

UNIVERSIDAD CENTRAL DE VENEZUELA
FACULTAD DE CIENCIAS
POSTGRADO EN MODELOS ALEATORIOS



MODELOS VAR CON PARAMETROS
VARIABLES EN EL TIEMPO.

TRABAJO DE GRADO DE MAESTRÍA

A ser desarrollado por el:

LIC. JOSE WILLIAM MUÑOZ ALVARADO

Firma: _____

Tutor: DR. DANIEL BARRAEZ

Lugar de trabajo: UCV

Firma: _____



UNIVERSIDAD CENTRAL DE VENEZUELA
FACULTAD DE CIENCIAS
COMISIÓN DE ESTUDIOS DE POSTGRADO



Comisión de Estudios
de Postgrado

VEREDICTO


Quienes suscriben, miembros del jurado designado por el Consejo de la Facultad de Ciencias de la Universidad Central de Venezuela, para examinar el Trabajo de Grado presentado por: **José William Muñoz Alvarado**, Cédula de identidad N°14.270.879, bajo el título "**MODELOS VAR CON PARAMETROS VARIABLES EN EL TIEMPO**", a fin de cumplir con el requisito legal para optar al grado académico de **MAGÍSTER SCIENTIARUM, MENCIÓN MODELOS ALEATORIOS**, dejan constancia de lo siguiente:

1.- Leído como fue dicho trabajo por cada uno de los miembros del jurado, se fijó el día 13 de junio de 2017 a las 08:00 AM., para que el autor lo defendiera en forma pública, lo que éste hizo en la Sala Raimundo Chela, mediante un resumen oral de su contenido, luego de lo cual respondió satisfactoriamente a las preguntas que le fueron formuladas por el jurado, todo ello conforme con lo dispuesto en el Reglamento de Estudios de Postgrado.

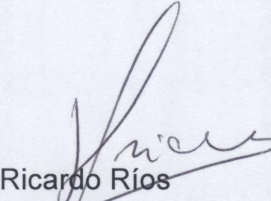
2.- Finalizada la defensa del trabajo, el jurado decidió **aprobarlo** por considerar, sin hacerse solidario con la ideas expuestas por el autor, que se ajusta a lo dispuesto y exigido en el Reglamento de Estudios de Postgrado.

Para dar este veredicto, el jurado estimó que el trabajo constituye un aporte de interés al modelaje de la economía Venezolana empleando vectores autoregresivos con parámetros variables en el tiempo.

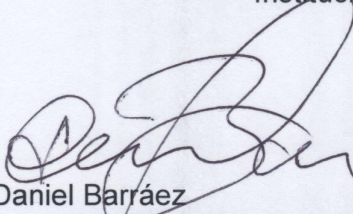
En fe de lo cual se levanta la presente ACTA, a los 13 días del mes de junio del año 2017, conforme a lo dispuesto en el Reglamento de Estudios de Postgrado, actuó como Coordinador del jurado Daniel Barráez.


José Rafael León

Nombre Apellido / C.I. 3.846.337
Institución (UCV)


Ricardo Ríos

Nombre Apellido / C.I. 3.949.476
Institución (UCV)


Daniel Barráez

Nombre Apellido / C.I. 6.197.305
Institución (UCV)
Tutor



Postgrado en
MODELOS
ALEATORIOS

*A mi madre ...
y mis hermanas que estuvieron allí.*

AGRADECIMIENTOS

De todo corazón quiero agradecerle a las siguientes personas.

A mi madre una persona que sola siempre estuvo ahí para sacarnos adelante, una persona que con muy poco logró estimular para que cada uno de nosotros fuera lo mejor para ella, dando ejemplo de constancia y de no rendirse ante nada, dando lo mejor de ella para que sus hijos fueran personas exitosas, es grato saber que de tres de sus hijos, los tres somos profesionales, gracias madre.

A mi hermana Loryibel por que gracias a ella estoy aquí en esta carrera, y mi hermana Orlays, que son las dos persona a las que mas quiero incluyendo a sus hijos, a todas esas personas que estuvieron dándome su apoyo.

A todos los profesores que me dieron clase y especialmente al Dr. Daniel Barraez que fue mi tutor en esta tesis, al Prof. Alí Duin, Prof. Ricardo Rios.

Y también todos aquellos compañeros que tuve durante todo el periodo de permanencia como estudiante en la universidad, algunos como Alejandro Labarca, Jorge Vinceiro, Carlos Yopez y muchos más.

Gracias a todas estas personas muchas gracias por estar allí

RESUMEN

Se presenta el modelo estadístico propuesto por Primiceri 2005 para modelar varias variables con un vector autoregresivo de parámetros variables en el tiempo. La fuente de variación de los parámetros en el tiempo son los coeficientes y la matriz de covarianzas de las innovaciones. Se estima el modelo mediante el muestreo de Gibbs, la técnica se utilizo para estimar un VAR de cinco variables de la economía venezolana con frecuencia trimestral, las variables son; las Importaciones en \$ U.S, el IPC del área metropolitana de Caracas, el PIB, el Precio de la Cesta Petrolera venezolana, el TC (tipo de cambio) no oficial $Bs/\$$ en el periodo 1997 I-2015 IV.

ÍNDICE

Agradecimientos	i
Resumen	iii
Introducción	1
1. EL MODELO ESTADISTICO.	3
2. INFERENCIA BAYESIANA.	7
2.1. Modelo de espacio de estado.	8
2.2. Muestreador de Gibbs.	10
3. ALGORITMO MCMC.	11
4. APLICACIÓN EN LA ECONOMÍA VENEZOLANA.	19
4.1. DENSIDADES A PRIORI DEL MODELO PARA LA ECONOMIA VE- NEZOLANA.	20
5. Resultados Computacionales.	23
Referencias Bibliográficas	31

INTRODUCCIÓN

Algunas variables macroeconómicas muestran importantes cambios en su comportamiento, que se expresan en cambios de su volatilidad y en sus interacciones. La literatura considera dos clases principales de explicaciones, la primera (vea Blanchard y Simon (2001), Stock y Watson (2002) y Sims y Zha (2004)) se centra en la heterocedasticidad de los choques exógenos. La segunda enfatiza los cambios en el mecanismo de transmisión, es decir, la manera como las variables macroeconómicas responden a los choques. El modelo planteado por Primiceri 2005 permite modelar simultáneamente los dos aspectos planteado en un único modelo. Este tipo de modelo es de interés para analizar la economía venezolana por los constantes cambios a que esta sometida por ejemplo, las abruptas variaciones de los precios del petróleo, las modificaciones al régimen cambiario, y los cambios en política monetaria y fiscal.

El objetivo es estudiar el modelo para ser utilizado en la economía venezolana, usando las técnicas de Primiceri que proporcionan un marco flexible para la estimación y la interpretación de la variación en el tiempo de alguna variable a estudiar y su efecto sobre el resto de las variables. Dos son las principales características requeridas: (1) Parámetros variando en el tiempo; (2) un modelo multivariado con el fin de entender cómo los cambios de una variable han afectado al resto de las variables. Para este propósito, se estima un vector auto regresivo (VAR), donde los coeficientes y la matriz de covarianza de las innovaciones del modelo cambian en el tiempo. Observe que cualquier intento razonable para modelar los cambios, la estructura y su interacción debe incluir la variación temporal de la matriz de covarianzas de las innovaciones. Esto se refleja tanto variación en el tiempo de las relaciones simultáneas entre las variables del modelo y heteroscedasticidad de las innovaciones. Esto se hace mediante el desarrollo de una simple estrategia de modelización multivariada de volatilidad estocástica de la ley del movimiento de la matriz de covarianzas. Un algoritmo eficiente de simulación de cadena de Markov Monte Carlo es propuesto para la simulación de las densidades a posteriori de los parámetros de interés.

CAPÍTULO 1

EL MODELO ESTADISTICO.

En este capitulo estudiaremos el modelo de Primiceri que es un modelo de serie temporal con coeficientes y matriz de covarianza variables en el tiempo. El estudio de los cambios en los coeficientes tienen el propósito de capturar posibles no linealidades o variación en el tiempo en la estructura de rezago del modelo. La volatilidad estocástica multivariada está destinado a capturar posible heterocedasticidad de los choques y las no linealidades en las relaciones simultáneas entre las variables del modelo.

Considere el modelo.

$$y_t = c_t + B_{1,t}y_{t-1} + \dots + B_{k,t}y_{t-k} + u_t \quad t = 1, \dots, T. \quad (1.1)$$

donde

- y_t es un vector $n \times 1$ de variables endógenas observadas,
- c_t es un vector $n \times 1$ de coeficientes variables en el tiempo que multiplica los términos constantes,
- $B_{i,t}$ $i = 1, \dots, k$ son matrices $n \times n$ de coeficientes variando en el tiempo,
- u_t son choques heterocedásticos centrados inobservables con matriz de covarianza Ω_t que satisface

$$A_t \Omega_t A_t' = \Sigma_t \Sigma_t' \quad (1.2)$$

donde A_t es la matriz triangular inferior

$$A_t = \begin{bmatrix} 1 & 0 & \dots & 0 \\ \alpha_{21,t} & 1 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ \alpha_{n1,t} & \dots & \alpha_{nn-1,t} & \end{bmatrix}$$

y Σ_t es la matriz diagonal

$$\Sigma_t = \begin{bmatrix} \sigma_{1,t} & 0 & \cdots & 0 \\ 0 & \sigma_{2,t} & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & \sigma_{n,t} \end{bmatrix}$$

resulta que

$$\begin{aligned} y_t &= c_t + B_{1,t}y_{t-1} + \cdots + B_{k,t}y_{t-k} + A_t^{-1}\Sigma_t\varepsilon_t, \\ V(\varepsilon_t) &= I_n. \end{aligned} \quad (1.3)$$

Apilando en un vector B_t todos los coeficientes del lado derecho, (1.3) se puede reescribir como

$$\begin{aligned} y_t &= X_t' B_t + A_t^{-1}\Sigma_t\varepsilon_t, \\ X_t' &= I_n \otimes [1, y_{t-1}', \dots, y_{t-k}'], \end{aligned} \quad (1.4)$$

donde el símbolo \otimes denota el producto Kronecker.

Una descomposición de la matriz de covarianza resultante en (1.4) es común, sobre todo en la literatura sobre el problema de la estimación eficientemente de matrices de covarianza. En el contexto de modelos VAR con estructura variable en el tiempo, Cogley (2003) and Cogley and Sargent (2003) tienen una descomposición similar, pero con una matriz A_t invariante en el tiempo. Es importante darse cuenta de que permitir que la matriz A_t varíe con el tiempo es crucial para un VAR con parámetros que varía en el tiempo. Una constante A_t implicaría que una innovación a la variable i -ésima tiene un impacto constante en el tiempo de la variable j -ésima. Esto es claramente no es adecuado si el objetivo es un modelo de ecuaciones simultáneas variando en el tiempo, donde las interacciones simultáneas entre variables son fundamentales.

La estrategia consiste en modelar los procesos coeficiente en (1.4) en lugar de (1.1). Observe que hay una relación uno a uno entre (1.1) y (1.4) que es totalmente justificado este enfoque. Sea α_t el vector distinto de cero y distinto de unos de la matriz A_t (apilada por filas) y σ_t sea el vector de los elementos diagonales de la matriz de Σ_t . La dinámica de los parámetros variables en el tiempo del modelo se especifican como sigue:

$$B_t = B_{t-1} + \nu_t, \quad (1.5)$$

$$\alpha_t = \alpha_{t-1} + \zeta_t, \quad (1.6)$$

$$\log \sigma_t = \log \sigma_{t-1} + \eta_t. \quad (1.7)$$

Todas las innovaciones en el modelo se supone que se distribuye normalmente en forma conjunta con los siguientes supuestos sobre la matriz de covarianza:

$$V = Var \left(\begin{bmatrix} \varepsilon_t \\ \nu_t \\ \zeta_t \\ \eta_t \end{bmatrix} \right) = \begin{bmatrix} I_n & 0 & 0 & 0 \\ 0 & Q & 0 & 0 \\ 0 & 0 & S & 0 \\ 0 & 0 & 0 & W \end{bmatrix} \quad (1.8)$$

donde I_n es una matriz identidad n-dimensional, Q, S, W son matrices definidas positivas, en Primiceri se señala que ninguna de las restricciones sobre la estructura de V son esenciales. Sin embargo, hay al menos dos factores que sugieren una selección de V , tales como el descrito en (1.8). La primera está relacionada con el ya alto número de parámetros del modelo. Sumando todos los elementos fuera de la diagonal de V , requeriría la especificación de prioris sensatos, capaces de prevenir los casos de los parámetros mal determinados. La segunda (y más importante) razón es que permite una estructura de correlación completamente general entre las diferentes fuentes de incertidumbre impediría cualquier interpretación estructural de las innovaciones.

Puede ser visto (1.4), (1.5), (1.6) y (1.7) como una representación de espacio de estado donde y_t es la variable observable y B_t, α_t, σ_t son las variables no observables o variables de estado, lo que permite emplear un algoritmo de kalma como se vera más adelante.

La siguiente notación, que emplearemos en el resto del trabajo, se utiliza para denotar la historia de un vector general de variables ω_t hasta un tiempo τ :

$$\omega^\tau = [\omega'_1, \dots, \omega'_\tau]'$$

Para una matriz general de variables y términos constantes M_t ,

$$M^\tau = [m'_1, \dots, m'_\tau]'$$

donde m_t es un vector columna construido con elementos de M_t variando en el tiempo.

CAPÍTULO 2

INFERENCIA BAYESIANA.

El objetivo en este capítulo es presentar las técnicas de simulación bayesiana (vea Gary Koop) utilizadas para estimar el modelo VAR con parámetros variando en el tiempo presentado en el capítulo anterior. Los métodos bayesianos se utilizan para estimar la distribución a posteriori de los parámetros de interés, es decir, B^T , A^T , Σ^T y los parámetros de la matriz covarianza V . Hay tres argumentos que hacen que los métodos bayesianos sean particularmente adecuados para la estimación de esta clase de modelos y preferibles a la estimación clásica. En primer lugar, si la varianza de los coeficientes variable en el tiempo es pequeña, la clásica estimación de máxima verosimilitud de esta variación tiene un punto de masa en cero. El segundo inconveniente de máxima verosimilitud clásica se relaciona con la alta dimensionalidad y la no linealidad del problema. Con este complicado modelo será muy posiblemente tener una probabilidad con múltiples picos, algunos de los cuales se encuentran en regiones carentes de interés o inverosímiles de los parámetros de espacio. Además, si estos picos son muy estrechos, la probabilidad puede alcanzar valores particularmente altos, no es en absoluto representativo de ajuste del modelo en una región más amplia y de parámetros más interesante. En un entorno bayesiano, el uso de distribuciones a priori poco informativas sobre las regiones razonables de los parámetros de espacio, es efectivo para descartar este mal comportamiento. La tercera razón es práctica: a pesar de que en principio es posible escribir la probabilidad del modelo, es una tarea difícil de maximizarlo sobre un espacio de tan alta dimensión. Los métodos bayesianos abordar eficazmente la alta dimensión del espacio de parámetros y las no linealidades del modelo, la división del problema de estimación original en otras más pequeñas y más simples. Aquí, el muestreo de Gibbs se utiliza para la estimación de las densidades a posteriori de los parámetros de interés. El muestreo de Gibbs es un tipo de cadena de Markov Monte Carlo (MCMC) que consiste en la simulación de densidades a posteriori condicional de dimensiones inferiores a diferencia de densidades a posteriori conjunta de alta dimensión de todo el conjunto

de parámetros.

2.1. Modelo de espacio de estado.

Considere una ecuación de medida:

$$y_t = H_t \beta_t + \varepsilon_t$$

donde y_t es una variable observable, H_t es la matriz de coeficiente la cual es conocida, β_t es una variable observable, ε_t es inobservable y la ecuación de transición viene dada por

$$\beta_t = F \beta_{t-1} + u_t$$

donde

$$\begin{bmatrix} \varepsilon_t \\ u_t \end{bmatrix} \text{i.i.d.} N \left(\begin{bmatrix} 0 \\ 0 \end{bmatrix}, \begin{bmatrix} R_t & 0 \\ 0 & Q \end{bmatrix} \right)$$

Denotando

$$\beta_{t|s} = E(\beta_t | Y^s, H^s, R^s, Q),$$

$$V_{t|s} = \text{Var}(\beta_t | Y^s, H^s, R^s, Q)$$

Entonces, dado $\beta_{0|0}$ y $V_{0|0}$ el filtro de Kalma estandar es el siguiente algoritmo recursivo que permite estimar $\beta_{t|t}$ y $V_{t|t}$ para cada instante de tiempo t :

$$\begin{aligned}\beta_{t|t-1} &= F\beta_{t-1|t-1}, \\ V_{t|t-1} &= FV_{t-1}F' + Q, \\ K_t &= V_{t|t-1}H_t'(H_tV_{t|t-1}H_t' + R_t)^{-1}, \\ \beta_{t|t} &= \beta_{t|t-1} + K_t(y_t - H_t\beta_{t|t-1}), \\ V_{t|t} &= V_{t|t-1} - K_tH_tV_{t|t-1}.\end{aligned}$$

Los últimos elementos de la recursividad son $\beta_{T|T}$ y $V_{T|T}$, los cuales son la media y la varianza de la distribución Normal usada para estimar β_T . La estimación de β_T y la salida del filtro se utiliza ahora para la primera etapa de la recursión hacia atrás, los cuales proporcionan $\beta_{T-1|T}$ y $V_{T-1|T}$, que son usado para la estimación de β_{T-1} . La recursión hacia atrás continúa hasta que el tiempo sea cero. Para un tiempo general t , las fórmulas de actualización de la recursión hacia atrás son:

$$\begin{aligned}\beta_{t|t+1} &= \beta_{t|t} + V_{t|t}F'V_{t+1|t}^{-1}(\beta_{t+1} - F\beta_{t|t}), \\ V_{t|t+1} &= V_{t|t} - V_{t|t}F'V_{t+1|t}^{-1}FV_{t|t}.\end{aligned}$$

La estimación de la variable no observable β_t y V_t empleando algoritmo MCMC es bien conocido en la literatura. Se emplea el algoritmo de Gibbs que presentaremos a continuación.

2.2. Muestreador de Gibbs.

Considere el caso del muestreador de Gibbs, donde $\theta = (\theta_1, \theta_2)$ con un iterado inicial θ_1^0 , se obtiene

$\theta_2^0 \sim p(\theta_2|y, \theta_1^0)$ luego $i = 1, \dots, j$ se obtiene de forma recursiva

$$\theta_1^i \sim p(\theta_1|y, \theta_2^{i-1})$$

$$\theta_2^i \sim p(\theta_2|y, \theta_1^{i-1})$$

CAPÍTULO 3

ALGORITMO MCMC.

En este capítulo las distribuciones a priori propuestas en este documento son elegidos debido a su intuición y la comodidad en las aplicaciones. En primer lugar, es conveniente suponer que los estados iniciales de los coeficientes, de las covarianzas, de los log volatilidades y los parámetros de la matriz de covarianza son independientes el uno del otro. Las densidades a priori de los parámetros de la matriz de covarianza Q , W y los bloques de S se suponen que son distribuidos independientes inversa Wishart. Las densidades a priori para los estados iniciales de coeficientes variando en el tiempo, relaciones simultáneas y log de errores estándares, $p(B_0)$, $p(\alpha_0)$ y $p(\log \sigma_0)$, se suponen que son normalmente distribuidos. Estos supuestos junto con (1.5), (1.6) y (1.7) implican densidades a priori normales en las secuencias completas de los B , α y $\log \sigma$ (condicional sobre Q , W y S). En resumen

B_0	$\sim N$	Q	$\sim IW$
α_0	$\sim N$	W	$\sim IW$
$\log \sigma_0$	$\sim N$	S	$\sim IW$

Que se usan para estimar la densidad a posteriori conjunta de parámetros $p(B^T, A^T, \Sigma^T, V|y)$ donde para estimar dicha densidad se utiliza el algoritmo de Gibbs, para ello se requiere simular las "Full" densidades a parte. Es decir simular

$$p(B^T|y^T, A^T, \Sigma^T, V)$$

$$p(A^T|y^T, B^T, \Sigma^T, V)$$

$$p(\Sigma^T|y^T, A^T, B^T, s^T, V)$$

$$p(s^T|y^T, A^T, \Sigma^T, V)$$

V , de

$$p(Q, W, S|y^T, B^T, A^T, \Sigma^T) = p(Q|y^T, B^T, A^T, \Sigma^T) \cdot$$

$$p(W|y^T, B^T, A^T, \Sigma^T) \cdot p(S_1|y^T, B^T, A^T, \Sigma^T) \cdot \dots \cdot p(S_{n-1}|y^T, B^T, A^T, \Sigma^T)$$

La densidad a priori normal sobre B es usual. Es importante destacar una desventaja potencial de los supuestos de modelado (1.4), (1.6), (1.7) y (1.8), en combinación con las distribuciones previas sobre A y Σ . El inconveniente es el hecho de que, en principio, el orden de las variables importa en (1.4). Esto es debido a la estructura triangular inferior impuesta a la matriz A_t .

El modelo se obtiene mediante la estimación de la distribución de los parámetros de interés, dados los datos. En lo siguiente se esboza el algoritmo MCMC utilizado para generar una muestra a posteriori conjunta de (B^T, A^T, Σ^T, V) . Como se mencionó anteriormente, el muestreo de Gibbs se utiliza con el fin de explotar la estructura de bloque de los parámetros. El muestreo de Gibbs se lleva a cabo en las siguientes etapas, estimación sucesiva de los coeficientes (B^T) variando en el tiempo, las relaciones simultáneas (A^T), volatilidades (Σ^T) y parámetros de la matriz de covarianza (V), condicionadas a los datos observados y el resto de los parámetros.

 EL ALGORITMO BASICO DE LA CADENA DE MARKOV MONTE CARLO.

Paso 1: Estimación de los estados de los coeficientes $\mathbf{p}(\mathbf{B}^T | \mathbf{y}^T, \mathbf{A}^T, \Sigma^T, \mathbf{V})$.

Condicional sobre A^T , Σ^T y V , la ecuación (1.4) es lineal y tiene innovaciones gaussianas con varianza conocida.

factorizado como

$$p(B^T | y^T, A^T, \Sigma^T, V) = p(B_T | y^T, A^T, \Sigma^T, V) \prod_{t=1}^{T-1} p(B_t | B_{t+1}, y^t, A^T, \Sigma^T, V)$$

donde

$$\begin{aligned} B_t | B_{t+1}, y^t, A^T, \Sigma^T, V &\sim N(B_{t|t+1}, P_{t|t+1}), \\ B_{t|t+1} &= E(B_t | B_{t+1}, y^t, A^T, \Sigma^T, V), \\ P_{t|t+1} &= Var(B_t | B_{t+1}, y^t, A^T, \Sigma^T, V). \end{aligned}$$

Es usado $p(\cdot)$ para denotar una función de densidad general, mientras que N denota la distribución Gaussiana. Los vectores de B pueden ser fácilmente estimado porque $B_{t|t+1}$ y $P_{t|t+1}$ puede ser calculado usando las recurrencias forward(adelante, filtro de Kalman) y backward(atras), se aplica a la forma de espacio de estado dada por (1.4) y (1.5). Específicamente, la última recursividad del filtro ofrece $B_{T|T}$ y $P_{T|T}$, es decir la media y la varianza de la distribución a posteriori de B_T . Estimando un valor de esta distribución es usado en la recurrencia backward para obtener $B_{T-1|T}$ y $P_{T-1|T}$ y así sucesivamente(Para más detalles sobre el muestreo de Gibbs para los modelos de espacio de estado vea Carter y Kohn (1994)).

Paso 2: Estimación los estados de la covarianza $p(\mathbf{A}^T | \mathbf{y}^T, \mathbf{B}^T, \Sigma^T, \mathbf{V})$.

El sistema de ecuaciones (1.4) puede ser escrito como

$$A_t \hat{y}_t = A_t (y_t - X_t' B_t) = \Sigma_t \varepsilon_t \quad (3.1)$$

donde, tomando B^T como dada, \hat{y}_t es observable. Como A_t es una matriz triangular inferior con unos en la diagonal principal, (3.1) puede ser escrito como

$$\hat{y}_t = Z_t \alpha_t + \Sigma_t \varepsilon_t. \quad (3.2)$$

Es definido α_t en (1.6) y Z_t es la siguiente matriz $n \times \frac{n(n-1)}{2}$:

$$Z_t = \begin{bmatrix} 0 & \cdots & \cdots & 0 \\ -\hat{y}_{1,t} & 0 & \cdots & 0 \\ 0 & -\hat{y}_{[1,2],t} & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & -\hat{y}_{[1,\dots,n-1],t} \end{bmatrix}$$

donde, abusando de la notación, $\hat{y}_{[1,\dots,n-1],t}$ denota el vector fila $[\hat{y}_{1,t}, \hat{y}_{2,t}, \dots, \hat{y}_{i,t}]$.

Observe que el modelo dado por (3.2) y (1.6) tiene una representación de espacio de estado Gaussiano pero no lineal. El problema, intuitivamente, es que la variable dependiente de la ecuación observación, \hat{y}_t , también aparece en el lado derecho en Z_t . por lo tanto, el vector $[\hat{y}_t, \hat{\alpha}_t]$ no es normal conjunta y, así, las distribuciones condicionales no pueden ser calculada usando la recursión de filtro de Kalman estandar. Sin embargo, bajo el supuesto adicional de que S es diagonal, este problema se puede resolver mediante la aplicación del filtro de Kalman y la ecuación de recursión hacia atrás ecuación por ecuación. Esto no es sólo debido a que la variable dependiente de cada ecuación $\hat{y}_{i,t}$, no aparece en el lado derecho de la misma ecuación, pero debido a que el vector $\hat{y}_{[1,\dots,i-1],t}$ también puede ser tratado como predeterminado en la i -ésima ecuación, debido a la estructura triangular. Otra forma de ver esto es reinterpretar los tiempo como ir a través de las ecuaciones, que es el tratamiento de diferentes de ecuaciones de medición como pertenecientes a períodos de tiempo distintos y posteriores. Exactamente igual que en el paso anterior de la toma de muestras, este procedimiento permite que se recuperan de forma recursiva

$$\alpha_{i,t|t+1} = E(\alpha_{i,t} | \alpha_{i,t+1}, y^t, B^T, \Sigma^T, V),$$

$$\Lambda_{i,t|t+1} = Var(\alpha_{i,t} | \alpha_{i,t+1}, y^t, B^T, \Sigma^T, V)$$

donde $\alpha_{i,t}$ es el i -ésimo bloque de α_t , correspondiente a los coeficientes de la i -ésima ecuación en (3.2). Como anteriormente, $\alpha_{i,t}$ puede ser estimado recursivamente de $p(\alpha_{i,t} | \alpha_{i,t+1}, y^t, B^T, \Sigma^T, V)$, el cual es $N(\alpha_{i,t|t+1}, \Lambda_{i,t|t+1})$.

Observe que si S no fuera diagonal no sería posible aplicar la ecuación recursiva ecuación por ecuación y extraer por separado cada bloque α_i^T . Sin embargo mientras que la suposición diagonal de bloques de S simplifica el análisis, no es esencial y el Apéndice D en Primiceri 2005, proporciona una modificación de este algoritmo con el fin de hacer frente a S sin restricciones.

Paso 3: Estimación de estados de volatilidad $p(\Sigma^T | y^T, B^T, A^T, V)$.

Considere ahora el sistema de ecuaciones

$$A_t(y_t - X_t' B_t) = y_t^* = \Sigma_t \varepsilon_t, \quad (3.3)$$

donde, tomando B_T y A_T como dados, y_t^* es observable. Este es un sistema de ecuaciones de medidas no lineal, pero se puede convertir fácilmente en uno lineal, elevando al cuadrado y tomando logaritmos de todos los elementos de (3.3) Debido al hecho de que $y_{i,t}^2$ puede ser pequeño, una constante de compensación se utiliza para hacer el procedimiento de estimación más robusta. Esto lleva a la siguiente forma de espacio de estado de aproximación:

$$y_t^{**} = 2h_t + e_t \quad (3.4)$$

$$h_t = h_{t-1} + \eta_t. \quad (3.5)$$

con $y_{i,t}^{**} \cong \log \left[(y_{i,t}^*)^2 + \bar{c} \right]$; \bar{c} es la constante de compensación (establecida a 0.001); $e_{i,t} = \log(\varepsilon_{i,t}^2)$; $h_{i,t} = \log \sigma_{i,t}$. Observe que los e y los η no están correlacionado dado que son independiente (ver Harvey et al 1994).

El sistema de esta forma tiene una forma lineal, pero una forma de espacio de estado no gaussiana, debido a las innovaciones en las ecuaciones de medida se distribuyen como $\log \chi^2(1)$. Con el fin de transformar aún más el sistema en uno aproximado Gaussiano, una mezcla de aproximaciones de normales de la distribución $\log \chi^2$ es usado, como se describe en Kim et al. (1998). Observe que la matriz de covarianza de los ε es la

identidad. Esto implica que la matriz de covarianza de los e es también diagonal, lo que permite utilizar la misma mezcla (independiente) de las aproximación de normales para cualquier elemento de e (Kim et al 1998) seleccione una mezcla de siete densidades normales con probabilidades de componentes q_j medias $m_j - 1.2704$, y varianza v_j^2 $j = 1, \dots, 7$. Las constantes $\{q_j, m_j, v_j^2\}$ se eligen para que coincida con una serie de momentos de la distribución $\log\chi^2(1)$.

Se define $s^T = [s_1, \dots, s_T]'$, la matriz de variables indicadoras en cada punto en el tiempo, qué miembro de la mezcla de la aproximación normal tiene que ser utilizado para cada elemento de e . Condicional sobre B_T, A_T, V y s_T , el sistema tiene una forma de espacio de estado lineal y Gaussian aproximada. Una vez más, exactamente igual que en los pasos anteriores de la toma de muestras, este procedimiento permite recuperan de forma recursiva

$$h_{t|t+1} = E(h_t | h_{t+1}, y^t, A^T, B^T, V, s^T),$$

$$H_{t|t+1} = Var(h_t | h_{t+1}, y^t, A^T, B^T, V, s^T)$$

y recursivamente simular cada h_t de $p(h_t | h_{t+1}, y^t, A^T, B^T, V, s^T)$, el cual es $N(h_{t|t+1}, H_{t|t+1})$. Condicional sobre y^{**T} y la nueva h^T , es posible muestrear la nueva matriz s^T , para ser utilizado en la siguiente iteración.

Como en Kim et al. (1998), esto se hace fácilmente mediante el muestreo de forma independiente de cada uno de los $s_{i,t}$ de la densidad discreta definida por

$$Pr(s_{i,t} = j | y_{i,t}^{**}, h_{i,t}) \propto q_j f_N(y_{i,t}^{**} | 2h_{i,t} + m_j - 1.2704, v_j^2), \quad j = 1, \dots, 7, i = 1, \dots, n.$$

Paso 4: Estimación de los parámetros de la matriz de covarianza

$p(V|y^T, B^T, A^T, \Sigma^T)$.

Los parámetros de la matriz de covarianza del modelo son los bloques diagonales de V : Q, W y los bloques diagonales de S (correspondiente a los parámetros que pertenecen a diferentes ecuaciones). Condicional sobre B^T, Σ^T, A^T y y^T , cada bloque cuadrado tiene una distribución a posteriori inversa Wishart, independiente de los otros bloques. Además, condicional sobre B^T, Σ^T, A^T y y^T , es fácil de simular de éstas densidades a posteriori inversa-Wishart debido a que las innovaciones son observables (ver Gelman, Carlin, Stern and Rubin 1995).

Paso 5: Resumen.

El muestreador toma la forma:

- a. Inicializar A^T, Σ^T, s^T y V .
- b. Muestra B^T de $p(B^T|y^T, A^T, \Sigma^T, V)$.
- c. Muestra A^T de $p(A^T|y^T, B^T, \Sigma^T, V)$.
- d. Muestra Σ^T de $p(\Sigma^T|y^T, A^T, B^T, s^T, V)$.
- e. Muestra s^T de $p(s^T|y^T, A^T, \Sigma^T, V)$.
- f. Muestra V , mediante el muestreo de Q, W y S de $p(Q, W, S|y^T, B^T, A^T, \Sigma^T) = p(Q|y^T, B^T, A^T, \Sigma^T) \cdot p(W|y^T, B^T, A^T, \Sigma^T) \cdot p(S_1|y^T, B^T, A^T, \Sigma^T) \cdot \dots \cdot p(S_{n-1}|y^T, B^T, A^T, \Sigma^T)$
- g. Ir a b

Paso 6: La selección de la distribución de mezcla para ser $\log\chi^2(1)$.

ω	$q_j = Pr(\omega = j)$	m_j	v_j^2
1	0.00730	-10.12999	5.79596
2	0.10556	-3.97281	2.61369
3	0.00002	-8.56686	5.17950
4	0.04395	2.77786	0.16735
5	0.34001	0.61942	0.64009
6	0.24566	1.79518	0.34023
7	0.25750	-.08819	1.26261

CAPÍTULO 4

APLICACIÓN EN LA ECONOMÍA VENEZOLANA.

En este capítulo, las técnicas que acabamos de describir se emplearán para la aplicación del modelo de Primiceri en periodo trimestral de la economía de VENEZUELA. Cinco variables están incluidas en el modelo:

- Las importaciones en \$ U.S.
- El IPC del área metropolitana de Caracas.
- El PIB.
- El precio de la cesta petrolera venezolana.
- El TC (tipo de cambio) no oficial $Bs/\$$.

La muestra se extiende desde 1997: I hasta 2015: IV. Los datos se transformaron en logaritmo con incremento de orden cuatro. Las simulaciones se basan en 5.000 iteraciones del muestreo de Gibbs, desechando los primeros 2000 para la convergencia. Como se muestra en el Apéndice B de PRIMICERI (2005), se dan, las funciones de autocorrelación de las estimaciones, descomposición bastante rápida y los controles de convergencia son satisfactorios.

4.1. DENSIDADES A PRIORI DEL MODELO PARA LA ECONOMÍA VENEZOLANA.

Los primeros 5 años (20 observaciones, a partir de 1997: I a 2002: I) se utilizan para calibrar las distribuciones a priori. Por ejemplo, la media y la varianza de B_0 se eligen para que sean las estimaciones puntuales de OLS (mínimos cuadrados ordinarios) (\hat{B}_{OLS}) y cuatro veces su varianza en un VAR invariante en el tiempo, que se estima en la pequeña submuestra inicial. De la misma manera, un priori razonable para A_0 se pueden obtener. Para $\log \sigma_0$, la media de la distribución se elige para ser el logaritmo de las estimaciones puntuales OLS de los errores estándar del mismo VAR invariante en el tiempo, mientras que la matriz de covarianza se asume arbitrariamente para ser la matriz identidad. Por último, los grados de libertad y la escala de las matrices se necesitan para las distribuciones previas de la inversa del Wishart de los parámetros de la matriz de covarianza. Los grados de libertad se fijan a 4 para W y 2 y 3 para los dos bloques de S (básicamente, uno más la dimensión de cada matriz). La razón de que los grados de libertad son elegidos de manera diferente es que para la distribución de la inversa del Wishart sea adecuada los grados de libertad deben ser superiores a la dimensión W , respectivamente, y los bloques de S . Para Q los grados de libertad se fijan a 20 (el tamaño de la submuestra inicial anterior), ya que un priori un poco más estrecho parece ser necesaria a fin de evitar comportamientos ficticio de coeficientes que varían con el tiempo. Las matrices de escala, \bar{Q} , \bar{W} , \bar{S}_1 y \bar{S}_2 , se eligen para ser fracciones constantes de las varianzas de las estimaciones OLS correspondientes en la submuestra inicial (multiplicado por los grados de libertad, ya que, en la distribución de la inversa del Wishart, la matriz de escala tiene la interpretación de suma de residuos al cuadrado).

Resumiendo, los prioris toman las formas:

$$\begin{aligned}
 B_0 &\sim N\left(\hat{B}_{OLS}, 4 \cdot V\left(\hat{B}_{OLS}\right)\right), \\
 A_0 &\sim N\left(\hat{A}_{OLS}, 4 \cdot V\left(\hat{A}_{OLS}\right)\right), \\
 \log \sigma_0 &\sim N\left(\log \hat{\sigma}_{OLS}, I_n\right), \\
 Q &\sim IW\left(k_Q^2 \cdot 20 \cdot V\left(\hat{B}_{OLS}\right), 20\right), \\
 W &\sim IW\left(k_W^2 \cdot 4 \cdot I_n, 4\right), \\
 S_1 &\sim IW\left(k_S^2 \cdot 2 \cdot V\left(\hat{A}_1, OLS\right), 2\right), \\
 S_2 &\sim IW\left(k_S^2 \cdot 3 \cdot V\left(\hat{A}_2, OLS\right), 3\right),
 \end{aligned}$$

donde S_1 y S_2 denotan dos bloques de S , mientras que \hat{A}_1, OLS y \hat{A}_2, OLS coloca dos bloques correspondientes de \hat{A}_{OLS} . Los resultados de referencia presentados en esta sección se obtienen utilizando los siguientes valores: $k_Q = 0.01$, $k_S = 0.1$, $k_W = 0.01$.

CAPÍTULO 5

RESULTADOS COMPUTACIONALES.

En este capítulo presentaremos definición de la función Impulso Respuesta (vea James Hamilton), instante de tiempo para comparar el comportamiento de la economía venezolana en estos periodos por medio de la función Impulso respuesta, las gráficas de la función Impulso Respuesta de cada una de las variable a estudiar y su respuesta en las demás variables.

Recordemos la definición de la función Impulso Respuesta.

Función impulso respuesta.

Un vector autoregresivo (VAR) en forma de vector MA(∞) es escrito como

$$y_t = \mu + \varepsilon_t + \Psi_1 \varepsilon_{t-1} + \Psi_2 \varepsilon_{t-2} + \dots = \mu + \Psi(L)\varepsilon_t$$

Así, la matriz Ψ_s tiene la siguiente interpretación

$$\frac{\partial y_{t+s}}{\partial \varepsilon'_t} = \Psi_s$$

Es decir, el elemento de la fila i y columna j de Ψ_s identifica la consecuencia de un aumento en una unidad en la j -ésima variable innovación en el tiempo t (ε_{ij}) para el valor de la i -ésima variable a tiempo $t+s$ ($y_{i,t+s}$), manteniendo todas las otras innovaciones en todo tiempo constante.

Si el primer elemento de ε_t se cambia por δ_1 , al mismo tiempo que el segundo elemento se cambia por δ_2, \dots , y el n -ésimo elemento se cambia por δ_n entonces el efecto de esos cambios sobre el vector y_{t+s} , sería dado por

$$\Delta y_{t+s} = \frac{\partial y_{t+s}}{\partial \varepsilon_{1t}} \delta_1 + \frac{\partial y_{t+s}}{\partial \varepsilon_{2t}} \delta_2 + \dots + \frac{\partial y_{t+s}}{\partial \varepsilon_{nt}} \delta_n = \Psi_s \delta$$

Con $\delta = (\delta_1, \dots, \delta_n)'$.

Una simple manera de encontrar estos multiplicadores dinámicos numéricamente es por

simulación. Para implementar la simulación se fija $y_{t-1} = y_{t-2} = \dots = y_{t-p} = \mathbf{0}$. Fijando $\varepsilon_{ij} = 1$ y todos los otros elementos de ε_t igual a cero, y simulamos el sistema

$$y_t = c + \Phi_1 y_{t-1} + \Phi_2 y_{t-2} + \dots + \Phi_p y_{t-p} + \varepsilon_t$$

con $\varepsilon_t \sim iid N(\mathbf{0}, \Omega)$ para instantes $t, t+1, \dots$, con c y $\varepsilon_{t+1}, \varepsilon_{t+2}, \dots$ todos cero. El valor del vector y_{t+s} en el instante $t+s$ de esta simulación corresponde a la j -ésima columna de la matriz Ψ_s . Haciendo una simulación separada por impulso por cada una de las innovaciones ($j=1, \dots, n$) todas las columnas de Ψ_s pueden ser calculadas.

El gráfico del elemento de la i -ésima fila y la j -ésima columna de Ψ_s

$$\frac{\partial y_{i,t+s}}{\partial \varepsilon_{jt}}$$

como una función de s es llamado la función impulso respuesta. Esta describe la respuesta de $y_{i,t+s}$ a un único impulso en y_{jt} con todas las otras variables con instante t o anterior constante (Ver en Hamilito J. D. Time Serie Analysis).

En lo que sigue se presentara la función impulso respuesta de las siguiente variables:

- Las Importaciones en \$ U.S.
- El IPC (Indice de precio al consumidor)del área metropolitana de Caracas.
- El PIB(Producto interno bruto).
- El Precio de la Cesta Petrolera Venezolana.
- El TC (Tipo de cambio) no oficial Bs/\$.

Un choque en una variable generara una respuesta tanto en esta variable como en las demás variables, esto generara el gráfico Impulso Respuesta de todas las variables del VAR en tres instante de tiempo diferentes que son:

- 2003:Q4.
- 2007:Q4.
- 2014:Q4.

Gráficas de la Función impulso respuesta.




Figura 5.1: Respuesta al impulso dado por las importaciones A.

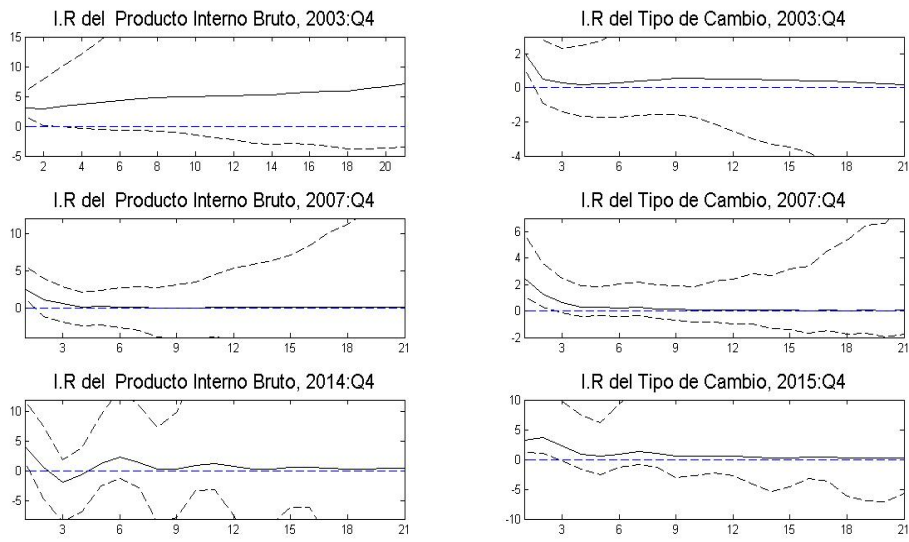


Figura 5.2: Respuesta al impulso dado por las Importaciones B.

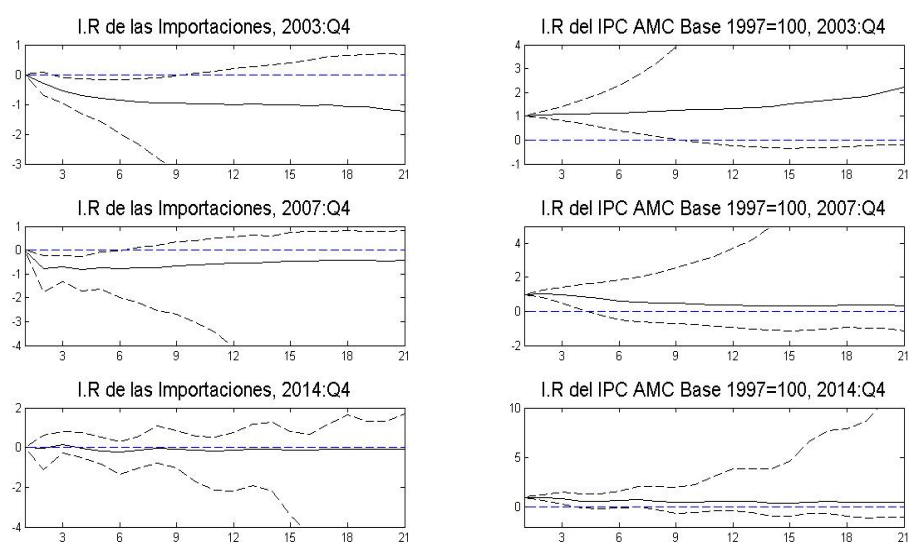


Figura 5.3: Respuesta al impulso dado por el IPC A.

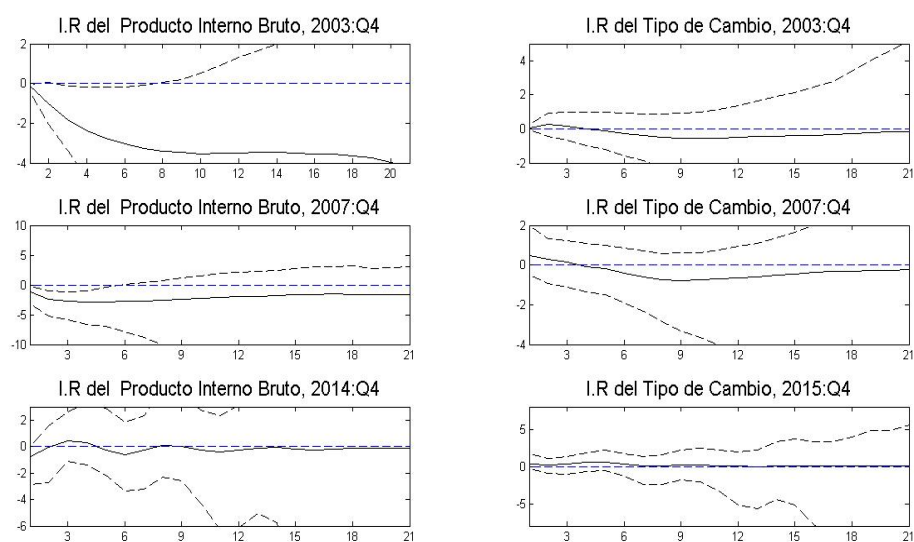


Figura 5.4: Respuesta al impulso dado por el IPC B.

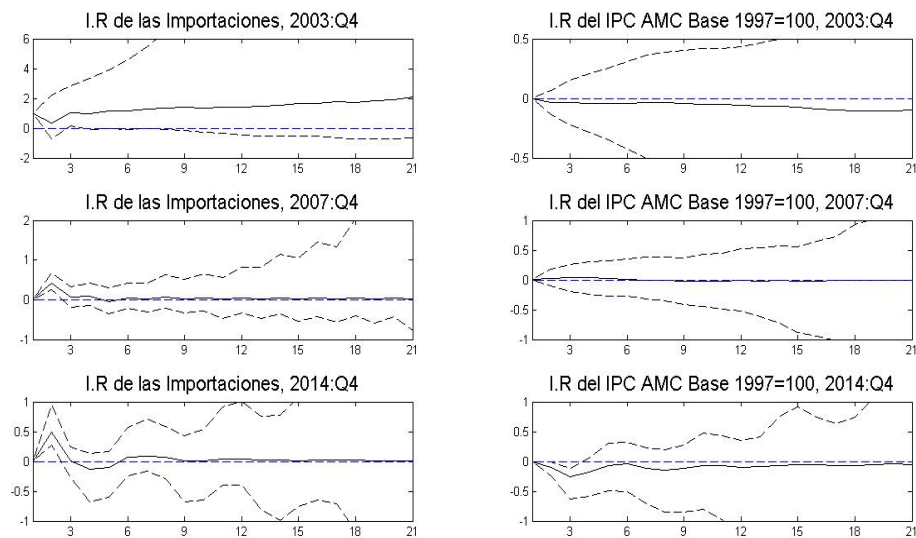


Figura 5.5: Respuesta al impulso dado por el PIB A.

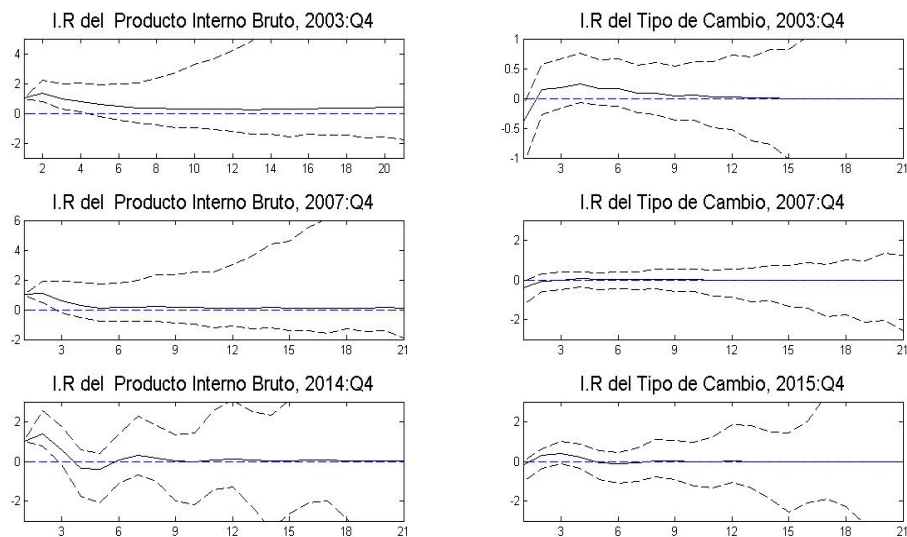


Figura 5.6: Respuesta al impulso dado por el PIB B.

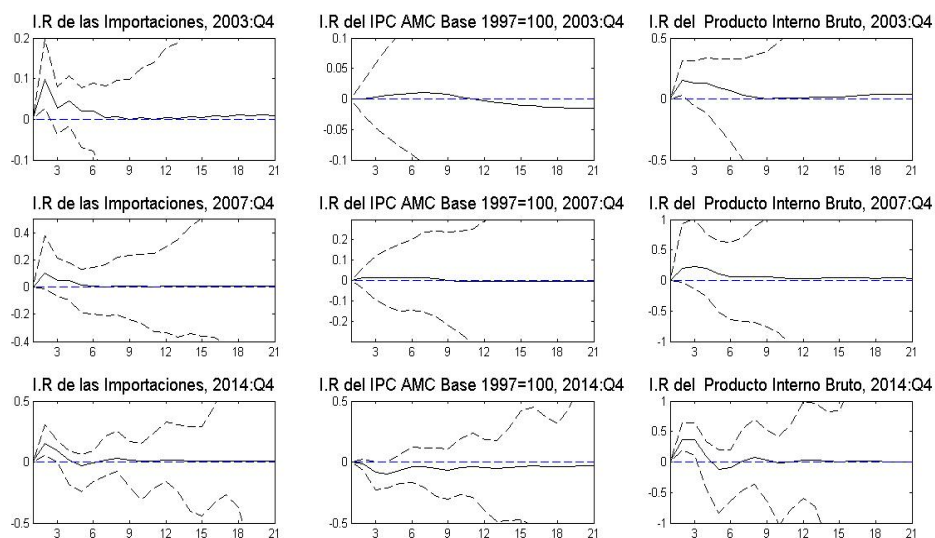


Figura 5.7: Respuesta al impulso dado por la CPV A.

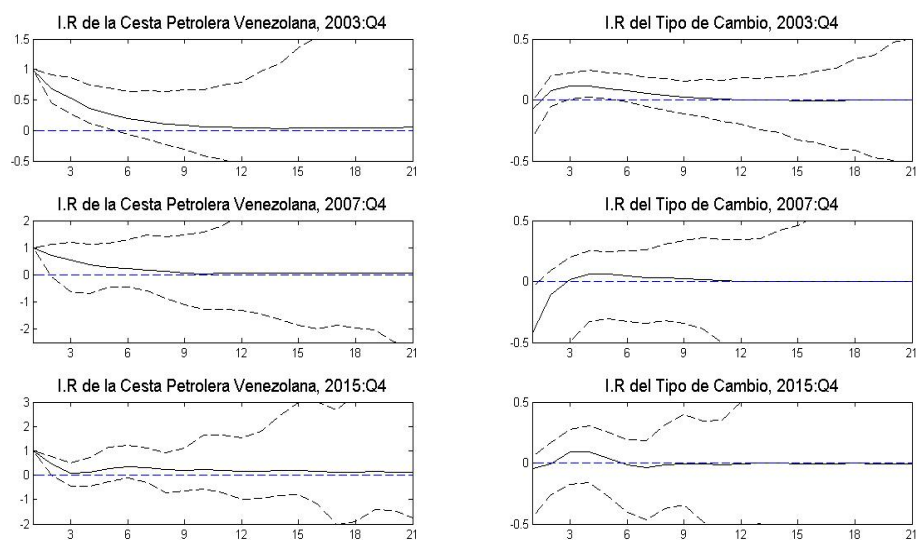


Figura 5.8: Respuesta al impulso dado por la CPV B.




Figura 5.9: Respuesta al impulso dado por la TC A.

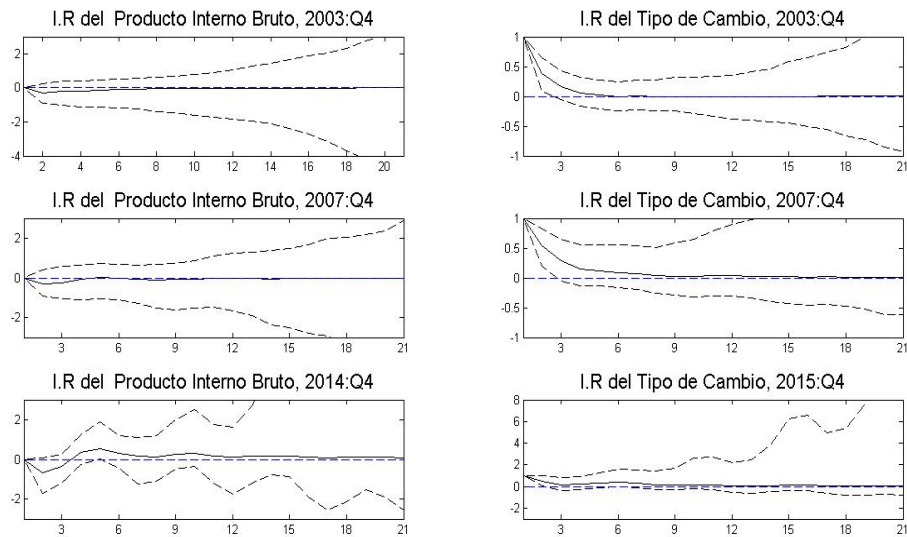


Figura 5.10: Respuesta al impulso dado por la TC B.

REFERENCIAS BIBLIOGRÁFICAS

- [1] BLANCHARD, O. and SIMON, J. (2001), “The Long and Large Decline in U.S. Output Volatility”, in *Brookings Papers on Economic Activity* 1 135–164.
- [2] CARTER, C. K. and KOHN, R. (1994), “On Gibbs Sampling for State Space Models”, *Biometrika*, 81, 541–553.
- [3] COGLEY, T. (2003), “How Fast Can the New Economy Grow? A Bayesian Analysis of the Evolution of Trend Growth” (Mimeo, University of California, Davis).
- [4] COGLEY, T. and SARGENT, T. J. (2003), “Drifts and Volatilities: Monetary Policies and Outcomes in the Post WWII U.S.” (Mimeo, New York University).
- [5] GARY KOOP, “Bayesian Econometrics” University of Glasgow.
- [6] GELMAN, A., CARLIN, J. B., STERN, H. S. and RUBIN, D. B. (1995) *Bayesian Data Analysis* (London: Chapman and Hall).
- [7] GIORGIO E. PRIMICERI (2005), “Time Varying Structural Vector Autoregressions and Monetary Policy” *Review of Economic Studies* (2005) 72, 821–852.
- [8] JAMES DOUGLAS HAMILTON, “Time Series Analysis” Princeton University.
- [9] KIM, S., SHEPHARD, N. and CHIB, S. (1998), “Stochastic Volatility: Likelihood Inference and Comparison with ARCH Models”, *Review of Economic Studies*, 65, 361–393.
- [10] STOCK, J. H. and WATSON, M. W. (2002), “Has the Business Cycle Changed and Why?” (NBER Working Paper No.9127).
- [11] SIMS, C. A. and ZHA, T. (2004), “Were There Regime Switches in US Monetary Policy?” (Mimeo, Princeton University).