Descripción del método 7

4. Metodología **7**
4.1 Modelos ARIMA 7
4.2 Modelos de función de transferencia 11
4.3 Modelos VARIMA 12
4.4 Predicción con modelos VARIMA 15
4.4.1 Cálculo de predicciones a partir de la ecuación en diferencia ARIMA
4.4.2 Cálculo de predicciones a partir de la forma infinita de medias móviles

5. Análisis Univariante **17**
5.1 Ratio financiera 17
5.2 Paro registrado 19
5.3 Índice de Producción Industrial (IPI) 20
5.4 Deducción 20

6. Análisis multivariante **21**
6.1 Identificación 21
6.2 Predicción 23
6.3 Análisis y simulación de escenarios teóricos 25

7. Conclusiones **27**

8. Apéndice de gráficos **29**

9. Bibliografía **37**

1. RESUMEN

El uso de los tests de stress macro para evaluar la solvencia bancaria ha sido desarrollado rápidamente a lo largo de estos últimos años. Además, estos tests de stress han demostrado ser una herramienta muy útil para identificar las debilidades potenciales del sector bancario, y para estimar su resistencia a los acontecimientos adversos.

Para llevar a cabo el desarrollo del análisis, se va a utilizar la metodología de análisis de series temporales propuesta por Box y Jenkins, en sus niveles univariantes y multivariantes proporcionando un marco teórico para realizar este tipo de test.

Este documento presenta todas las características dentro este marco teórico y se aplica al análisis de 3 series temporales: una ratio financiera, el paro registrado y el índice de producción industrial.

ABSTRACT

The use of macro stress tests to assess bank solvency has developed rapidly over the past few years. Besides, macro stress testing has proved a useful instrument to help identify potential vulnerabilities within the banking sector and to gauge its resilience to adverse developments.

In order to carry out the analysis development, it will be used the methodology of temporal series analyisis formulated by Box and Jenkins, in the univariate and multivariate case in order to set up a framework.

This paper present all the feaures of this framework and they are aplicated to three temporal series: a financial ratio, the unemployment rate and industrial production index.

2. INTRODUCCIÓN

Con el fin de medir la resistencia del sistema financiero en su conjunto frente a varios escenarios adversos, los tests de stress (tests de resistencia bancaria) unen las variables macroeconómicas con la salud y solvencia de las entidades e instituciones financieras.

Estos tests de stress, a través de la selección de variables que se emplean como factores de riesgo, analizan o miden la resistencia de una entidad financiera concreta, o de todo el sector en su conjunto, o una serie temporal.

El uso de los tests de stress macro para evaluar la solvencia bancaria ha ido incrementando en los últimos años. Este desarrollo viene motivado por la crisis

financiera, donde los resultados mostraron que no todas las entidades mantenían un cierto nivel de solvencia adecuado para hacer frente a dicha adversidad. ("A Macro Stress Testing Framework For Assessing Systemic Risks In The Banking Sector." European Central Bank)

El rol de llevar a cabo los tests de stress ha sido asumido por los Bancos Centrales. Sin embargo, estas herramientas tienen sus limitaciones. Una de las más importantes es que no se las variables macroeconómicas no se pueden considerar una medida de riesgo bancario en sí mismo, sino que más bien es una ayuda o un apoyo para predecir la solvencia bancaria.

Por otro lado, los métodos para realizar el análisis dentro de este trabajo fin de grado (TFG) son los aprendidos en la asignatura de "Predicción Económica" mayoritariamente, con el fin de identificar los modelos univariantes de cada serie temporal utilizada para el análisis. Ahora bien, como se ha explicado anteriormente, los tests de stress macro utilizan varias variables macroeconómicas para mejorar las predicciones de una medida del riesgo bancario, siendo necesario ampliar conocimientos propios para extender el análisis univariante al caso multivariante.

Los principales objetivos que se persiguen en la elaboración de este trabajo fin de grado son los siguientes:

Objetivo 1: Definir un marco teórico en el ámbito de los tests, definiendo así la naturaleza de los mismos y centrándose en una de las modalidades más importantes de estos tests de resistencia: la simulación de casos teóricos.

Objetivo 2: Establecer y delimitar la metodología utilizada para llevar a cabo dichos tests de stress**,** llevando a cabo en primer lugar la definición de los modelos univariantes que son necesarios, así como posteriormente la extensión a los modelos multivariantes para el análisis de series temporales.

Objetivo 3: Estudiar las propiedades estadísticas de cada una de las respectivas series temporales, identificando los modelos necesarios para llevar a cabo las pruebas de stress, además de extraer posibles similitudes entre las mismas.

Objetivo 4: Llevar a cabo un análisis multivariante para realizar las pruebas de resistencia bancaria, utilizando variables macroeconómicas para el apoyo de dichas pruebas.

Objetivo 5: Proporcionar pruebas empíricas apoyando el uso de las variables macroeconómicas para las pruebas de stress bancario, estableciendo relaciones entre el sector real y sector financiero.

Objetivo 6: Extraer conclusiones de las pruebas de stress bancario realizadas.

Una vez definidos los objetivos elementales, se procede a formular la estructura del trabajo. Como partida inicial se va definir un marco teórico para profundizar en los tests de resistencia bancaria. Posteriormente se va a definir toda la metodología

necesaria para llevar a cabo los análisis tanto univariantes como multivariantes. Una vez establecida toda la metodología, se realiza un análisis empírico, identificando los modelos, realizando predicciones y simulando escenarios teóricos para comprobar la solvencia bancaria. Finalmente se mencionan las conclusiones extraídas durante todo el proceso de elaboración de este trabajo.

3. MARCO TEÓRICO

3.1 DEFINICIÓN DE LOS TESTS DE STRESS

Los tests de Stress son una de las herramientas utilizadas por los bancos para entender sus exposiciones al riesgo.

Este tipo de test lo realizan las entidades reguladoras y supervisoras, como el Banco de España (en el caso español), y el comité de supervisiones bancarios europeos (CEBS). Además, cuentan con la colaboración del Banco Central Europeo y la Comisión Europea. En el caso de US, cuentan con un órgano supervisor denominado CCAR (Comprehensive Capital Analysis and Review) perteneciente a la Reserva Federal.

El objetivo primordial de los tests de stress bancarios es verificar que las entidades bancarias supervisadas van a ser capaces de mantener un adecuado nivel de capital ante una serie de circunstancias de stress. Como consecuencia de este objetivo esencial surge otro objetivo complementario, y es que, al publicar los resultados de los tests, se está emitiendo una señal al mercado y al conjunto de inversores de la situación de solvencia de las entidades bancarias supervisadas. Estos resultados sirven también a la función para identificar que entidades están mejor preparadas y cuales están peor para hacer frente a una situación de coyuntura futura desfavorable, y tomar medidas al respecto para su recapitalización.

El factor clave es que los bancos superen un mínimo nivel de solvencia, que se va a medir a partir del indicador financiero “Tier1”, computando las partidas contables de cada entidad bancaria en concepto de reservas, beneficios no distribuidos y participaciones, para hacer frente a los créditos concedidos y otras inversiones de riesgo. Los supervisores de los tests han establecido un valor mínimo (a mayor valor, mayor solvencia) al Tier1 del 6%.

3.2 SIMULACIÓN DE ESCENARIOS TEÓRICOS

Uno de los tipos de tests de stress más utilizados es aquel que realiza un análisis de los escenarios posibles. Este tipo de test implica la utilización de escenarios históricos tanto como hipotéticos, con el fin de predecir y medir el impacto de varios eventos en el propio desarrollo de la actividad de dichas entidades bancarias.

Aunque las pruebas de stress bancario a través del cálculo y creación de escenarios es un movimiento de carácter moderno (debido a que su implantación es relativamente cercana), no por ello deja de carecer de importancia. Si es cierto que el interés en estos tipos de tests de stress antes de la crisis financiera era casi nulo, solo por aquellas entidades que lo realizarán con carácter voluntario. Ahora bien, a raíz de la crisis financiera que surge en el año 2008, estos tests recogen una gran importancia, hasta el punto de que las entidades son obligadas, por un órgano externo, a recoger en informes los resultados de dichos tests. En concreto, a partir del año 2009, se estableció lo que hoy en día es el SCAP (Supervisory Capital Assessment Program) con el fin de evaluar las entidades bancarias y supervisar su estabilidad futura.

Una de las primeras premisas con las que se construyen los tests de stress bancarios es la importancia o relevancia de la selección las variables que van a soportar el test de stress. Como partida inicial se eligen variables pertenecientes a los balances contables de las entidades bancarias, estableciéndose una regresión lineal entre una variable dependiente (es la que va a ser sometida al test), y el resto de variables seleccionadas que van a actuar como variables independientes, y son las cuales van a servir de base para crear los escenarios teóricos.

Otro enfoque aplicable a estos tests de stress bancario es que el escenario macroeconómico, a través del conjunto de macro variables, son de utilidad en la predicción de la situación de los bancos. Al igual que en el enfoque inicial, existe una variable dependiente que se selecciona a partir del balance contable. Por lo tanto, la diferencia que existe entre estas dos visiones de los tests de stress es que en la segunda se va a utilizar variables macroeconómicas como variables independientes.

3.3 DATOS

Las medidas del desempeño del sector bancario para nuestro análisis se centran en el conjunto de bancos que engloban el sector bancario en España.

Se consideran medidas del desempeño cualquier variable financiera que afecte en los balances de situación de los bancos. Sin embargo, dependiendo del peso relativo de cada una de estas variables en los balances económico-financieros, serán más importantes o mejores unidades de medias unas variables que otras. Así, se ha considerado que la variable dependiente que se va a analizar y va a ser objeto de las pruebas de stress es una ratio financiera, compuesta por el cociente de los créditos de dudoso cobro entre los créditos totales. El uso de este cociente en vez del “Tier1” es debido a que no se dispone información pública de esta serie, siendo necesario acudir a información privada financiera. Por otro lado, esta ratio financiera puede tomar valores comprendidos entre 0 y 1, representando la inestabilidad de la entidad las entidades de crédito, por lo que es aconsejable que esta ratio tomara valores muy cercanos a 0 para representar una buena solvencia del sector bancario español.

Como variables macroeconómicas se han seleccionado las dos más relevantes que parecen las más relevantes para explicar dicha ratio y poder predecir en conjunto

posteriormente. La primera de ellas es el paro registrado en España y la segunda, el Índice de Producción Industrial (IPI).

Como es de esperar, lo lógico es esperar que exista una relación directa entre el paro registrado y la ratio financiera, así como una relación inversa entre el IPI y dicha ratio.

3.4 DESCRPCIÓN DEL MÉTODO

Una de las principales características del análisis univariante de series temporales es la de predecir un valor futuro de una variable a partir de su propia historia pasada. Estos modelos univariantes se pueden extender incorporando la información presente y pasada de otros factores, o en este contexto, variables macroeconómicas, dando lugar a modelos de regresión dinámica.

Ahora bien, es lógico pensar que existe una relación de simultaneidad o interdependencia entre las variables bancarias y las variables macroeconómicas: Las partidas de los estados financieros bancarios también ayudan a predecir la evolución futura de las variables macro, como lo muestra la evidencia empírica de diferentes estudios académicos o científicos, por ejemplo, “Balance Sheets of Financial Intermediaries: Do They Forecast Economic Activity”, Bank of Canada. Por lo tanto, parece necesario utilizar un análisis multivariante para facilitar y mejorar ambas predicciones. A pesar de ello, el análisis univariante utilizando la propia información de una serie temporal va a permitir identificar el modelo que sigue esa serie.

Como herramientas y métodos utilizados tanto para la identificación como para la predicción se van a utilizar los modelos ARIMA, así como sus extensiones para el análisis multivariante (VARIMA). Además, en la etapa de identificación los modelos ARIMA se reforzarán con modelos de función de transferencia para corregir anomalías.

Toda la elaboración de estos métodos y modelos se explican con mayor amplitud y precisión en los siguientes apartados pertenecientes a la metodología.

4. METODOLOGÍA

4.1 MODELOS ARIMA

Toda la metodología elaborada por Box y Jenkins (2008) está basada bajo la suposición de que las series siguen una estacionariedad débil o de segundo orden:

- Se poseen observaciones de la serie de Z_t para todo t=1, 2, …, n
- La serie sigue un nivel constante: $E(Z_t) = \mu < \infty$
- La serie es homocedástica, por lo que tiene varianza constante:

$$V(Z_t) = E(Z_t - \mu)^2 = \gamma_0$$

- Las distintas observaciones de la serie están correlacionadas, pero no dependen del instante t, sino de la distancia temporal entre las observaciones:

$$Cov(Z_t\ , Z_{t-k}) = E[(Z_t - \mu)(Z_{t-k} - \mu)] = \gamma_k$$

Los supuestos básicos generalmente no se cumplen para cualquier serie temporal. Es decir, no se puede afirmar que cualquier serie mantiene un nivel y una varianza constante. Para conseguir que la serie sea estacionaria en media, Box y Jenkins propusieron la diferenciación de datos. Esta propuesta se basa en que la tendencia de una serie es una función del nivel que va variando a lo largo del tiempo, de tal manera que si existe una tendencia de tipo lineal o cuadrática se obtendría lo siguiente:

$$\begin{array}{l} T_t = \mu_0 + \mu_1 t \\ \underline{-T_{t-1} = -[\mu_0 + \mu_1(t-1)]} \\ (1-B)T_t = \mu_1 \end{array} \qquad \begin{array}{l} T_t = \mu_0 + \mu_1 t + \mu_2 t^2 \\ \underline{-T_{t-1} = -[\mu_0 + \mu_1(t-1) + \mu_2(t-1)^2]} \\ (1-B)T_t = \mu_1 + \mu_2(2t-1) \end{array}$$

*El operador retardo B indica que: $Z_t B = Z_{t-1}$

Es preciso diferenciar tantas veces como sea necesario para que la serie siga un nivel constante. En el ejemplo anterior, se ha aplicado una diferencia regular, y se consigue modelizar tanto tendencias como rachas. Sin embargo, en vez de emplear una diferencia regular se puede utilizar una diferencia estacional, con el objetivo de modelizar la estacionalidad.

Por otro lado, requiere que la serie sea estacionaria en varianza. Para tratar este problema, Box y Cox propusieron una familia de transformaciones para conseguir homocedasticidad en la misma, bajo la proposición inicial de que la varianza de la serie es una función del nivel.

$$Var(Z_t) = cf(\mu_t)$$

El planteamiento inicial es que tiene que existir una transformación para que la varianza siga una constante:

$$\exists T,\ Var[T(Z_t)] = c$$

Esta transformación se aproxima por el método de Taylor:

$$T(Z_t) \cong T(\mu_t) + T'(\mu_t)[Z_t - \mu_t]$$

Si se aplica esperanza matemática, el segundo sumando se anula, quedando, como la esperanza de la transformación de la serie, la propia transformación en el nivel. Para calcular la varianza es necesario apoyarse en la siguiente expresión:

$$V[T(Z_t)] = E\left[T'(\mu_t)[Z_t - \mu_t]\right]^2$$

despejando la transformación del nivel:

$$T'\mu_t = \frac{1}{\sqrt{\partial(\mu_t)}} \rightarrow T(\mu_t) = \int \frac{1}{\sqrt{\partial(\mu_t)}} d\mu_t$$

Volviendo a la familia de transformaciones de Box y Cox, propusieron, a su vez, las siguientes transformaciones respecto al nivel:

$$T(\mu_t) = \frac{(Z_t^{\lambda} - 1)}{\lambda}$$

De todos los posibles valores para el parámetro lambda, en el ámbito práctico, solo es necesario quedarse los siguientes para realizar los análisis:

λ	Transformación
1	Serie original
0	Aplicar logaritmo

Partiendo de los supuestos, y una vez que se ha realizado las transformaciones correspondientes para lograr que la serie temporal sea estacionaria tanto en media como en varianza, se puede empezar el proceso de elaboración de modelos ARIMA. Como partida inicial se parte de la representación de Wold del proceso lineal general:

$$\tilde{Z}_t = a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \ldots = a_t + \sum_{j=1}^{\infty} \psi_j a_{t-j}$$

Para poder expresar el modelo de manera más compacta, se vuelve a utilizar el operador retardo “B”, de manera que:

$$Ba_t = a_{t-1} \qquad \text{y} \qquad B^2 a_t = a_{t-2}$$

Por lo que la representación inicial la podemos expresar de la siguiente manera:

$$\tilde{Z}_t = \psi(\mathrm{B}) a_t$$

De forma que ψ(B) es un polinomio de orden infinito con la siguiente forma:

$$\psi(\mathrm{B}) = (1 - B - B^2 - B^3 - \ldots)$$

El principal problema de esta representación es que la variable estacionaria depende de los infinitos retardos. Para expresar el modelo de forma parsimoniosa con pocos parámetros, este polinomio se aproxima por uno de orden finito:

$$\psi(\mathrm{B}) = \frac{\theta_q(B)}{\phi_p(B)} = \frac{(1 - \theta_1 B - \ldots - \theta_q B^q)}{(1 - \phi_1 B - \ldots - \phi_p B^p)}$$

Si se vuelve a reescribir el modelo inicial, se obtiene el modelo ARMA con la siguiente expresión:

$$\phi_p(B)\tilde{Z}_t = \theta_q(B)a_t$$

Una vez que ya está establecido como formulan estos modelos, Box y Jenkins establecieron un proceso iterativo de elaboración de modelos ARIMA. Este proceso se desarrolla en tres etapas:

1) Identificación. En esta primera etapa básicamente se intenta identificar tanto la transformación Box-Cox (λ), como el orden de los polinomios "p" y "q". Para ello se utilizan las herramientas de la ACF, PACF y el gráfico temporal. Por último, hay que intentar hallar el número de diferencias "d" que hay que aplicar para que la serie sea estacionaria en media.
2) Estimación. El método principal para estimar los parámetros del modelo es el de maximizar la función de verosimilitud conjunta. La función de densidad individual(verosimilitud) se define como la probabilidad de observar cada dato:

$$p(Z_t) = \frac{1}{\sqrt{2\pi\gamma_0}}\exp\left[-\frac{1}{2}\frac{(Z_t-\mu)^2}{\gamma_0}\right]$$

Ahora se procede a definir la función de densidad conjunta:

$$p(Z_1, \ldots, Z_n) = (2\pi)^{-n/2}|\Omega_z|^{-1/2}exp\left[-\frac{1}{2}(Z-\mu)'\Omega_z'(Z-\mu)\right]$$

Donde la matriz Ω_z es una matriz Toeplitz, es decir, los elementos pertenecientes a cada una de sus respectivas diagonales son idénticos.

$$\Omega_z = \begin{bmatrix} \gamma_0 & \cdots & \gamma_{n-1} \\ \vdots & \ddots & \vdots \\ \gamma_{n-1} & \cdots & \gamma_0 \end{bmatrix}$$

3) Diagnosis. En esta última etapa del proceso, se realiza una crítica constructiva al modelo para encontrar direcciones de mejora. Principalmente, se tiene que realizar varios contrastes de que el error es ruido blanco.
   i. La media de los residuos es nula:

$$H_0\colon E(a_t) = 0$$
$$H_1\colon E(a_t) \neq 0$$

Para realizar este contraste, se utiliza el estadístico t de Student:

$$Si\left|\frac{\bar{a}}{\hat{\sigma}_a/\sqrt{n}}\right| > 2\ Se\ rechaza\ H_0$$

   ii. Homocedasticidad. La varianza de los residuos tiene que ser constante. Para comprobar este requisito hay que observar el gráfico temporal de los residuos, comprobando que la serie sigue unas fluctuaciones respecto al nivel (medidas en desviaciones típicas) constantes.

iii. Ausencia de Autocorrelación. Las distintas observaciones de los residuos no tienen que estar correlacionadas. Las herramientas que se utiliza en estos casos son la ACF y PACF para comprobar que aproximadamente el 100%(1-α) de las barras están dentro de barras.

iv. Normalidad y periodicidades ocultas. Las herramientas que se van a utilizar en este apartado para comprobar que los residuos son ruido blanco son herramientas visuales. En primer lugar, se va a utilizar el histograma $(\hat{a}_t/\hat{\sigma}_a)$ para analizar si los residuos siguen una distribución normal centrada en la media. Por último, se emplearás la herramienta del periodograma para observar si hay algún ciclo oculto cuando este se salga de las bandas.

v. Sobreajuste. Inicialmente se mencionó que el proceso de elaboración de modelos ARIMA es un proceso iterativo. Esto significa mayormente que, si la diagnosis del modelo inicial no es satisfactoria, hay que reformular el modelo y volver a la etapa de identificación.

4.2 MODELOS DE FUNCIÓN DE TRANSFERENCIA

Los modelos de función de transferencia se elaboran bajo dos supuestos elementales. El primero de ellos es que se dispone de información de dos variables, una de ellas considerada output, y la otra input, para el mismo periodo muestral. Se va a representar la variable output como Y , y la variable input como X. La segunda de estas suposiciones es que existe una relación lineal entre ambas variables:

$$Y_t = \nu_0 X_t + \nu_1 X_{t-1} + \nu_2 X_{t-2} + \dots$$

La variable Y es una combinación lineal del valor presente de X y de todos sus retardos. Al igual que en el caso de elaboración de modelos ARIMA, vamos a utilizar el operador retardo “B” para poder expresar la variable input como un polinomio de orden infinito de la variable output:

$$Y_t = (\nu_0 + \nu_1 B + \nu_2 B^2 + \dots) X_t$$

$$Y_t = \nu(\mathrm{B}) X_t$$

donde :

- $\nu(\mathrm{B})$ es la función de transferencia.
- $\nu_0, \nu_1, \nu_2, \dots =$ Función de respuesta al impulso
- $V_j = \nu_0 + \nu_1 + \dots + \nu_j$ es la función de respuesta el escalón
- V_∞ representa a largo plazo un cambio de tipo escalón, conocido comúnmente como ganancia del sistema.

Este polinomio está formado por los infinitos retardos de la variable input, por lo que es conveniente aproximarlo por un cociente de polinomios que tenga orden finito:

$$\nu(\mathrm{B}) = \frac{\omega_s(B)}{\delta_r(B)} = \frac{(\omega_0 - \omega_1 B - \ldots - \omega_s B^s)}{(1 - \delta_1 B - \ldots - \delta_r B^r)}$$

El polinomio situado en el numerador nos va a medir el efecto contemporáneo que tiene X sobre la variable endógena a través del parámetro ω_0, y va a recoger también todo el efecto pasado que tiene esta variable hasta un orden X_{t-s} . El polinomio $\delta_r(B)$ que se encuentra el denominador va a incorporar toda la información pasada de la variable endógena (hasta un orden "r") para explicar el valor de Y en un instante t.

Con la metodología explicada hasta este punto, los modelos de función de transferencia se pueden descomponer en dos modelos dependiendo de los polinomios que se aproximan:

Modelos ADL (r,s) (Autorregresive Distributive Lags)

$$Y_t = \delta_1 Y_{t-1} + \ldots + \delta_r Y_{t-r} + \omega_0 X_t + \ldots + \omega_s X_{t-s} + \varepsilon_t$$

Modelos ARMAX:

$$\phi_p(B) Y_t = \omega_s(B) X_t + \theta_q(B) a_t$$

La principal utilidad práctica que van a tener estos modelos es poder introducir variables de intervención, ya sean de tipo impulso, rampa o escalón. Estas variables se van a representar con la letra "ξ", y con el superíndice:

- P, si la variable de intervención es un impulso
- R, si modelizamos una rampa
- S, si queremos introducir una variable del tipo escalón.

4.3 MODELOS VARIMA

La elaboración de los modelos VARMA es una extensión de los modelos ARMA para el análisis multivariante. El proceso de elaboración de estos modelos sigue la misma metodología que para el caso de los modelos iniciales utilizados para el análisis univariante, solo que ahora utilizaremos el enfoque matricial para el análisis.

Los supuestos básicos siguen siendo los mismos, las series temporales siguen estacionariedad débil o de segundo orden, teniendo un nivel constante y siendo homocedásticas, solo que simplemente tendremos una extensión meramente trivial a través de vectores y matrices. Los supuestos quedarían expresados de la siguiente forma:

- Poseemos las mismas observaciones para cada una de las series temporales. Estas series se recogerán en un vector columna de la siguiente forma:

$$Z_t = \begin{bmatrix} Z_{1t} \\ Z_{2t} \\ \vdots \\ Z_{kt} \end{bmatrix}$$

- Todas las series siguen un nivel correspondiente constante. El nivel corresponde con la esperanza matemática de la serie, así que representamos como μ el vector columna que contiene los niveles correspondientes a cada una de las series:

$$E(Z_{t)} = \mu = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_k \end{bmatrix}$$

- Las varianzas de cada una de las series son constantes, y además las observaciones para cualquier instante t de cada una de las series están correlacionadas, junto con observaciones con un retardo l. Todo esto se resume en la matriz de varianzas y covarianzas:

$$\Gamma(l) = E[(Z_t - \pi)(Z_{t+l} - \mu)'] = \begin{pmatrix} \gamma_{11}(l) & \gamma_{12}(l) & \cdots & \gamma_{1k}(l) \\ \gamma_{21}(l) & \gamma_{22}(l) & \cdots & \gamma_{2k}(l) \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{k1}(l) & \gamma_{k2}(l) & \cdots & \gamma_{kk}(l) \end{pmatrix}$$

  Si se observa bien, para el retardo $l = 0$, se obtendría una matriz donde su diagonal principal serían las varianzas de cada una de las series. También es interesante destacar que la matriz de varianzas y covarianzas $\Gamma(l)$ no depende del instante t, sino de la distancia medida por el retardo l.

Al tener más de dos variables, puede resultar de mucha utilidad estudiar el grado de asociación lineal que pueden tener dos series concretas. Este tipo de asociación se mide con el coeficiente de correlación lineal entre dos variables específicas y con un retardo l:

$$\varphi_{ij}(l) = corr\left[Z_{it}, Z_{j,t+l}\right] = \frac{\gamma_{ij}(l)}{\left[\gamma_{ii}(0)\gamma_{jj}(0)\right]^{1/2}}$$

Hay que tener en cuenta que los coeficientes de correlación lineal no son simétricos, sino que cumplen la siguiente propiedad:

$$\varphi_{ij}(l) \neq \varphi_{ji}(l) \rightarrow \varphi_{ij}(l) = \varphi_{ji}(-l)$$

Sin embargo, puede expresarse todos los coeficientes de correlación lineal en una misma matriz:

$$\varphi(l) = \mathrm{V}^{-1/2}\, \Gamma(l)\, \mathrm{V}^{-1/2}$$

$$\mathrm{V}^{-1/2} = diag\{\gamma_{11}(0)^{-1/2}, \ldots, \gamma_{kk}(0)^{-1/2}\}$$

Una vez descritas las características básicas del enfoque matricial, se puede empezar a describir todo el proceso de elaboración de los modelos VARMA. Al igual que en el caso del univariante, se parte de la representación de Wold del proceso lineal general:

$$Z_t = \mu + a_t + \Psi_1 a_{t-1} + \Psi_2 a_{t-2} + \ldots = \mu + \sum_{j=0}^{\infty} \Psi_j a_{t-j}$$

$$\Psi_j = \begin{pmatrix} \psi_{j,11} & \psi_{j,12} & \cdots & \psi_{j,1k} \\ \psi_{j,21} & \psi_{j,22} & \cdots & \psi_{j,2k} \\ \vdots & \vdots & \ddots & \vdots \\ \psi_{j,k1} & \psi_{j,k2} & \cdots & \psi_{j,kk} \end{pmatrix}$$

Esta representación la podemos expresar de forma más compacta utilizando el operador escalar “B”:

$$Z_t = \mu + \Psi(B) a_t$$

Esta expresión, al igual que en el caso univariante, tenía el inconveniente de ser un polinomio de orden infinito, por lo que en este contexto también se va a aproximar por un polinomio de orden finito. Además, la representación inicial de Wold va a tener una característica muy interesante y de mucha utilidad, ya que todos los elementos $\psi_{ij} \in \Psi_j$ nos medirán el efecto de los shocks a cada una de las variables.

Aproximando dicho polinomio de orden infinito:

$$\Psi(B) = \Phi(B)^{-1}\Theta(B) \begin{cases} \Phi(B) = I - \Phi_1 B - \Phi_2 B^2 - \ldots - \Phi_p B^p \\ \Theta(B) = I - \Theta_1 B - \Theta_2 B^2 - \ldots - \Theta_q B^q \end{cases}$$

Gracias a las aproximaciones anteriores, cualquier modelo VARMA se puede representar a partir de las dos siguientes expresiones:

$$\Phi(B)(Z_t - \mu) = \Theta(B) a_t$$

$$(Z_t - \mu) - \sum_{j=1}^{p} \Phi_j \left(Z_{t-j} - \mu\right) = a_t - \sum_{j=1}^{q} \Theta_j a_{t-j}$$

$$\Phi_j = \begin{pmatrix} \phi_{j,11} & \phi_{j,12} & \cdots & \phi_{j,1k} \\ \phi_{j,21} & \phi_{j,22} & \cdots & \phi_{j,2k} \\ \vdots & \vdots & \ddots & \vdots \\ \phi_{j,k1} & \phi_{j,k2} & \cdots & \phi_{j,kk} \end{pmatrix} \quad \Theta_j = \begin{pmatrix} \theta_{j,11} & \theta_{j,12} & \cdots & \theta_{j,1k} \\ \theta_{j,21} & \theta_{j,22} & \cdots & \theta_{j,2k} \\ \vdots & \vdots & \ddots & \vdots \\ \theta_{j,k1} & \theta_{j,k2} & \cdots & \theta_{j,kk} \end{pmatrix}$$

Para comprobar que el modelo es adecuado, tenemos que seguir comprobando que a_t es ruido blanco. En el enfoque matricial, el vector de ruido blanco cumple las siguientes propiedades estadísticas:

$$a_t = \begin{bmatrix} a_{1t} \\ a_{2t} \\ \vdots \\ a_{kt} \end{bmatrix} \; y \; E(a_t) = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

$$Cov(a_t a_{t+l}) = E[a_t a'_{t+l}] = \begin{cases} \Sigma \; si \; l = 0 \\ 0 \; \forall \; l \neq 0 \end{cases}$$

Siendo Σ:

$$\Sigma = \begin{pmatrix} \sigma_{a1}^2 & Cov(a_1, a_2) & \cdots & Cov(a_1, a_k) \\ Cov(a_2, a_1) & \sigma_{a2}^2 & \cdots & Cov(a_2, a_k) \\ \vdots & \vdots & \ddots & \vdots \\ Cov(a_k, a_1) & Cov(a_k, a_2) & \cdots & \sigma_{ak}^2 \end{pmatrix}$$

Volviendo a los supuestos básicos, hay que recordar que el nivel tiene que ser constante. Generalmente, esto no se suele cumplir, ya que las series temporales suelen presentar tendencias de cualquier tipo (lineales, cuadráticas, exponenciales…), por lo que va a ser necesario aplicar diferencias para poder modelizar dichas tendencias.

Estas diferencias se van a representar de la siguiente manera:

$$D(B) = diag\{(1-B)^{d1}, \dots, \; (1-B)^{dk}\} \; \forall \; d_1, \dots, d_j > 0$$

Si incluimos esta matriz en el modelo, obtenemos lo que se denomina un modelo VARIMA, obteniendo como expresión final:

$$\Phi(B) D(B) Z_t = \Theta(B) a_t$$

4.4 PREDICCIÓN CON MODELOS VARIMA

La elaboración de los modelos VARIMA tienen como objetivo principal la predicción conjunta de todas las series temporales introducidas en el vector Z_t, además de poder ver el reflejo del impacto que tiene cada una de ellas sobre el resto.

Para poder calcular dichas predicciones, se puede partir de dos representaciones equivalentes. La primera de ellas es a través de la ecuación en diferencias, y la segunda a partir de la representación de medias móviles de orden infinito.

4.4.1 CÁLCULO DE PREDICCIONES A PARTIR DE LA ECUACIÓN EN DIFERENCIA ARIMA

Para la predicción se parte del vector ARMA (p,q) una vez conseguida estacionariedad para todo el vector Z_t:

$$Z_t = \sum_{j=1}^{p} \Phi_j Z_{t-j} + \delta + a_t - \sum_{j=1}^{q} \Theta_j a_{t-j}$$

donde $\delta = (I - \Phi_1 - \ldots - \Phi_p)\mu$.

El valor futuro del vector Z_t a horizonte l viene dado por la siguiente expresión en diferencias:

$$\Phi(B) Z_{t+l} = \delta + \Theta(B) a_{t+l}$$

Como el objetivo es predecir el valor futuro de Z_{t+l} , se denomina $\hat{Z}_t(l)$ a la predicción para dicho valor futuro, y se calcula como $\hat{Z}_t(l) = E[Z_{t+l} | Z_t, Z_{t-1}, \ldots]$ con la condición de que si tomamos esperanza condicionada al error en el instante "t" con horizonte l se cumple: $E[a_{t+l} | Z_t, Z_{t-1}, \ldots] = 0$

Por lo tanto, el valor de la predicción se puede representar de la siguiente manera una vez aplicadas la esperanza condicionada:

$$\hat{Z}_t(l) = \sum_{j=1}^{p} \Phi_j \hat{Z}_t(l-j) + \delta - \sum_{j=l}^{q} \Theta_j a_{t+l-j} \quad \forall\, l = 1,2, \ldots, q$$

$$\hat{Z}_t(l) = \sum_{j=1}^{p} \Phi_j \hat{Z}_t(l-j) + \delta \quad \forall\, l > q$$

4.4.2 CÁLCULO DE PREDICCIONES A PARTIR DE LA FORMA INFINITA DE MEDIAS MÓVILES

Cuando nos encontramos ante una serie estacionaria, el modelo ARMA se puede reescribir como una combinación lineal de orden infinito de medias móviles:

$$Z_t = \Psi(B) a_t = \left[\sum_{j=0}^{\infty} \Psi_j B^j \right] a_t$$

Los valores futuros Z_{t+l} se pueden expresarse como:

$$Z_{t+l} = \sum_{j=0}^{\infty} \Psi_j a_{t+l-j} = a_{t+l} + \Psi_1 a_{t+l-1} + \ldots + \Psi_{l-1} a_{t+1} + \Psi_l a_t + \ldots$$

La expresión de la predicción del valor futuro de Z_{t+l} se calcula de la misma manera que en el caso anterior, aplicando esperanza condicionada:

$$\hat{Z}_t(l) = E[Z_{t+l}|Z_t, Z_{t-1}, \dots] = \sum_{j=l}^{\infty} \Psi_j a_{t+l-j}$$

5. ANÁLISIS UNIVARIANTE

Este apartado se centra en el estudio individualizado de cada una de las variables elegidas para realizar los tests de stress bancario. El objetivo principal de estos análisis consiste en familiarizarse con las propiedades estadísticas de cada una de las series temporales correspondientes a cada variable, además de identificar modelos que servirán de utilidad en el análisis multivariante.

Como se ha explicado en apartados anteriores, para realizar el análisis univariante se van a utilizar los modelos ARIMA para la predicción de dichas variables. Además, en el siguiente apartado se intentará mejorar dichas propiedades estadísticas con modelos multivariantes, por lo que la eficacia del resultado de cada una de las estimaciones realizadas con la propia información de la serie serán un objetivo a batir por los modelos multivariantes.

Dichos modelos ARIMA son elaborados bajo la metodología de Box y Jenkins, bajo el supuesto de que las series temporales tienen que presentar estacionariedad débil o de segundo orden para poder predecir. Para ello se tienen que realizar operaciones y transformaciones a cada una de las series.

5.1 RATIO FINANCIERA

En primer lugar, se va a analizar la variable financiera elegida como medida del riesgo bancario. Esta variable es una ratio formada por el cociente entre los créditos de dudoso cobro y los créditos totales, ambas variables extraídas de las cuentas del balance de situación del Banco de España. La expresión de la ratio es la siguiente:

$$Z_{1t} = \frac{CD_t}{CT_t}$$

Para empezar el propio análisis, hay que empezar observando el gráfico temporal de la serie. Como se observa en el apéndice de gráficos (Gráfico 1.1), la muestra obtenida va desde enero del año 1975 hasta enero de 2016, apreciándose una tendencia lineal creciente desde el inicio de la serie hasta el año 1985, donde empiezan a diferenciarse rachas, tanto con crecimiento exponencial como tendencias lineales crecientes y decrecientes. Además, la varianza no parece ser constante a lo largo de la

serie, por lo que para arreglar este problema y que la serie temporal sea estacionaria en varianza, se aplica logaritmo a la serie. Esta nueva serie transformada no está centrada en la media (Gráfico 1.2), con lo que es recomendable aplicar una diferencia regular. Además, con las herramientas de identificación, la decisión de aplicar dicha diferencia regular viene corroborada por un lento decrecimiento en la ACF con el primer coeficiente muy próximo a 1. Sin embargo, esta única diferencia no es suficiente, siendo necesario aplicar una diferencia regular extra y una diferencia estacional para modelizar la estacionalidad y centrar la serie sobre la media. Volviendo a retomar las herramientas de identificación, se observa un patrón de medias móviles tanto en la parte regular como estacional, por lo que el modelo tentativo es el siguiente:

$$\nabla^2 \nabla_{12} log Z_{1t} = (1 - \theta_1 B)(1 - \Theta_2 B^{12}) a_t$$

Estimando el modelo anterior y observando sus residuos (Gráfico 1.3), se observa un patrón trimestral tanto en la ACF como en la PACF. Junto con esto, se extraen los outliers o anomalías para introducir variables de intervención. En concreto, se ha introducido 3 variables tipo escalón en las siguientes fechas: enero de 1986, abril de 2008 y julio de 2008. Con todo esto, se modeliza el nuevo modelo, añadiendo una parte autorregresiva (AR(2) trimestral) a la variable corregida por las variables de intervención:

$$log Z_{1t} = \omega_0 \xi_t^{S\,1980.12} + \omega_1 \xi_t^{S\,1986,1} + \omega_2 \xi_t^{S\,2008,7} + \omega_3 \xi_t^{S\,2012.12} + M_t$$

$$(1 - \Phi_1 B^3 - \Phi_2 B^6) \nabla^2 \nabla_{12} log M_t = (1 - \theta_1 B)(1 - \Theta_2 B^{12}) a_t$$

Se obtienen los parámetros del modelo a través de la estimación de máxima verosimilitud, y además realizando una diagnosis de los residuos de este modelo (Gráfico 1.5). En las herramientas de diagnosis de los residuos nos encontramos con lo siguiente:

1) Los residuos siguen una distribución normal
2) Dichos residuos están centrados en el valor 0 dentro de la distribución, por lo que tienen media nula
3) El gráfico temporal refleja homocedasticidad
4) Las gráficas ACF y PACF muestran ausencia de autocorrelación, ya que aproximadamente el 95% de las barras caen dentro de barras.

Finalmente, con todo el análisis realizado, se puede afirmar que a_t es significativamente ruido blanco, y se puede reescribir el modelo ya sustituyendo los parámetros por sus respectivas estimaciones:

$$log Z_{1t} = 0.10 \xi_t^{S\,1980.12} + 0.18 \xi_t^{S\,1986,1} + 0.15 \xi_t^{S\,2008,7} - 0.12 \xi_t^{S\,2012.12} + M_t$$

$$(1 - 0{,}17 B^3 - 0{,}18 B^6) \nabla^2 \nabla_{12} log M_t = (1 - 0{,}74 B)(1 - 0{,}84 B^{12}) a_t$$

Por otro lado, las variables elegidas como indicadores económicos o de actividad real han sido las siguientes dos:

-Paro Registrado

-Índice de Producción Industrial

5.2 PARO REGISTRADO

La serie original (Gráfico 2.1) presenta un patrón muy similar a la serie temporal de la ratio financiera, pero esta variable económica presenta una estacionalidad más fuerte. Cabe destacar que el periodo muestral de esta serie es más acotado que la ratio financiera, empezando en enero de 1996 y terminando en diciembre de 2015.

La transformación logarítmica en esta serie tiene doble finalidad. La primera de ellas es, al igual que en el caso anterior, conseguir que la serie sea estacionaria en varianza, y la segunda de ellas es poder trabajar con incrementos porcentuales sobre el paro registrado. Una vez realizada la transformación (Gráfico 2.2), se aplica inicialmente una diferencia regular corroborada por el lento decrecimiento en la ACF, junto con el parámetro próximo a 1. Aun así, se vuelve a presentar la misma situación de antes: es necesario aplicar una diferencia estacional para modelizar la estacionalidad mencionada anteriormente, y otra diferencia regular para conseguir que la serie sea estacionaria en media.

Como ya se ha mencionado anteriormente, las dos series presentan patrones similares, por consiguiente, es lógico deducir que el primer modelo tentativo sea el mismo para ambas series, y esto es precisamente lo que demuestra las herramientas de identificación (Gráfico 2.3):

$$\nabla^2 \nabla_{12} log Z_{2t} = (1 - \theta_1 B)(1 - \Theta_2 B^{12}) a_t$$

Siguiendo la metodología, se estima el modelo y se obtienen los residuos (Gráfico 2.4). Lo más impactante de estos residuos es que no presentan el patrón trimestral que seguía la serie financiera. De hecho, los residuos presentan ausencia de autocorrelación entre las distintas observaciones, por lo que solo procede incluir variables de intervención para el tratamiento de anomalías. Estas anomalías se manifiestan en febrero de 2002 (impulso) y junio de 2009 (escalón), quedando como resultado el modelo:

$$\log Z_{2t} = \omega_0 \xi_t^{P\ 2002,2} + \omega_1 \xi_t^{S\ 2009,6} + PR_t$$

$$\nabla^2 \nabla_{12} log PR_t = (1 - \theta_1 B)(1 - \Theta_2 B^{12}) a_t$$

Siguiendo el proceso iterativo, se reestima el modelo y se vuelven a extraer los residuos (Gráfico 2.5). Estos residuos presentan las mismas características mencionadas en la serie anterior, por lo que son significativamente ruido blanco, quedando el modelo definitivo:

$$\log Z_{2t} = 0{,}03 \xi_t^{P\ 2002,2} - 0{,}016 \xi_t^{S\ 2009,6} + PR_t$$

$$\nabla^2 \nabla_{12} log PR_t = (1 - 0{,}65B)(1 - 0{,}52B^{12}) a_t$$

5.3 ÍNDICE DE PRODUCCIÓN INDUSTRIAL (IPI)

Antes de realizar el análisis univariante, comentar brevemente que se dispone datos de la serie desde enero de 1975 hasta enero de 2016. Se debe observar que la serie original (Gráfico 3.1) presenta una estacionalidad muy fuerte. Para analizar la serie, se ha realizado una transformación del siguiente orden:

$$I_t = (1 + B + B^2 + \ \ldots \ + B^{11})Z_{3t}$$

*Siendo I_t una combinación lineal de los retardos de la serie original.

Junto con la transformación anterior, también se aplica logaritmo a la serie para poder trabajar con incrementos porcentuales. Observando la serie transformada (Gráfico 3.2), es necesario aplicar dos diferencias regulares para conseguir estacionariedad en media (Gráfico 3.3), pudiendo estimar ya el primer modelo tentativo:

$$(1 - \phi_1 B - \phi_2 B^2)\nabla^2 log I_t = (1 - \theta_1 B)(1 - \Theta_2 B^{12})a_t$$

Este modelo tentativo no es el definitivo, debido a que los residuos extraídos de este modelo no cumplen las propiedades para considerar que error es ruido blanco (Gráfico 3.4). Se puede observar que en la ACF y PACF que los errores tienen correlación. Para modelizar esta correlación, se incorpora variables de intervención en las fechas de semana santa, junto con una parte autorregresiva de orden 2 en la parte estacional. Esta nueva variable corregida de los efectos de la semana santa se va a denominar I_t^*.

Una vez más, se estima el modelo y analizamos los residuos (Gráfico 3.5). Se cumplen las 4 propiedades para afirmar que a_t es significativamente ruido blanco, por lo que ya se obtiene el modelo estimado para esta serie temporal.

$$(1 - \phi_1 B - \phi_2 B^2)(1 - \Phi_3 B^{12} - \Phi_4 B^{24})\nabla^2 log I_t^* = (1 - \theta_1 B)(1 - \Theta_2 B^{12})a_t$$

$$(1 + 0{,}36B + 0{,}07B^2)(1 + 0.19B^{12} + 0.26B^{24})\nabla^2 log I_t^* = (1 - 0.35B)(1 - 0{,}37B^{12})a_t$$

5.4 DEDUCCIÓN

Una vez realizado estos tres primeros análisis, es interesante ver el gráfico temporal conjunto de las variables (una vez aplicada cada una de las transformaciones respectivas a cada una de ellas).

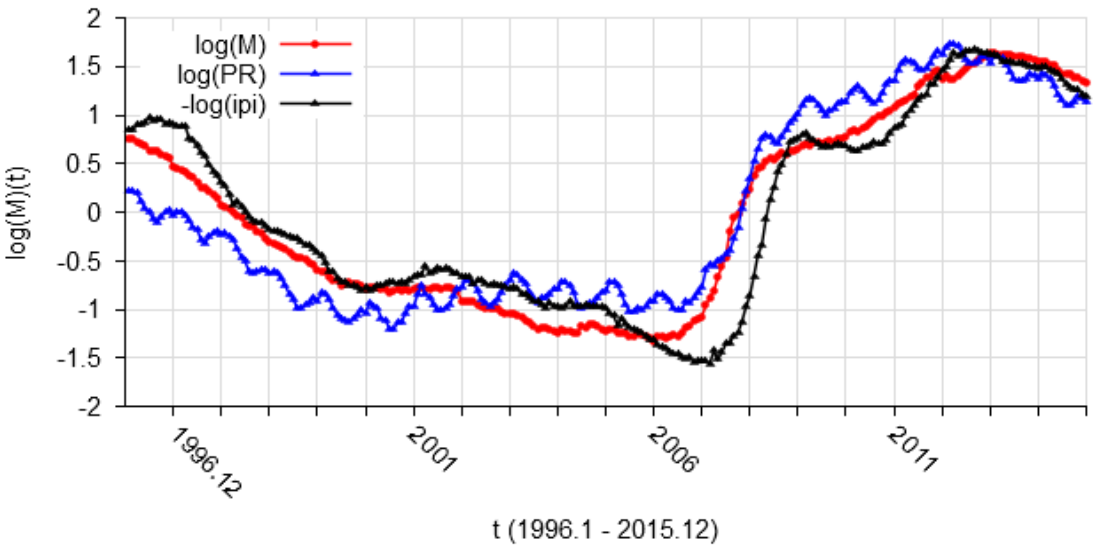

Como se puede observar en el gráfico anterior, las variables evolucionan a lo largo del tiempo con un patrón muy similar (en el caso del IPI, sigue una evolución inversa respecto a la ratio financiera y al paro registrado). Ahora bien, multitud de estudios y pruebas de stress bancario han aportado evidencias empíricas de que existe una relación de causalidad entre las variables de actividad o macroeconómicas y las variables financieras, estableciendo modelos econométricos dinámicos que ayuden a la predicción de una de las variables, ya sea de actividad real o financiera (variable endógena) a través de una regresión de la variable complementaria (variable exógena). Sin embargo, puede ser difícil a veces distinguir si es el sector financiero el que se adelanta al ciclo económico, o es al revés. Es por ello que se procede al análisis multivariante en el siguiente apartado.

6. ANÁLISIS MULTIVARIANTE

6.1 IDENTIFICACIÓN

La motivación principal de este epígrafe va a ser el estudio conjunto de las 3 variables seleccionadas para identificar un modelo que sea útil para predecir y para el cálculo de análisis de escenarios teóricos. Como resumen del análisis univariante, cabe destacar el gráfico reflejado al final del epígrafe, ya que muestra que existe un comportamiento muy similar entre las variables. Además, es de interés ver el gráfico conjunto de las variables transformadas junto con las diferencias necesarias que se han aplicado a cada una de ellas, para su posterior estimación.

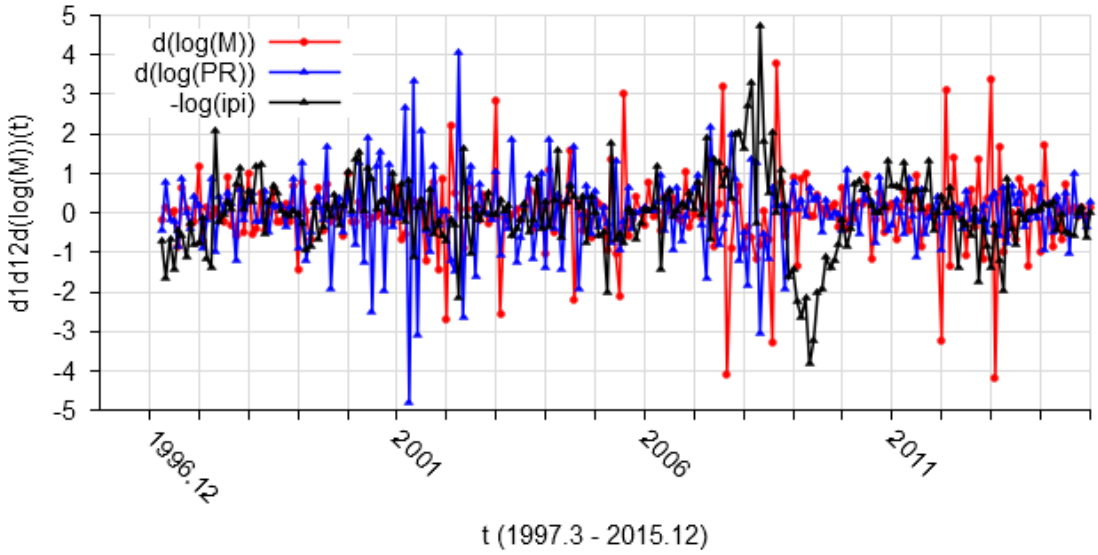

En todos los modelos univariantes definitivos estimados anteriormente, todos tienen una parte de media móviles tanto regular como estacional (aplicando logaritmo), así que como punto de partida se va a estimar un modelo VIMA $_{(0,1,1)\ (0,1,1)}$. Sin embargo, antes de estimar el modelo anterior, se van a corregir las variables de sus respectivas anomalías a través de las funciones de transferencia. La expresión general de los modelos de función de transferencia es la siguiente:

$$logZ_t = X_t'\beta + N_t$$

Como el objetivo es corregir la serie original y no la serie logarítmica, se eleva la expresión al número "e", quedando las series corregidas como:

$$N_t = \exp(\log(Z_t) - X_t'\beta)$$

Por lo tanto, el modelo tentativo inicial es el siguiente:

$$D(B)N_t = \Theta(B)a_t$$

Reexpresado de forma más extendida:

$$(I - B)(I - B^{12})logN_t = (I - \Theta_1 B - \Theta_2 B^{12})a_t$$

Estimando el modelo tentativo, los parámetros pertencientes a la matriz Θ_2, que no son elementos de la diagonal principal, no son significativos. Por lo tanto, se vuelve a estimar el modelo anterior pero con la condición de que:

$$\Theta_2 = \begin{pmatrix} \theta_{2,11} & 0 & 0 \\ 0 & \theta_{2,22} & 0 \\ 0 & 0 & \theta_{2,33} \end{pmatrix}$$

Se extraen los residuos del modelo tentativo corregido (Gráfico 4.1), con una diagnosis que no es satisfactoria. El aspecto más importante es que es necesario corregir es la interdepedencia entre las distintas observaciones de los residuos, ya que las anomalías se corrigieron anteriormente. La principal causa de esta correlación entre los residuos es que solo se ha modelizado una diferencia regular y una estacional, pero en el caso univariante se han añadido una diferencia regular extra para las series de la ratio financiera y el paro registrado.

Sin embargo, se presenta un problema al incluir una diferencia regular más, y es que se estaría sobrediferenciando el Índice de Producción Industrial (IPI). Para evitar dicha contingencia, se va a elaborar una matriz especial:

$$I_2 = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{pmatrix}$$

Con la elaboración de esta nueva matriz, se puede ajustar el modelo de manera que no se sobrediferencie el IPI, siendo el modelo resultante un VIMA $_{(0,2,1)\ (0,1,1)}$:

$$(I - B)(I - I_2 B)(I - B^{12}) log N_t = (I - \Theta_1 B - \Theta_2 B^{12}) a_t$$

Realizando la diagnosis de nuevo de este modelo (Gráfico 4.2), las gráficas ACF y PACF para la serie de la ratio financiera muestran que todavía existe una relación trimestral entre los residuos. Para modelizar esta correlacion, hay que ampliar el modelo VIMA planeteado con una parte autorregresiva de orden 1 trimestral.

El nuevo modelo VARIMA viene dado por la siguiente expresión:

$$(I - \Phi_1 B^3)(I - B)(I - I_2 B)(I - B^{12}) log N_t = (I - \Theta_1 B - \Theta_2 B^{12}) a_t$$

Al igual que en caso anterior, al estimar la matriz Φ_1, los elementos que no pertenecen a la diagonal principal son no significativos, por lo que se establece una doble condición para reestimar el modelo, y es que tanto la matriz autorregresiva como la de medias móviles estacional están compuesta por elementos no nulos únicamente en su diagonal principal:

$$\Phi_1 = \begin{pmatrix} \phi_{1,11} & 0 & 0 \\ 0 & \phi_{1,22} & 0 \\ 0 & 0 & \phi_{1,33} \end{pmatrix} \quad \Theta_2 = \begin{pmatrix} \theta_{2,11} & 0 & 0 \\ 0 & \theta_{2,22} & 0 \\ 0 & 0 & \theta_{2,33} \end{pmatrix}$$

Una vez establecidas las condiciones, se estima el modelo VARIMA definitvo, debido a que la extracción de sus respectivos residuos (Gráfico 4.3) revelan que el vector columna a_t es significativamente un proceso de ruido blanco, cumpliéndose todas las propiedades del mismo.

Como se ha identificado y estimado finalmente el modelo que se va a utilizar para futuras predicciones, se reescribe sustituyendo los parámetros por sus respectivas estimaciones:

$$\Phi_1 = \begin{pmatrix} 0.32 & 0 & 0 \\ 0 & 0.26 & 0 \\ 0 & 0 & 0.30 \end{pmatrix} \Theta_1 = \begin{pmatrix} 0.77 & -0.10 & -0.02 \\ -0.07 & 0.97 & 0 \\ 0.07 & 0.82 & 0.74 \end{pmatrix} \Theta_2 = \begin{pmatrix} 0.71 & 0 & 0 \\ 0 & 0.43 & 0 \\ 0 & 0 & 0.60 \end{pmatrix}$$

6.2 PREDICCIÓN

En la etapa anterior se identificó el modelo VARIMA que es necesario para calcular las predicciones. En la parte metódica, se menciona y se detalla los dos principales enfoques para poder predecir, además del cálculo del error de predicción.

Junto con el valor futuro estimado por el modelo identificado aplicando el operador esperanza matemática, se puede establecer la predicción junto con las bandas de un intervalo del 100*(1-α)% de confianza través del RMSE (Root Mean Square Error).

Este proceso inicia con el cálculo del error de predicción. En la metodología se demuestra la distribución que sigue dicho error. A la desviación típica del error de predicción se le denomina Root Mean Square Error, y es el necesario para poder tipificar la variable:

$$\frac{e_n(l)}{\sqrt{V[e_n(l)]}} = \frac{e_n(l)}{RMSE} \sim N(0,1)$$

Escogiendo un nivel de significación α se puede crear un intervalo de confianza para las predicciones, que se va a reflejar como las bandas para los posibles valores de la predicción:

$$Prob\left(\left|\frac{Z_{n+l} - \hat{Z}_n(l)}{\sqrt{V[e_n(l)]}}\right| \leq Z_{\frac{\alpha}{2}}\right) = 1 - \alpha$$

donde el intervalo de confianza se puede reexpresar como:

$$IC = \hat{Z}_n(l) \pm Z_{\frac{\alpha}{2}}\sqrt{V[e_n(h)]}$$

Como en la identificación del modelo se aplicó la transformación logarítmica el intervalo de confianza viene dado por:

$$IC = log\hat{Z}_n(l) \pm Z_{\frac{\alpha}{2}}\sqrt{V[e_n(h)]}$$

Sin embargo, no siempre lo que se busca no es la predicción logarítmica, sino que también puede ser de interés la predicción para el valor original con su respectivo intervalo de confianza, por lo que para ello se toma exponencial:

$$IC = \exp\left(log\hat{Z}_n(l) \pm Z_{\frac{\alpha}{2}}\sqrt{V[e_n(h)]}\right)$$

Una vez que está especificado todo el cálculo de las predicciones, se procede a la realización y representación de las mismas a un horizonte "*l*" igual a 1 año, donde la banda superior se representa de color azul, y la banda inferior del intervalo de confianza se representa con el color rojo.

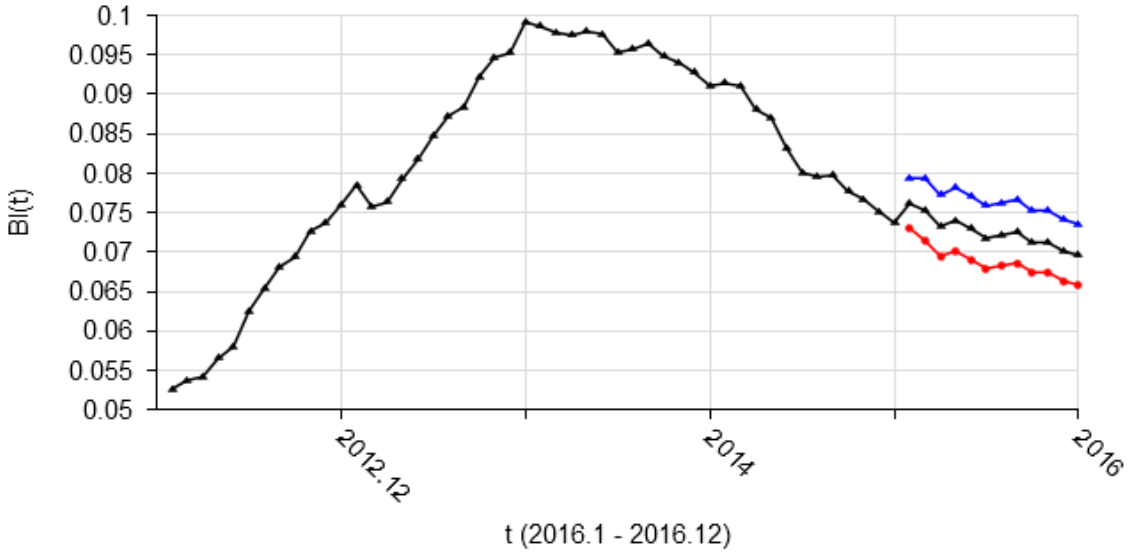

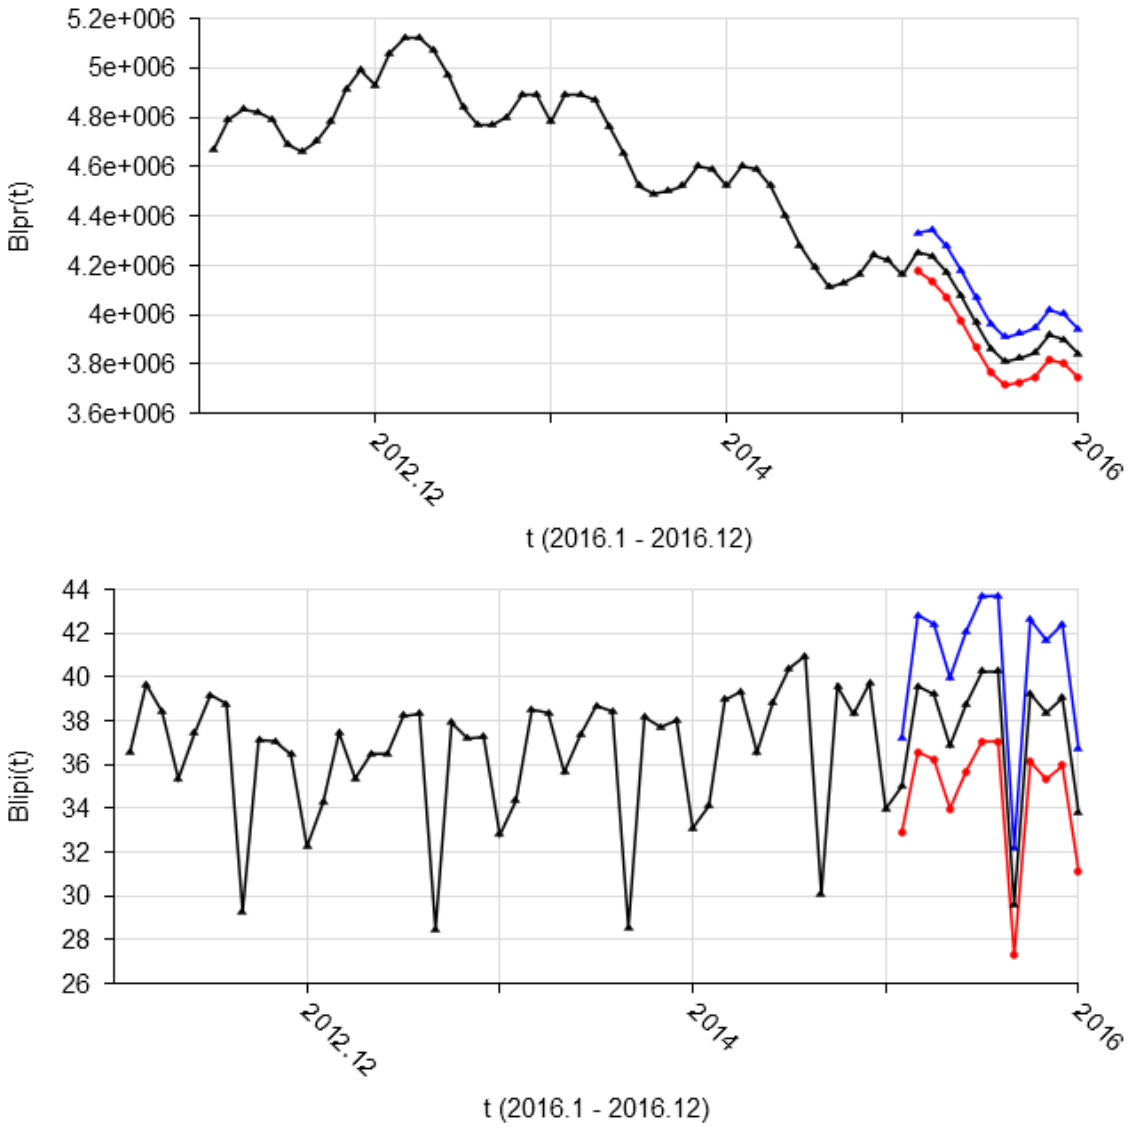

6.3 CÁLCULO DE ESCENARIOS

La simulación de escenarios es una modalidad de los tests de stress bancarios que coge una gran relevancia en estos últimos años a raíz de la crisis financiera de 2008. Esta simulación se basa en la predicción de una variable endógena a través de valores simulados o ficticios de las variables exógenas o independientes.

En este análisis se van a crear 2 escenarios, uno simulando un caso hipótetico favorable, es decir, las variables macroeconómicas seleccionadas como representantes de la actividad real siguen una evolución favorable para disminuir el riesgo bancario, mientras que el otro caso simulado es justo lo contrario. Las variables exogénas van a ser simuladas para que exista una situación desfavorable, y así aumente la ratio financiera, aumentando al mismo tiempo el riesgo bancario de insolvencia.

Así, se han manipulado los datos a partir de enero del año 2013 para el cálculo de los escenarios. En color azul se representa el caso favorable, mientras que en rojo el desfavorable.

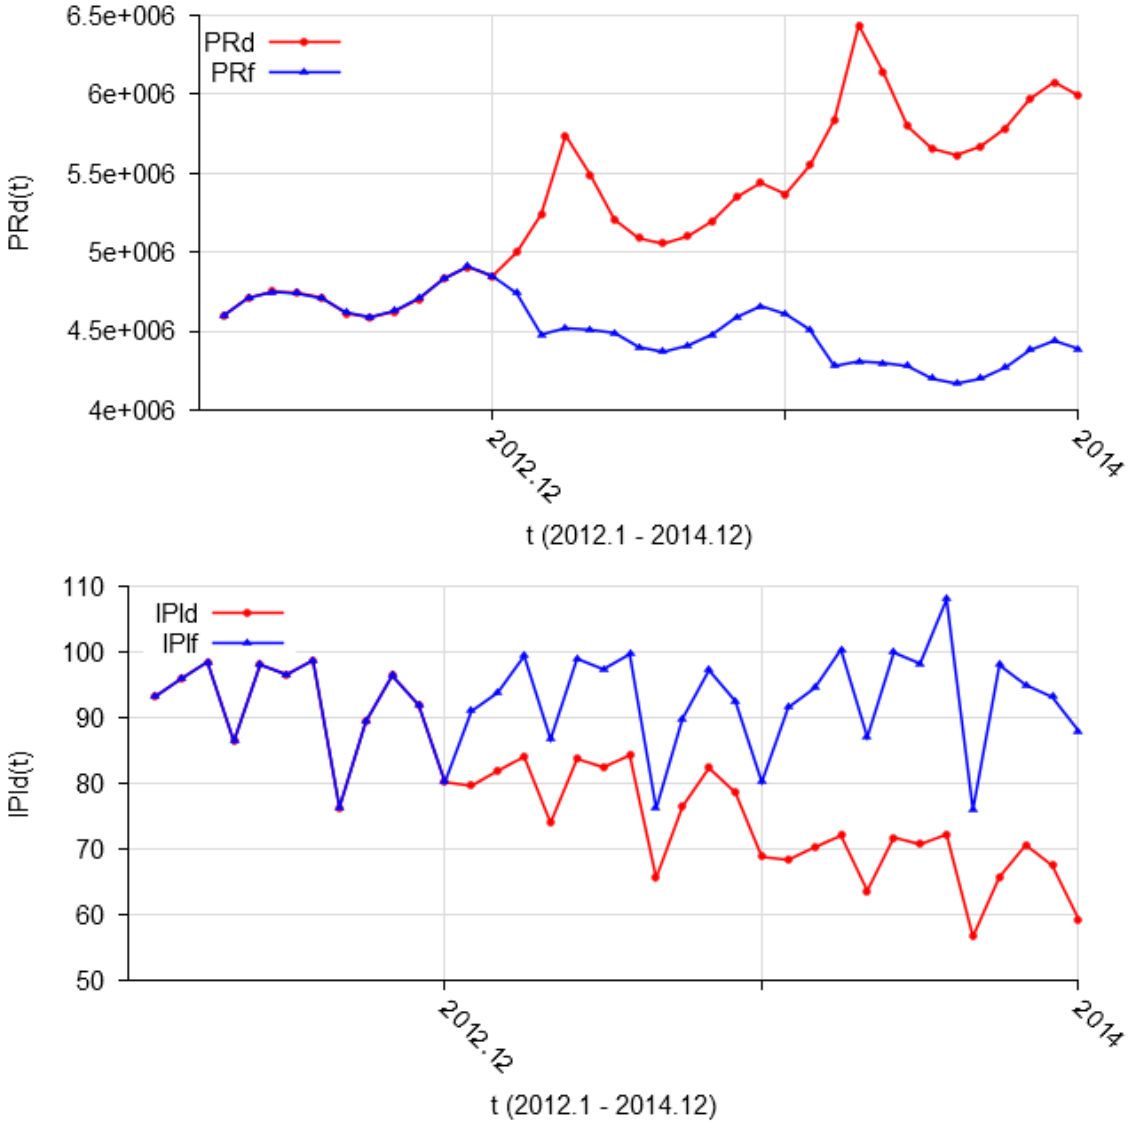

Una vez modelizados los escenarios teóricos, es posible predecir el valor de la ratio para el año 2015 y poder comprobar los valores de dichas predicciones con el valor real que ha tomado la variable a lo largo del año.

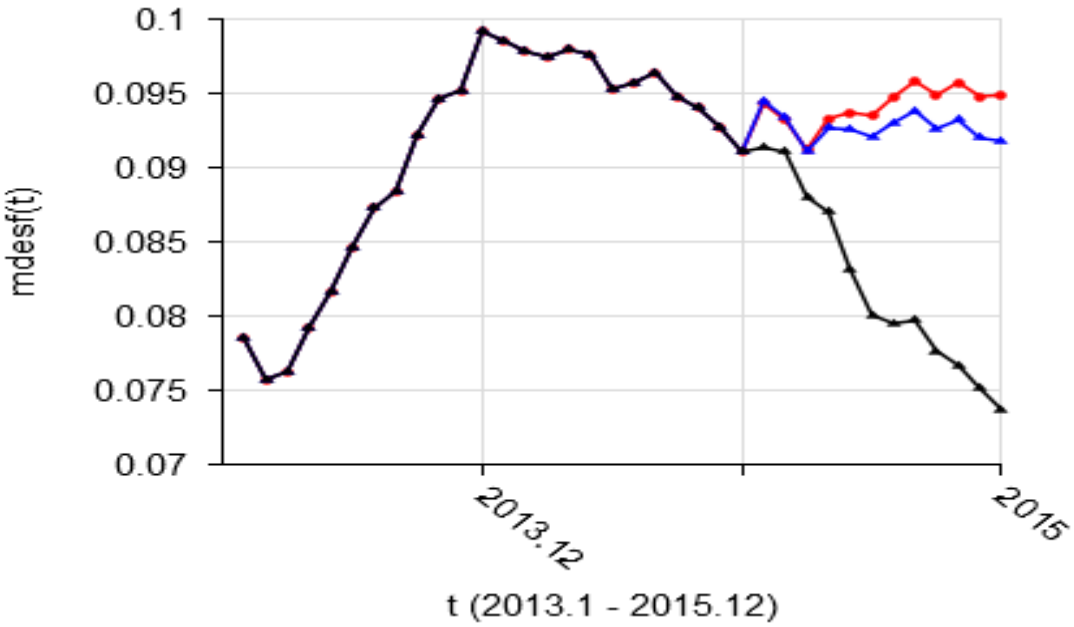

El gráfico anterior, a diferencia de las representaciones de los escenarios modificando los valores de las variables macroeconómicas, se muestran las predicciones a horizonte igual a 1 año. Así, se pueden comparar las predicciones en los casos favorables (color azul) y las predicciones en los casos desfavorables (color rojo), con los valores reales que ha tomado la ratio financiera en el año 2015.

7. CONCLUSIONES

Este documento describe como un test de stress macro puede afectar a las variables financieras elegidas como medidor del riesgo bancario, utilizando el análisis de series temporales.

Como partida inicial, se ha realizado una parte de identificación de todas las series temporales empleadas, tanto financieras como macroeconómicas. Esta identificación puede ser utilizada para realizar análisis futuros, tanto para tests de stress como análisis complementarios.

Posteriormente, se ha vuelto identificar el modelo para el caso multivariante. La identificación del modelo VARIMA para poder predecir y hacer un análisis de simulación revela que los shocks estacionales de las variables macroeconómicas no influyen en el sector financiero, y viceversa. Junto con esto, la parte autorregresiva trimestral de cada una de las variables no afecta respectivamente a las demás.

Después de la identificación del modelo multivariante, se propone una simulación modificando las variables macroeconómicas, creando dos simulaciones reflejando un escenario económico favorable y otro desfavorable. Esta simulación revela un dato muy interesante, y es que, al realizar la predicción simulada de la ratio financiera, comparándola con la evolución real de la misma, se observa que la evolución real presenta un decremento mayor al simulado en el caso desfavorable. La principal idea que se extrae de este análisis es que la solvencia del sector bancario ha superado

satisfactoriamente la prueba de stress, presentando una evolución muy positiva para los próximos años.

Por último, mencionar que por las limitaciones en cuanto a la extensión de este trabajo se ha reducido a un análisis a nivel nacional del sector financiero español, utilizando únicamente dos variables macroeconómicas pertenecientes al mismo nivel. Como directrices de mejora, este análisis se puede ampliar utilizando más variables macro para la simulación. Junto con esto, se puede ampliar el rango del análisis, pudiendo estudiar la solvencia de entidades financieras de manera individual, así como el caso contrario, realizando un análisis global del sector financiero europeo.

8. APÉNDICE DE GRÁFICOS

Gráfico 1.1

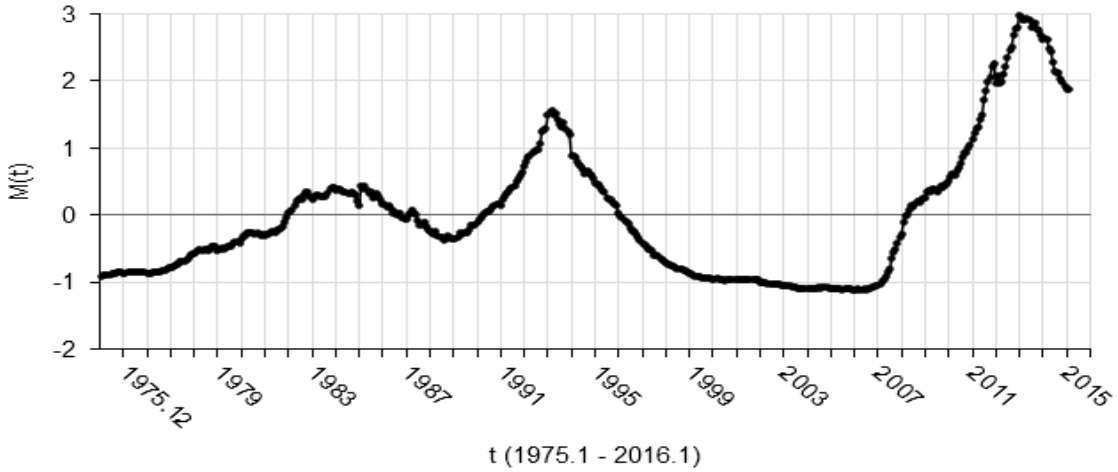

Gráfico 1.2

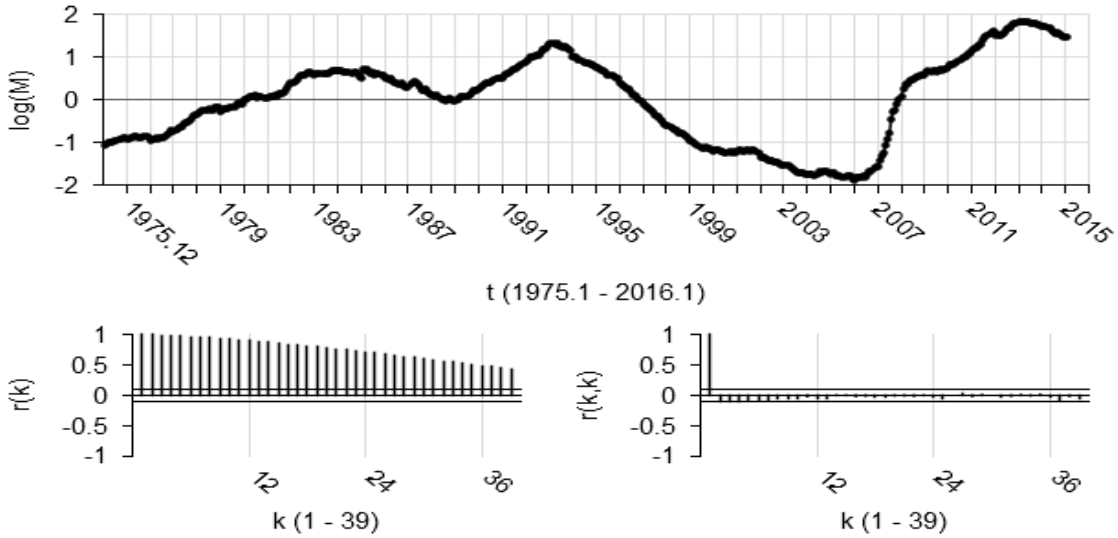

Gráfico 1.3

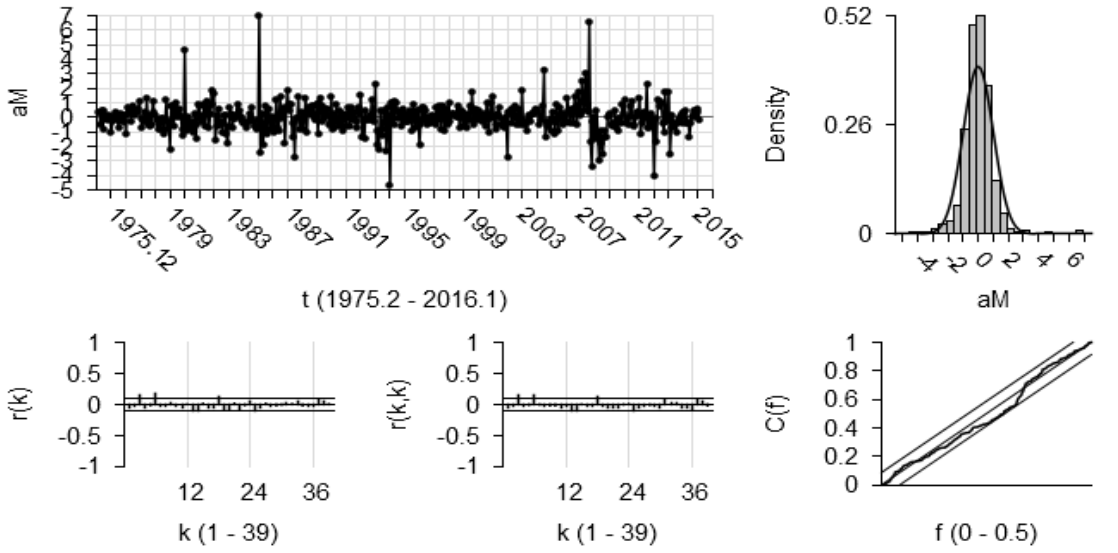

Gráfico 1.4

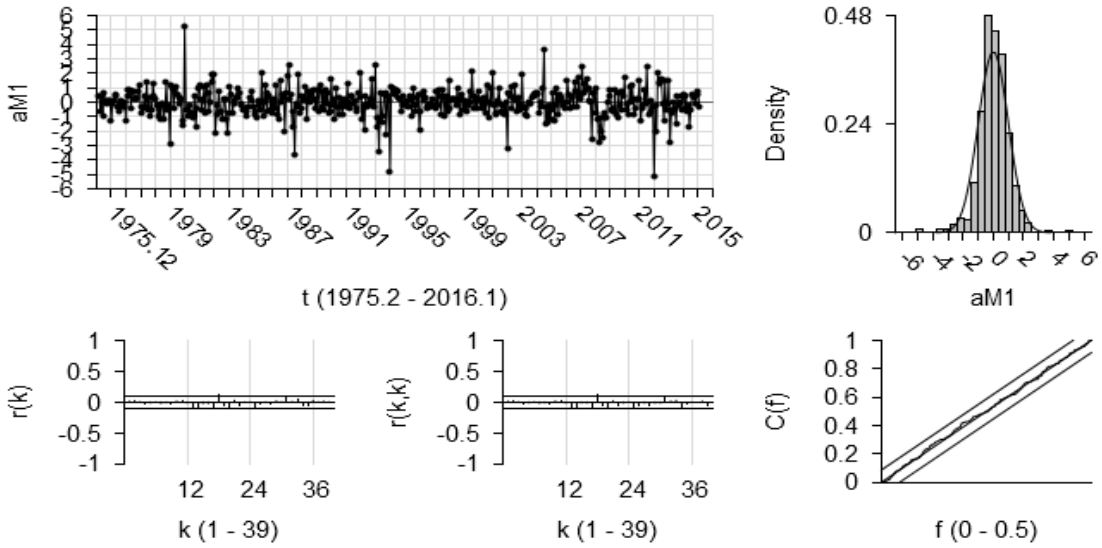

Gráfico 2.1

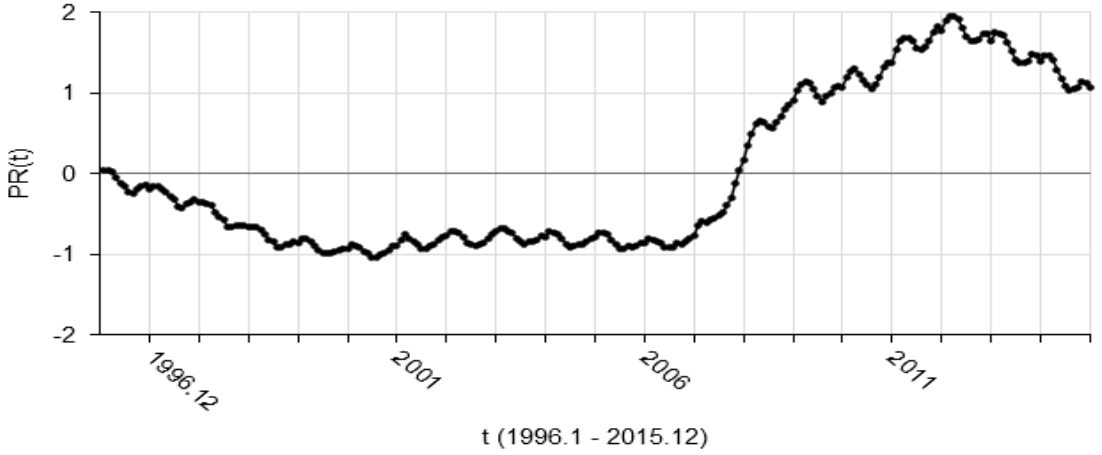

Gráfico 2.2

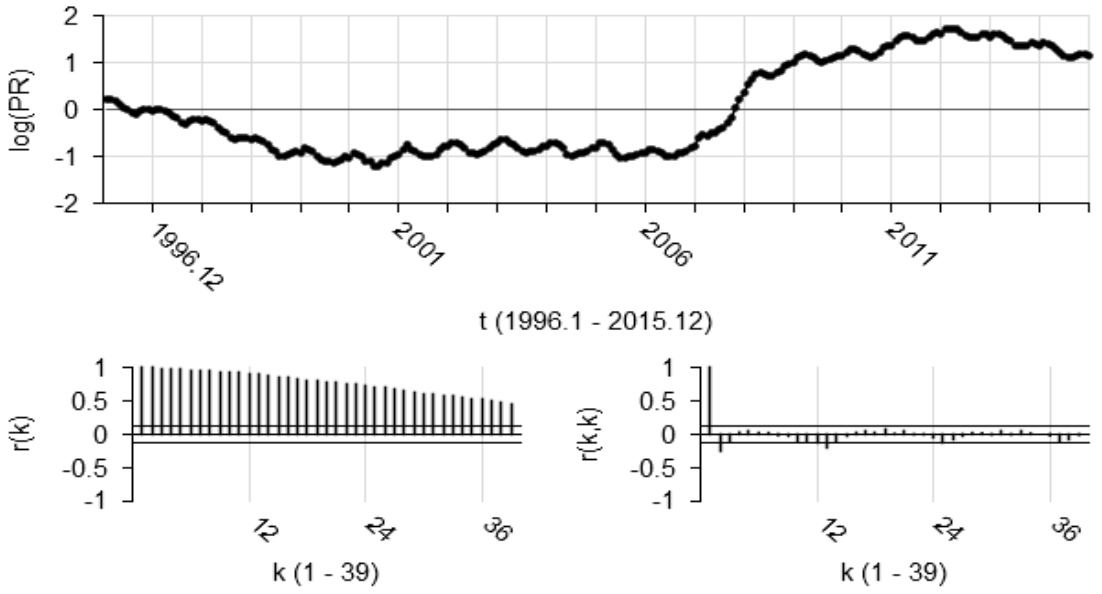

Gráfico 2.3

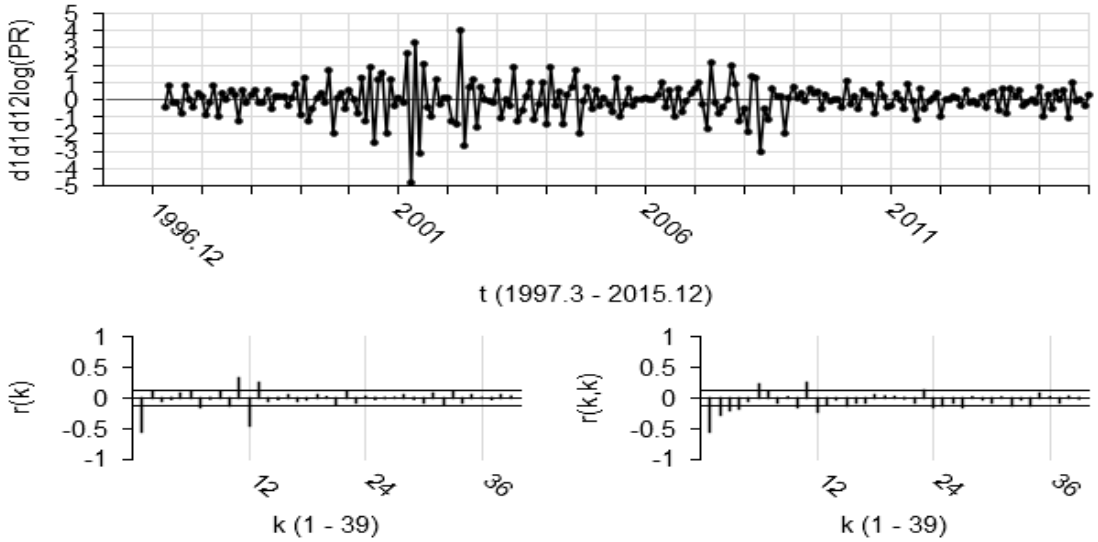

Gráfico 2.4

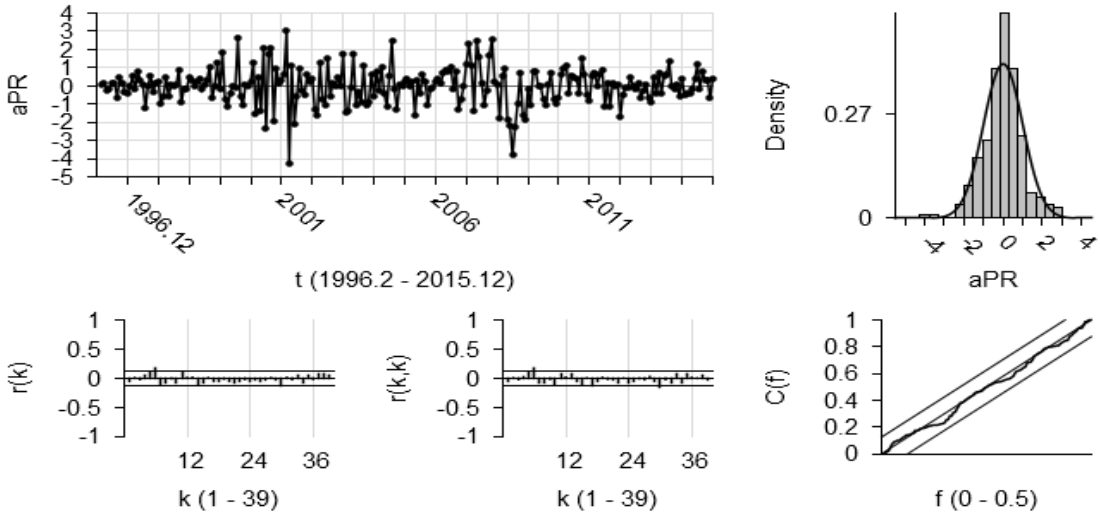

Gráfico 2.5

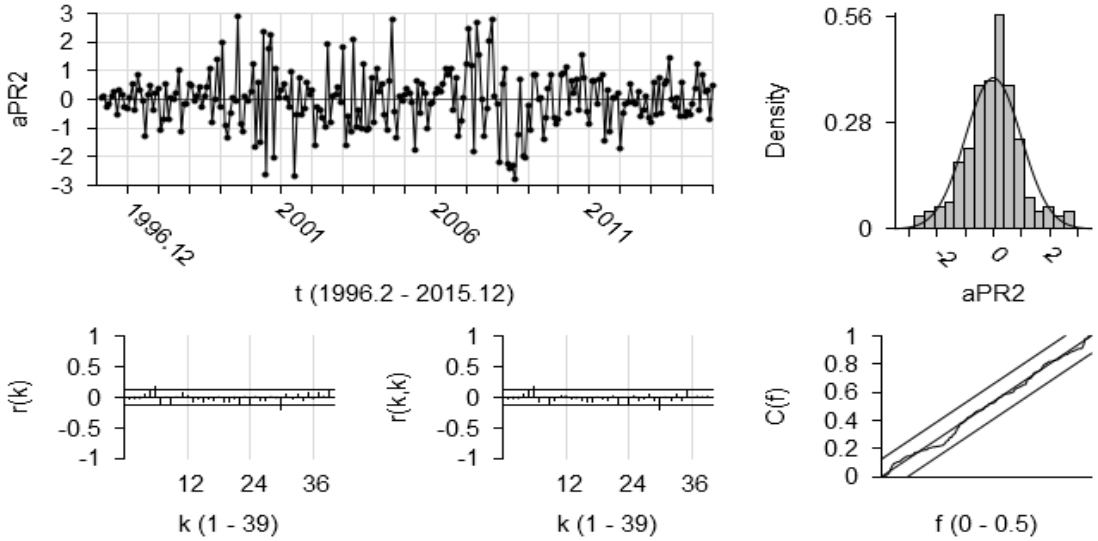

Gráfico 3.1

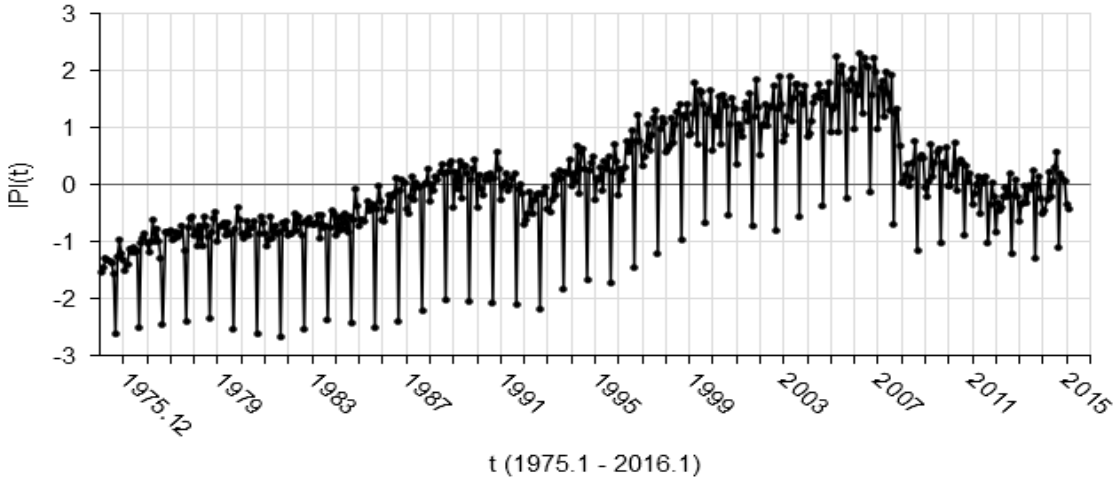

Gráfico 3.2

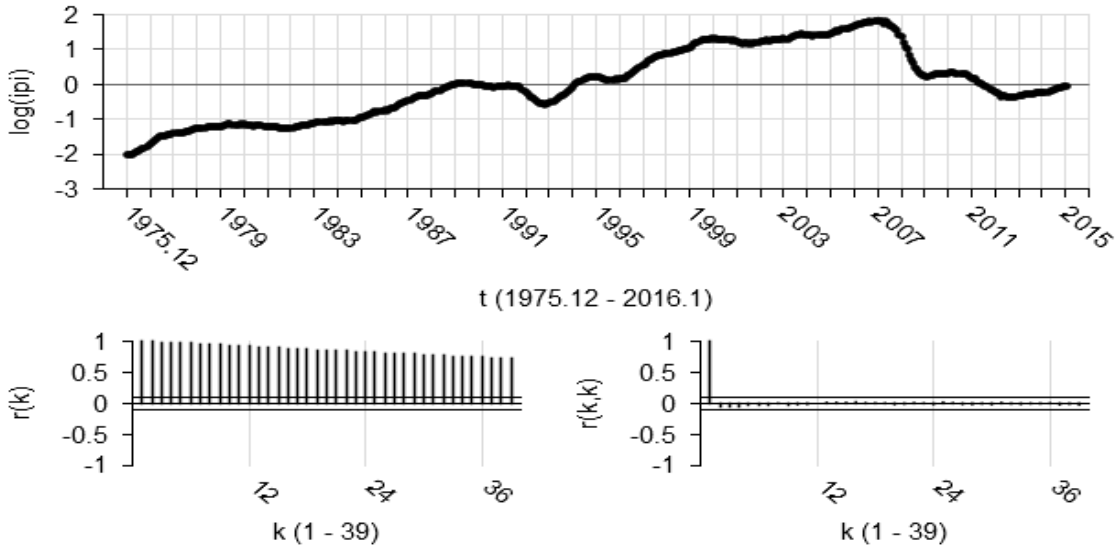

Gráfico 3.3

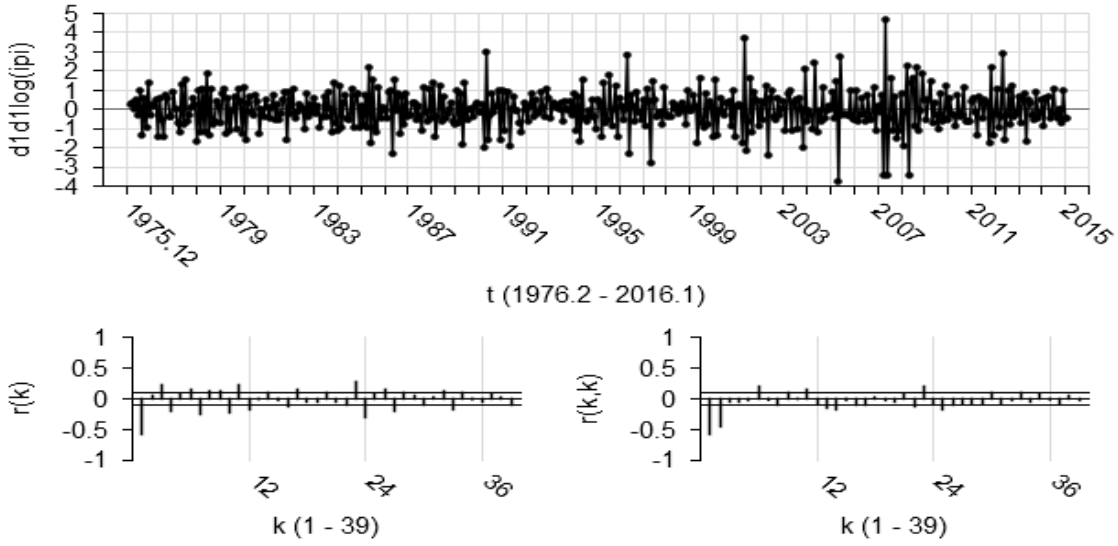

Gráfico 3.4

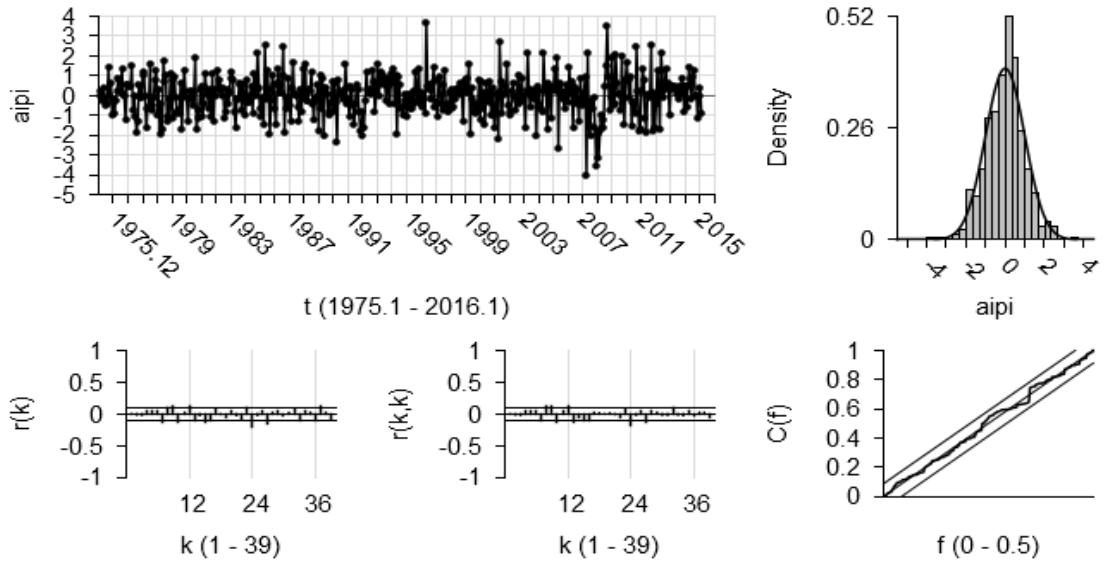

Gráfico 3.5

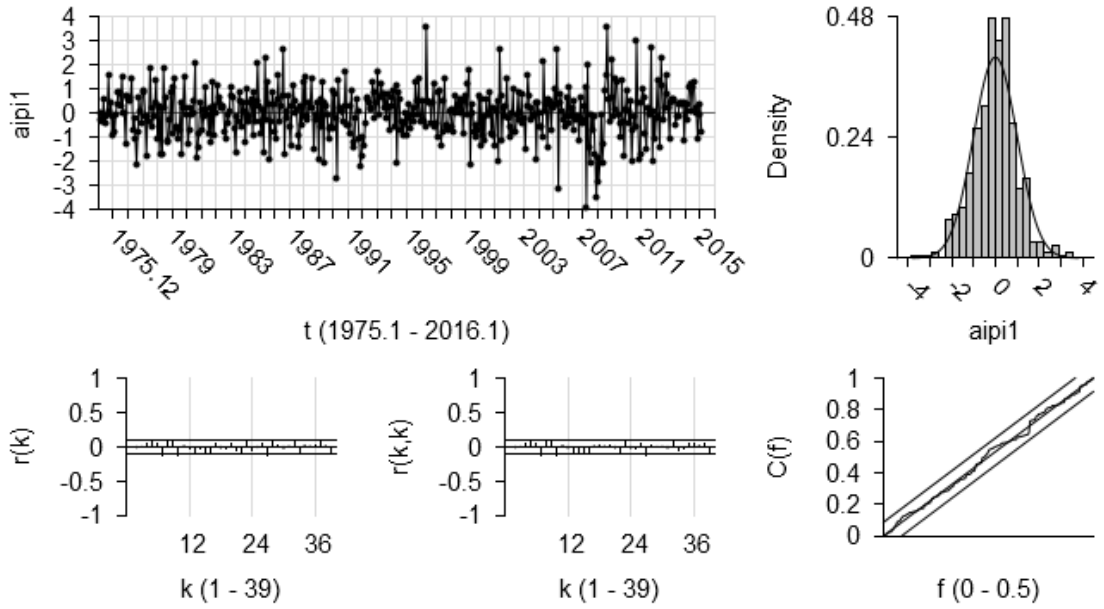

Gráfico 4.1

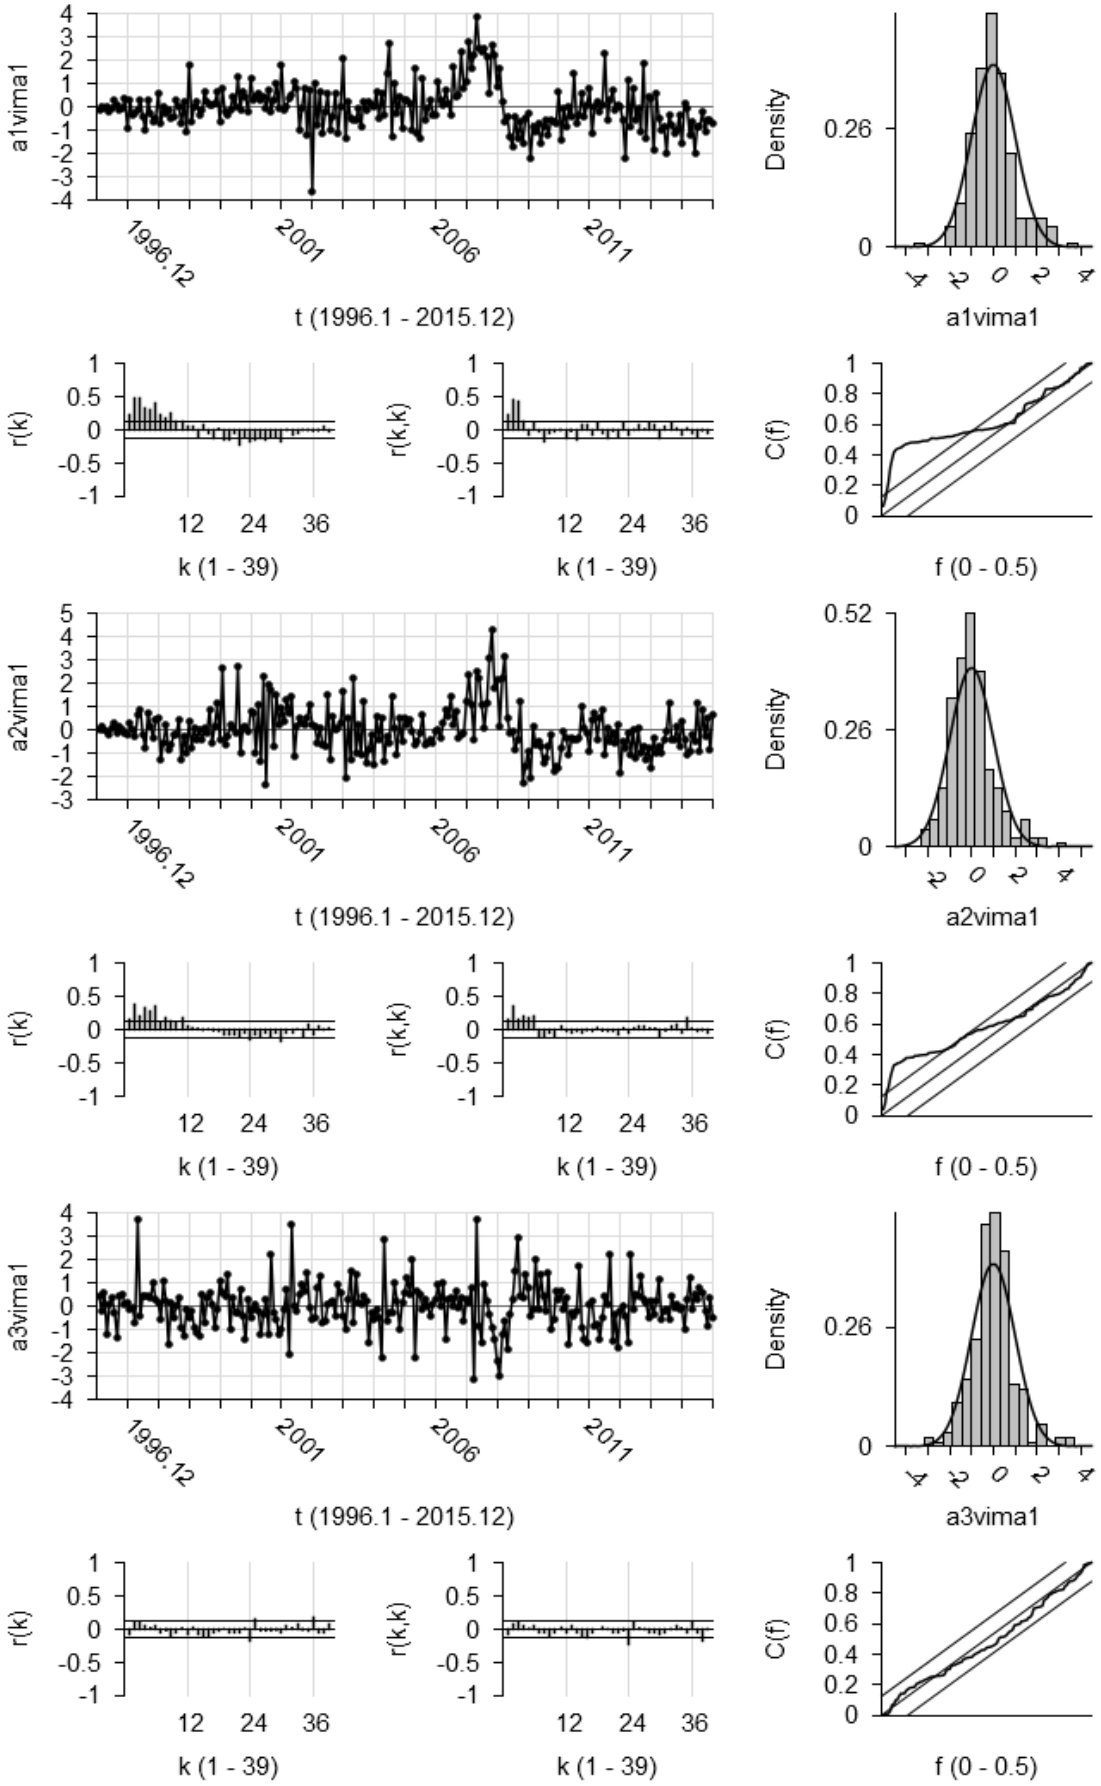
a1vima1
1996.12
2001
2006
2011
t (1996.1 - 2015.12)
Density
a1vima1
r(k)
r(k,k)
k (1 - 39)
C(f)
f (0 - 0.5)
a2vima1
a3vima1

Gráfico 4.2

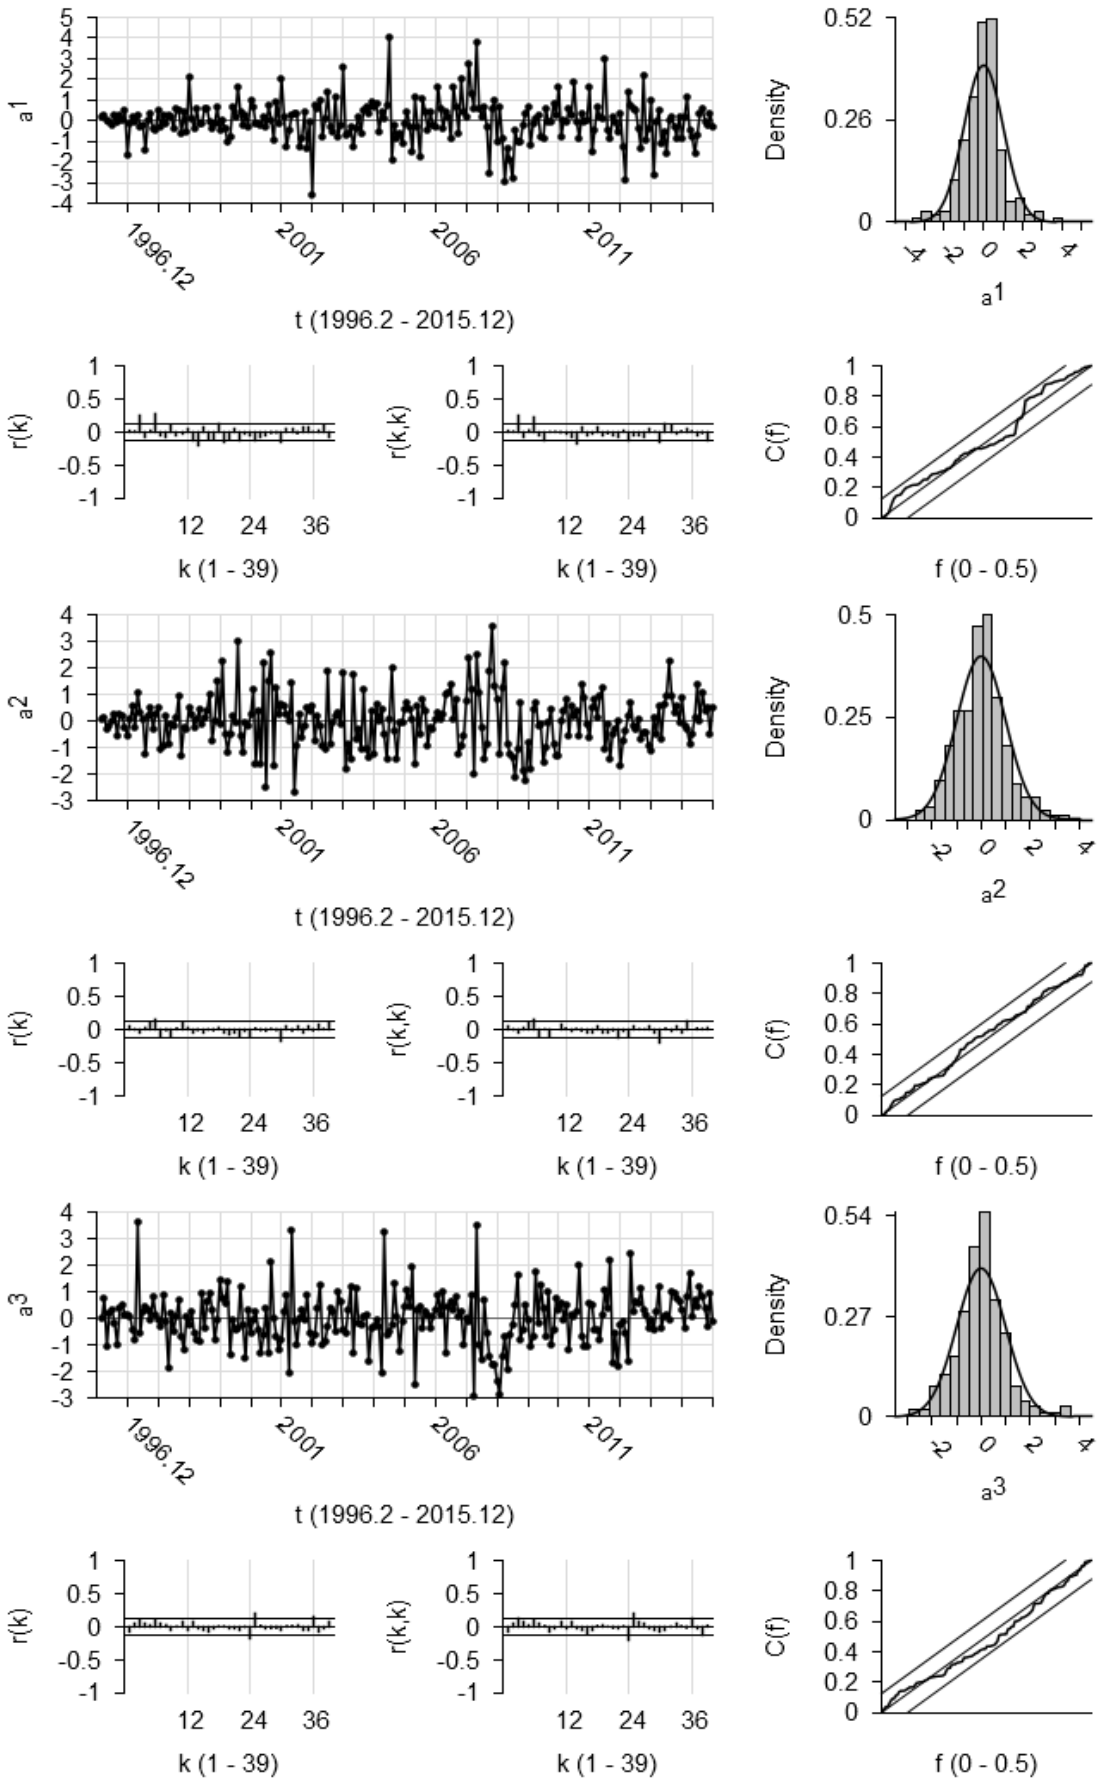
a1
1996.12
2001
2006
2011
t (1996.2 - 2015.12)
Density
a1
r(k)
r(k,k)
k (1 - 39)
C(f)
f (0 - 0.5)
a2
a3

Gráfico 4.3

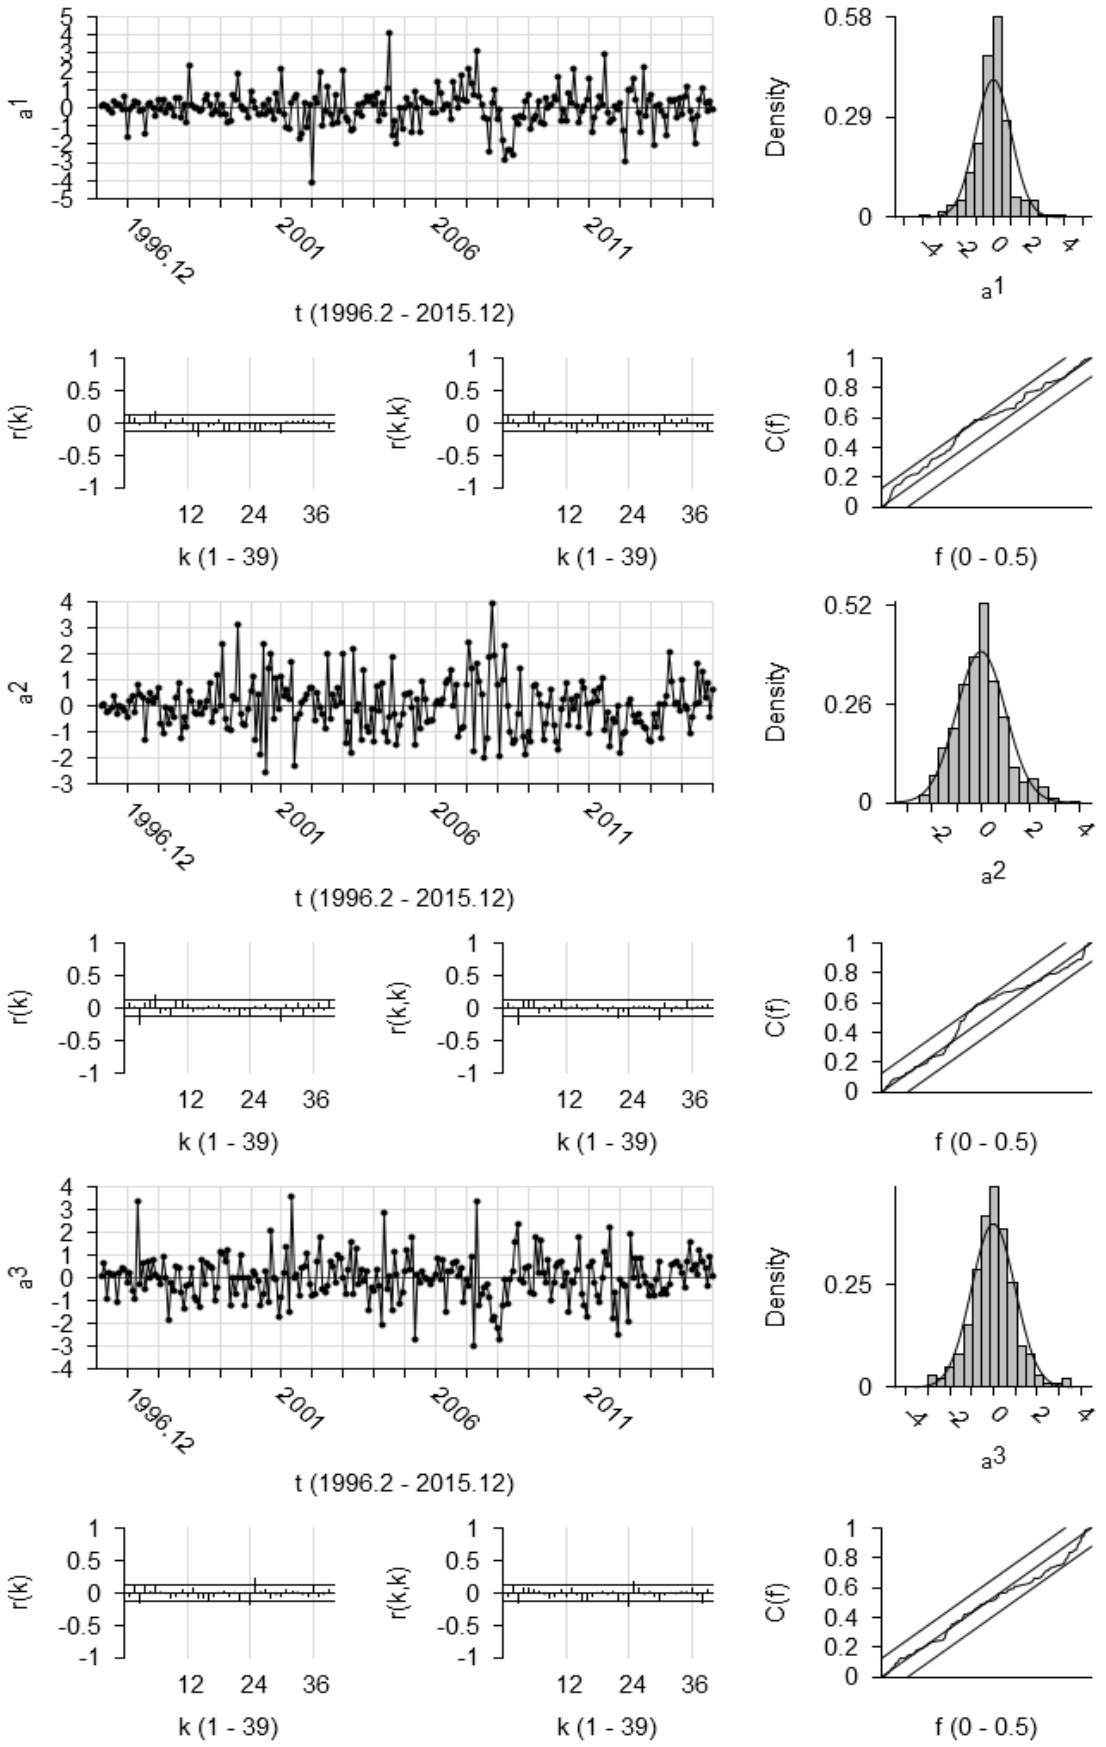
a1
1996.12
2001
2006
2011
t (1996.2 - 2015.12)
Density
a1
r(k)
r(k,k)
k (1 - 39)
C(f)
f (0 - 0.5)
a2
a3

9. BIBLIOGRAFÍA

Box G. & Jenkins G. & Reinsel (2015). “Time Series Analysis: Forecasting and Control.” 4º Edición. Ed: WILEY.

Peña D. (2005). “Análisis de series temporales.” Ed: Alianza

Aznar A. & Trívez FJ (1993). “Métodos de predicción en economía.” Ed: Ariel

Harvey A. (1990). “Forecasting, structural time series models and the Kalman filter”. Ed: Cambridge University Press

Maudos J. “El sector bancario español en el contexto internacional: El impacto de la crisis.”

Ania Supady-Chavan, SAS Global Forum. “Time Series Modeling and Forecasting – An application to Bank´s Stress Testing.”

Luca Guerrieri & Michelle Welch, Federal Reserve Board. “Can Macrovariables Used In Stress Testing Forecast The Performance Of Banks?”

Rodrigo M. Sekkel, Bank of Canada. “Balance Sheets of Financial Intermediaries: Do They Forecast Economic Activity.”

Jérôme Henry & Christoffer Kok, European Central Bank. “A Macro Stress Testing Framework For Assessing Systemic Risks In The Banking Sector.”

http://salaimartin.com/randomthoughts/item/436-el-informe-wyman-con-stress-test-de-la-banca-primeras-impresiones.html

http://economia.elpais.com/economia/2016/02/24/actualidad/1456346148_729953.html

http://www.ine.es/

http://www.bde.es/bde/es/

http://economia.elpais.com/economia/2010/07/22/actualidad/1279783985_850215.html

http://www.extensionuned.es/archivos_publicos/qdocente_planes/42172/tema10sistemasfinancierosanalisisdeentidadesbancarias.pdf

http://www.uv.es/maudosj/publicaciones/Revista%20Castilla%20La%20Mancha.pdf

http://www.uv.es/maudosj/publicaciones/Cuadernos%20de%20Informaci%C3%B3n%20Econ%C3%B3mica_2012.pdf