

Modelos SparseSVAR como aproximaciones de los mecanismos estructurales de transmisión

Carlos R. Barrera Chaupis



XXIV

Encuentro de

Economistas

15/12/06

D.M.E.



Motivación

D.M.E.

La manera de hacer es ser.

Lao-Tse



- Generación de proyecciones estructurales.
- Reseña de las estrategias de estimación parsimoniosa, en particular aquellos aplicables a modelos Sparse VAR.
- Reseña de estimaciones estructurales a partir de la matriz de covarianzas de un modelo Sparse VAR con dos conjuntos desagregados y un conjunto de variables macroeconómicas.
- Comparación de la precisión *ex post* de las proyecciones de los modelos Sparse SVAR con la de las proyecciones de los modelos Sparse VAR.
- Mecanismos de transmisión y respuestas a impulsos.



Antecedentes

D.M.E.

- Los modelos Sparse VAR “plain vainilla” ha tenido un relativo éxito al elevar la precisión de las proyecciones desagregadas de inflación, como se ha reseñado en trabajos previos (Barrera 2005, 2006A).
- El trabajo por bloques obedece entonces los lineamientos de la escuela de econometría inglesa, del LSE-Oxford, desde las transformaciones a los datos.
- Recientemente se encontró una transformación de los datos del PBI real que ha permitido proyectar la actividad económica con mayor precisión. También para el IPM.
- Siempre estamos conscientes de que el conjunto de información restringida a los desagregados, es insuficiente.



Antecedentes

D.M.E.

- Por lo tanto, para elevar la **precisión de las proyecciones**, era necesario ampliar el conjunto de información mediante un tipo de modelo Sparse VAR “ampliado” que considerara ambos conjuntos de componentes así como un grupo de variables macroeconómicas. Pero el tema de las transformaciones es extremadamente importante.
- Pero esta no era la única razón de este programa de investigación empírica. El objetivo final es determinar la estructura contemporánea y de mediano plazo en la economía.
- Los modelos VAR pueden ser los modelos con mayor potencial para lograrlo una vez que se afinen como una herramienta útil para el contraste de modelos teóricos, especialmente evitando sesgos por un exceso de parámetros estimados para muestras pequeñas.



I. *Introducción*

II. Modelos Sparse VAR para el IPC y el PBI real

III. Modelos *Sparse VAR* con dos conjuntos de componentes y un conjunto de variables macro.

IV. Estimación Estructural en el espacio de estructuras perfectamente identificadas

V. Evaluación *ex post* y respuestas al impulso

VI. Conclusiones



I. Introducción

D.M.E.

- Los modelos Sparse VAR “plain vainilla” incluyen una ecuación que agrega los componentes para obtener las proyecciones del agregado (IPC ó PBI). Esta ecuación es una identidad con parámetros cambiantes en el tiempo.
- Los modelos Sparse VAR “ampliados” contemplan un conjunto de información que incluye: los componentes del IPC, del PBI y un grupo de variables macroeconómicas. Por esta razón, estos modelos deben considerar dos identidades de agregación.
- El objetivo intermedio es incluir más conjuntos desagregados (IPM, exportaciones reales, créditos e inversión sectoriales,...)



- I. *Introducción*
- II. *Modelos Sparse VAR para el IPC y el PBI real*
- III. *Modelos Sparse VAR con dos conjuntos de componentes y un conjunto de variables macro.*
- IV. *Estimación Estructural en el espacio de estructuras perfectamente identificadas*
- V. *Evaluación ex post y respuestas al impulso*
- VI. *Conclusiones*



II. Modelos Sparse VAR -IPC y -PBI D.M.E.

- Los modelos Sparse VAR con 1 conjunto desagregado tienen una estructura dinámica como la del diagrama

$$q_1 = d_1(L)q_1 + e_1(L)q_1^* + \text{dums}$$

$$q_2 = d_2(L)q_2 + e_2(L)q_2^* + \text{dums}$$

$$q_3 = d_3(L)q_3 + e_3(L)q_3^* + \text{dums}$$

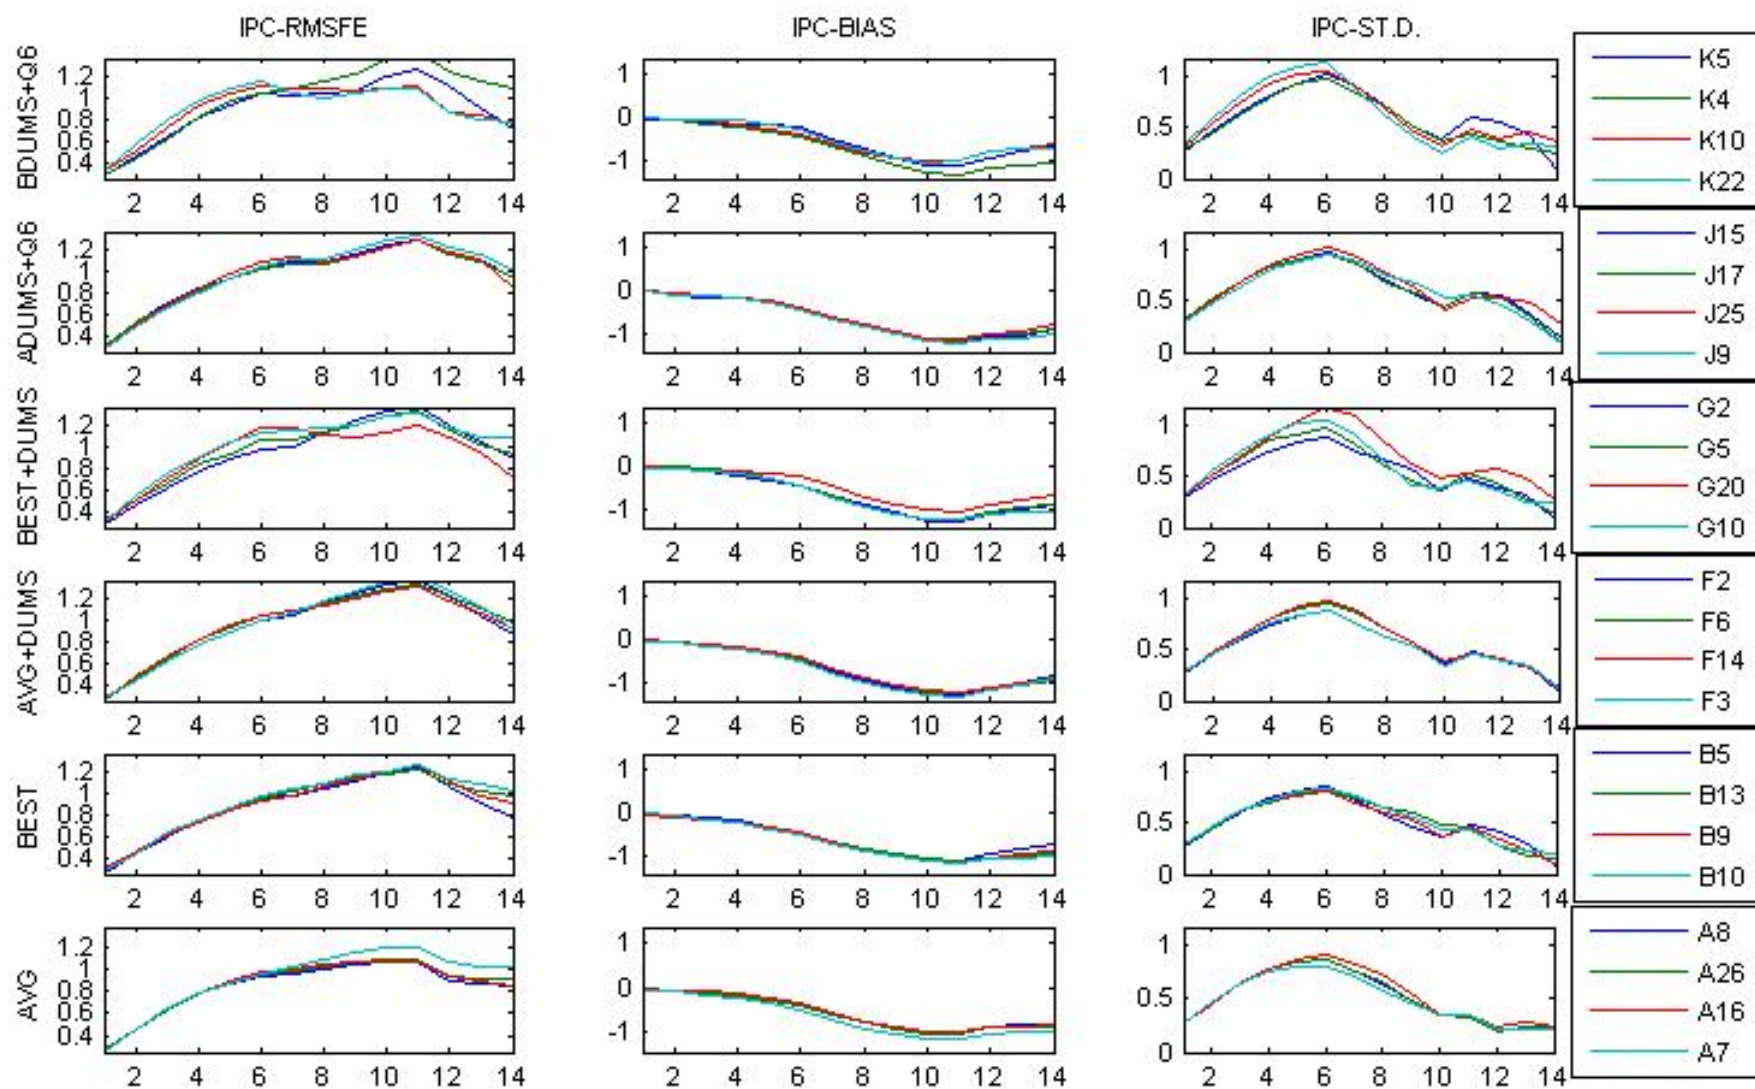
$$q_N = d_N(L)q_N + e_N(L)q_N^* + \text{dums}$$

$$q = (w_1^t q_1) + (w_2^t q_2) + \dots + (w_N^t q_N)$$

$$q_K^* \in \{q, q_1, q_2, q_3, \dots, q_N\} \quad K \in \{1, 2, \dots, N\}$$

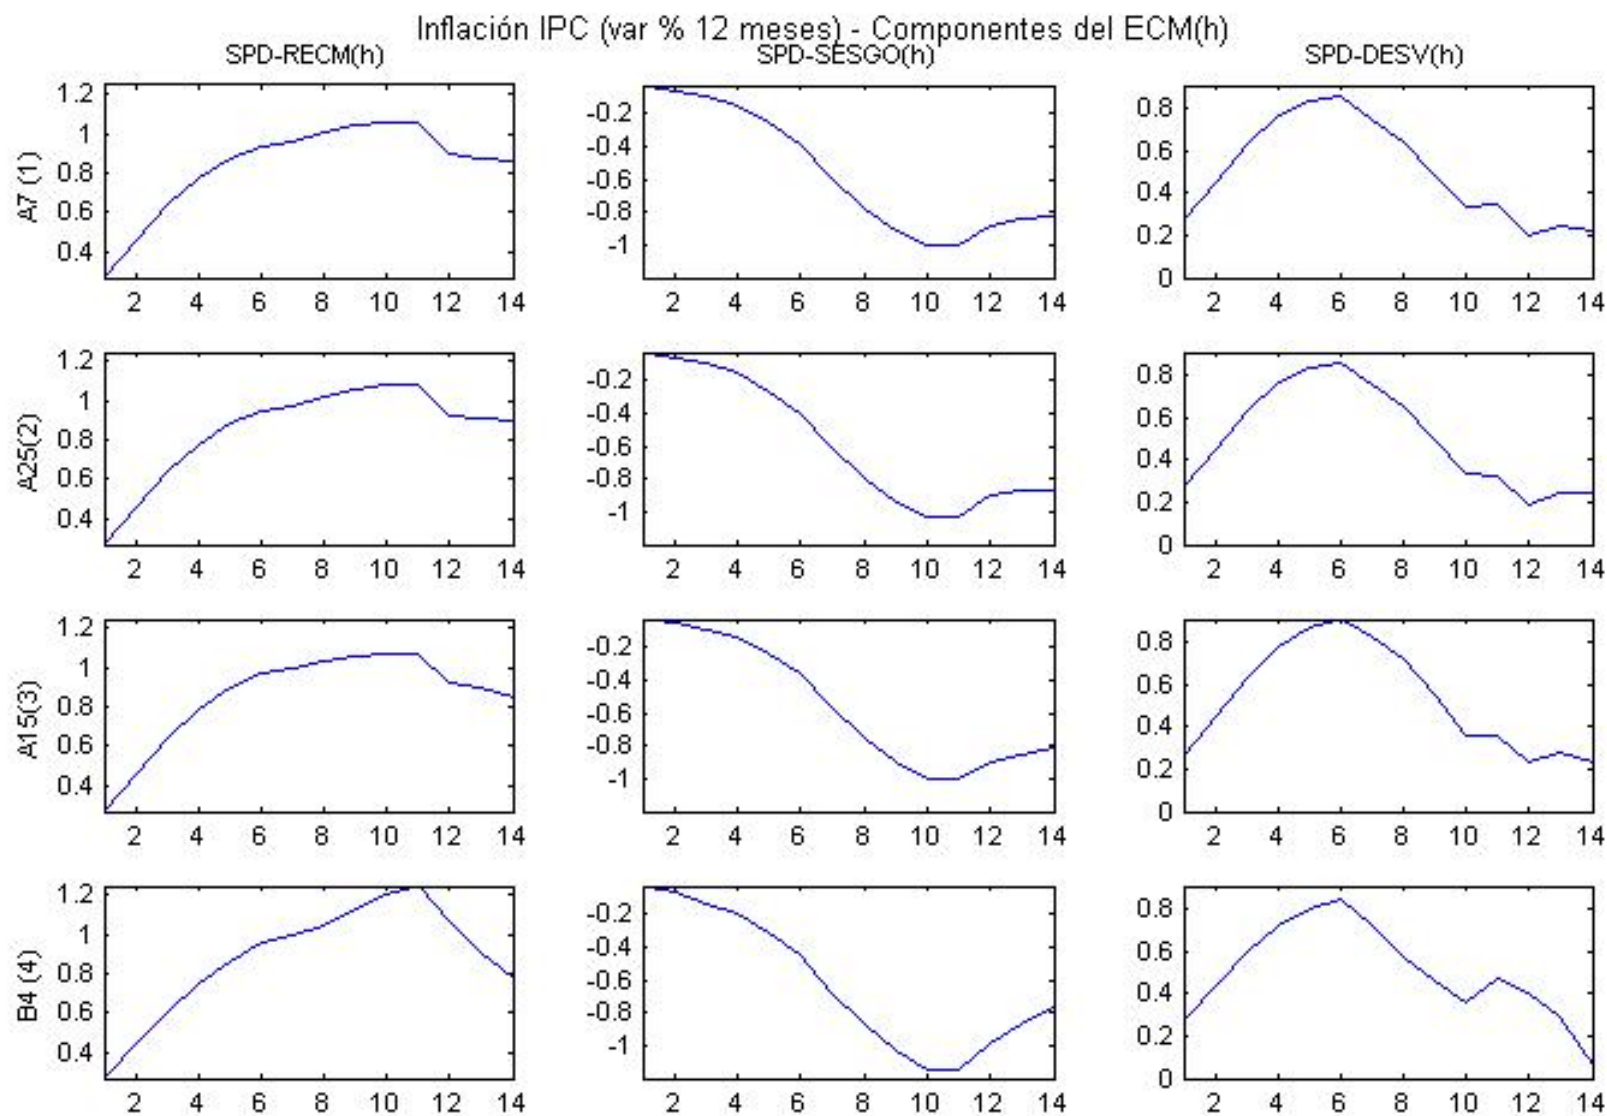


II. Modelos Sparse VAR -IPC y -PBI D.M.E.



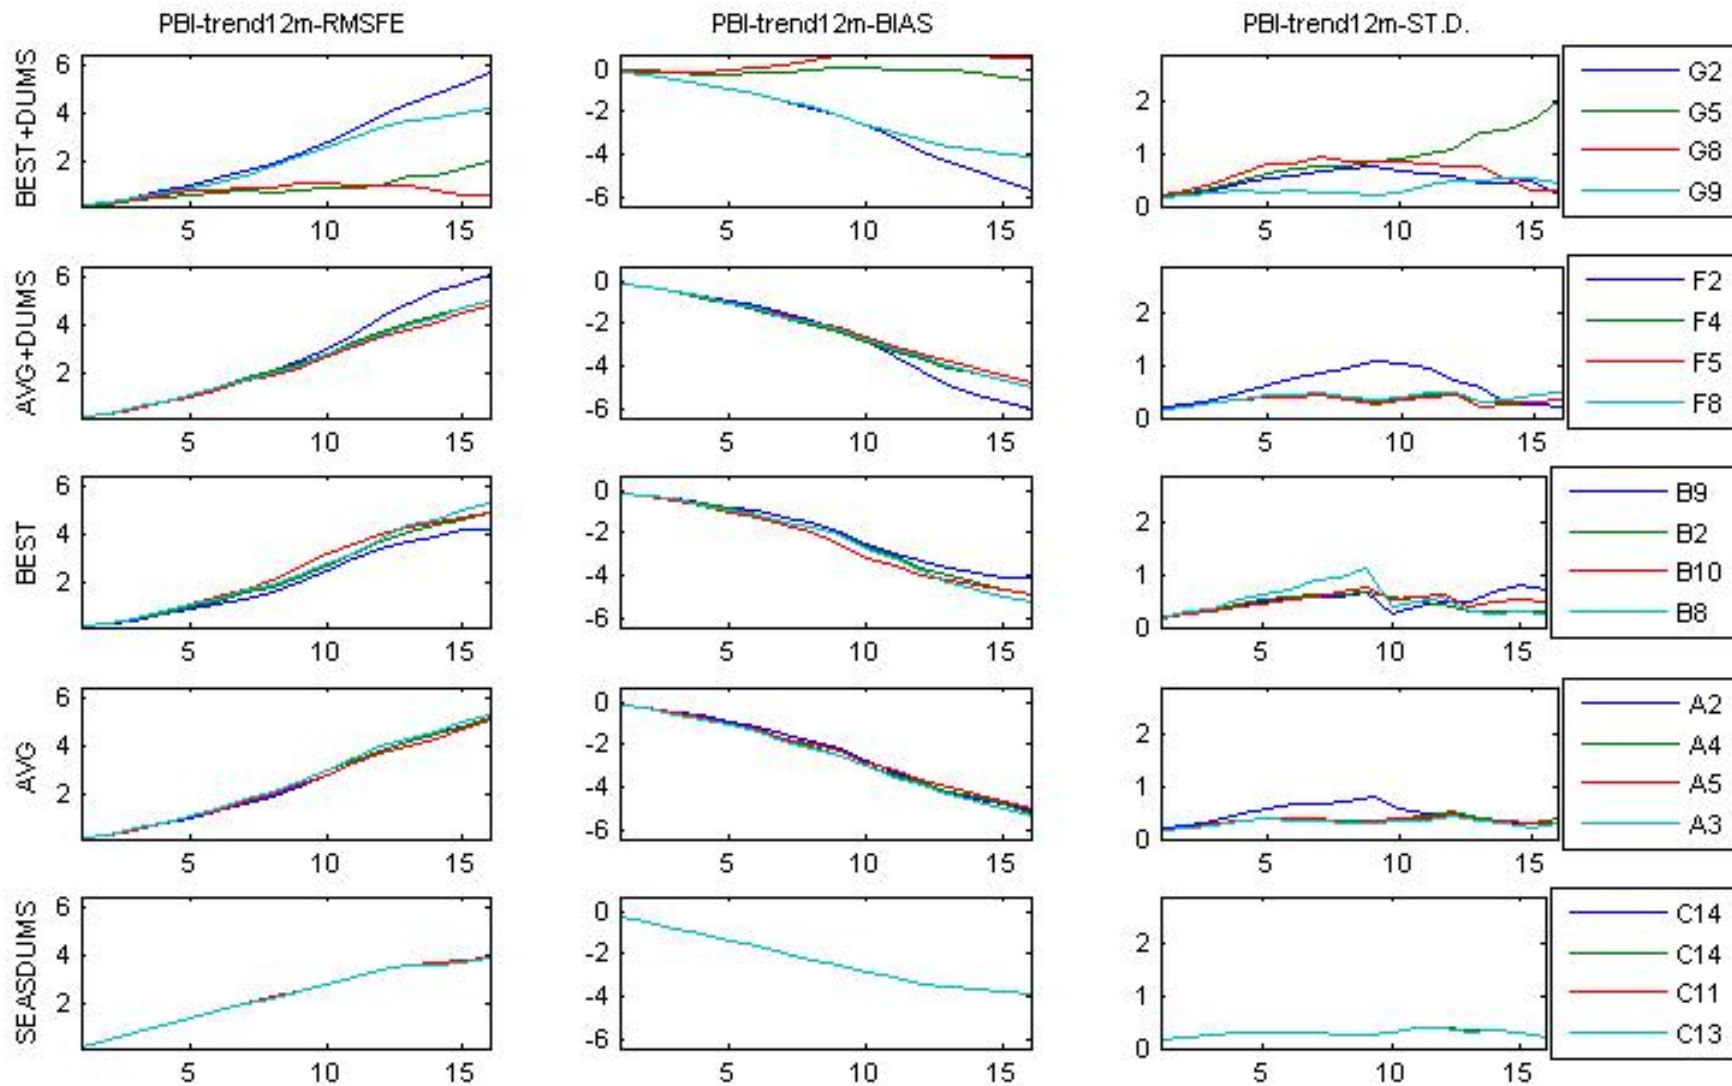


II. Modelos Sparse VAR -IPC y -PBI D.M.E.



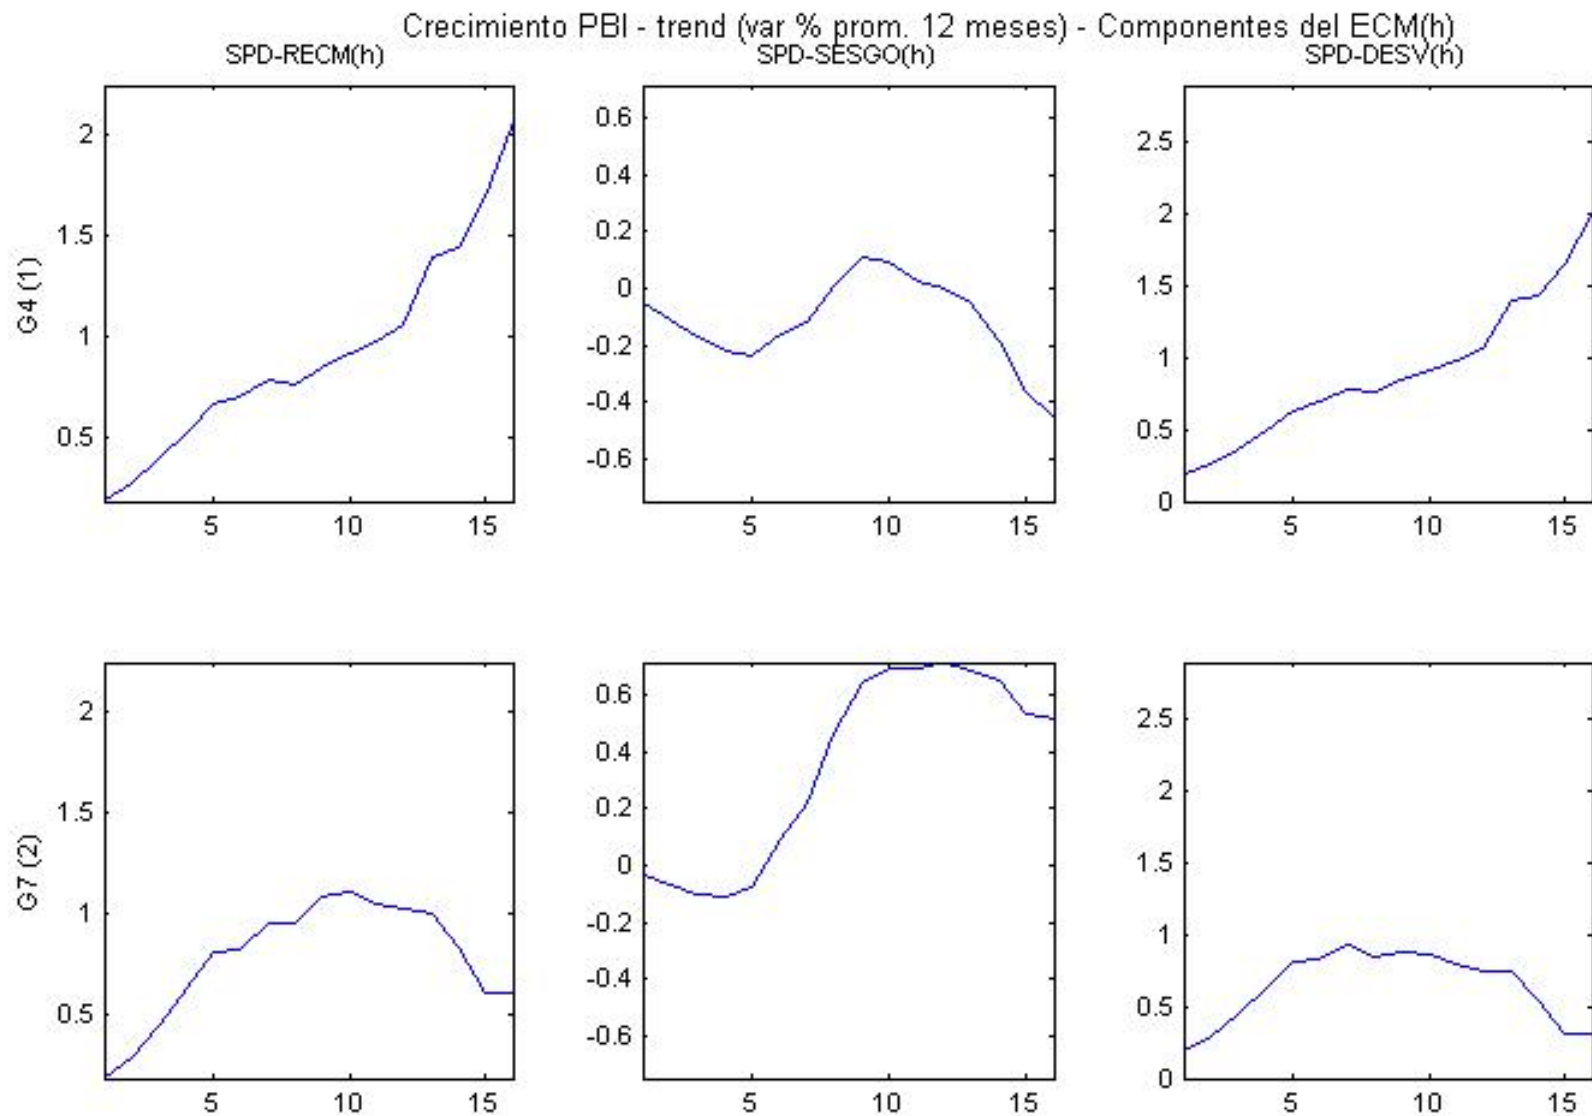


II. Modelos Sparse VAR -IPC y -PBI D.M.E.





II. Modelos Sparse VAR -IPC y -PBI D.M.E.





II. Modelos Sparse VAR -IPC y -PBI **D.M.E.**

- Puede apreciarse que ya se ha logrado una precisión importante en términos de las proyecciones de los agregados IPC y PBI. Sin embargo, resulta evidente que incluir más información puede mejorarla aún más.
- En el caso del PBI, la transformación a los datos ha permitido encontrar grupos de modelos que predigan adecuadamente el agregado para horizontes cortos. La extensión del conjunto de información con variables macroeconómicas puede ser importante para elevar la precisión para horizontes más largos.



Esquema de la presentación

D.M.E.

- I. *Introducción*
- II. *Modelos Sparse VAR para el IPC y el PBI real*
- III. *Modelos Sparse VAR con dos conjuntos de componentes y variables macro.*
- IV. *Estimación Estructural en el espacio de estructuras perfectamente identificadas*
- V. *Evaluación ex post y respuestas al impulso*
- VI. *Conclusiones*



III. Modelos Sparse VAR con 2 conjuntos

D.M.E.

- Los modelos Sparse VAR de 2 conjuntos desagregados tienen una estructura dinámica como la siguiente

$$\begin{aligned} p_1 &= a_1(L)p_1 + b_1(L)p_1^* + c_1(L)q_1^* + g_1(L)x_1 + \text{dums} \\ p_2 &= a_2(L)p_2 + b_2(L)p_2^* + c_2(L)q_2^* + g_2(L)x_2 + \text{dums} \\ p_3 &= a_3(L)p_3 + b_3(L)p_3^* + c_3(L)q_3^* + g_3(L)x_3 + \text{dums} \\ p_M &= a_M(L)p_M + b_M(L)p_M^* + c_M(L)q_N^* + g_M(L)x_Q + \text{dums} \end{aligned}$$

$$p = (v_1^t p_1) + (v_2^t p_2) + \dots + (v_M^t p_M)$$

$$\begin{aligned} q_1 &= d_1(L)q_1 + e_1(L)q_1^* + f_1(L)p_1^* + h_1(L)x_1 + \text{dums} \\ q_2 &= d_2(L)q_2 + e_2(L)q_2^* + f_2(L)p_2^* + h_2(L)x_2 + \text{dums} \\ q_3 &= d_3(L)q_3 + e_3(L)q_3^* + f_3(L)p_3^* + h_3(L)x_3 + \text{dums} \\ q_N &= d_N(L)q_N + e_N(L)q_N^* + f_N(L)p_M^* + h_N(L)x_Q + \text{dums} \end{aligned}$$

$$q = (w_1^t q_1) + (w_2^t q_2) + \dots + (w_N^t q_N)$$

$$\begin{aligned} x_1 &= s_1(x,p,q) + \text{dums} \\ x_2 &= s_2(x,p,q) + \text{dums} \\ x_3 &= s_3(x,p,q) + \text{dums} \\ x_Q &= s_Q(x,p,q) + \text{dums} \end{aligned}$$



III. Modelos Sparse VAR con 2 conjuntos

D.M.E.

- A partir de los resultados obtenidos con los modelos Sparse VAR con 1 conjunto de componentes, para los modelos “ampliados” se eligió una desagregación de 7 rubros para el IPC y una desagregación de 12 sectores para el PBI. El bloque de estos 19 componentes depende del pasado de 11 variables macroeconómicas.
- El bloque de variables macroeconómicas depende del pasado de los dos agregados, mas no del pasado de los componentes asociados. De esta manera la explicación de los agregados incluir los errores idiosincráticos de los componentes correspondientes.



III. Modelos Sparse VAR con 2 conjuntos

D.M.E.

- Las 11 variables macroeconómicas incluidas son:
 - Los precios del petróleo;
 - Los precios de las exportaciones peruanas;
 - La tasa de interés de fondos federales de la Reserva Federal;
 - El índice de producción manufacturera de los EE.UU.;
 - El índice subyacente de precios de los EE.UU.;
 - El valor de las exportaciones peruanas;
 - La tasa de interés interbancaria overnight en soles;
 - La emisión primaria;
 - El ripo de cambio (soles por US\$);
 - La demanda interna; y
 - El índice de empleo en el sector manufactura.



III. Modelos Sparse VAR con 2 conjuntos

D.M.E.

- Todas estas variables mensuales se incluyen como variaciones porcentuales promedio 12 meses, una transformación de los datos promedio de cada mes que permite elevar su idoneidad estadística y modelar las tendencias locales en su interior.
- Esta transformación es la misma que brinda los resultados positivos en predicción ya mencionados para el modelo Sparse VAR con los componentes del PBI. Sin embargo, las unidades de los componentes del IPC siguen siendo variaciones porcentuales mensuales, lo que es consistente con los resultados teóricos del Doctor Gabriel Rodríguez.



III. Modelos Sparse VAR con 2 conjuntos

D.M.E.

- Las pruebas individuales de estacionariedad son redundantes debido a que todos los sistemas VAR parciales utilizados corresponden a los modelos con el menor MSFE($h=12$), por lo que se incluye únicamente los más precisos y estables.
- Sin embargo, se dispone de una batería de pruebas estadísticas para evaluar el vector de errores no estructurales estimados: la prueba de ausencia de correlación serial (Portmanteau) y la prueba de normalidad (Jarque-Bera).



III. Modelos Sparse VAR con 2 conjuntos

D.M.E.

CONSTRAINED VAR PORTMANTEAU TEST [130 obs,efec,13 rezagos]

Ho: Autocorrelaciones de errores [R1,R2,...,R13]=0

Pbar ~ Chi²[586gl] Pbarcalc= 607.6785 Pvalue= 0.25946

MULTIVARIATE JARQUE&BERA TEST [7 variables]

H1o: $E[v^3]=0$

mL1 ~ Chi²[7gl] mL1 = 8.7373 Pvalue= 0.27207

H2o: $E[v^4]=3$

mL2 ~ Chi²[7gl] mL2 = 60.7869 Pvalue= 1.0511e-010

Ho: Normalidad Multivariada { $E[v^3]=0$ & $E[v^4]=3$ }

mJB ~ Chi²[14gl] mJB = 69.5242 Pvalue= 2.3534e-009

->Puede rechazar Ho. Los errores no son normales!



III. Modelos Sparse VAR con 2 conjuntos

D.M.E.

CONSTRAINED VAR PORTMANTEAU TEST [130 obs,efec,13 rezagos]

Ho: Autocorrelaciones de errores [R1,R2,...,R13]=0

Pbar ~ Chi²[1778gl] Pbarcalc= 2072.9955 Pvalue= 1.25e-006

->Puede rechazar Ho. Los errores no son ruido blanco!

MULTIVARIATE JARQUE&BERA TEST [12 variables]

H1o: $E[v^3]=0$

mL1 ~ Chi²[12gl] mL1 = 2.0131 Pvalue= 0.99939

H2o: $E[v^4]=3$

mL2 ~ Chi²[12gl] mL2 = 6.0231 Pvalue= 0.91491

Ho: Normalidad Multivariada { $E[v^3]=0$ & $E[v^4]=3$ }

mJB ~ Chi²[24gl] mJB = 8.0362 Pvalue= 0.99905



III. Modelos Sparse VAR con 2 conjuntos

D.M.E.

- -----
- CONSTRAINED VAR PORTMANTEAU TEST [130 obs,efec,13 rezagos]
- Ho: Autocorrelaciones de errores [R1,R2,...,R13]=0
- $P_{bar} \sim \text{Chi}^2[1573gl]$ $P_{barcalc} = 1760.9618$ $P_{value} = 0.00060183$
- ->Puede rechazar Ho. Los errores no son ruido blanco!
- -----
- MULTIVARIATE JARQUE&BERA TEST [11 variables]
- $H_{1o}: E[v^3] = 0$
- $mL1 \sim \text{Chi}^2[11gl]$ $mL1 = 4.4096$ $P_{value} = 0.95637$
- $H_{2o}: E[v^4] = 3$
- $mL2 \sim \text{Chi}^2[11gl]$ $mL2 = 7.7551$ $P_{value} = 0.73506$
- Ho: Normalidad Multivariada $\{E[v^3] = 0 \ \& \ E[v^4] = 3\}$
- $mJB \sim \text{Chi}^2[22gl]$ $mJB = 12.1648$ $P_{value} = 0.95388$



Esquema de la presentación

D.M.E.

- I. *Introducción*
- II. *Modelos Sparse VAR para el IPC y el PBI real*
- III. *Modelos Sparse VAR con dos conjuntos de componentes y variables macro.*
- IV. *Estimación Estructural en el espacio de estructuras perfectamente identificadas*
- V. *Evaluación ex post y respuestas al impulso*
- VI. *Conclusiones*



IV. Estimaciones Estructurales

D.M.E.

- Sobre la base de estos modelos se obtiene un estimado robusto de la matriz de covarianzas de los errores no estructurales. Estas matrices estimadas son poco sensibles a la presencia de “outliers”, por lo que resultan apropiadas para la búsqueda de descomposiciones estructurales.
- Sin embargo, no se impondrá una estructura particular a los datos. Más bien los datos informarán sobre la estructura contemporánea más adecuada, de un conjunto amplio de posibilidades.



IV. Estimaciones Estructurales

D.M.E.

- Por ejemplo, el número de modelos estructurales exactamente identificados y sin que el economista teórico imponga restricciones de exogeneidad en un modelo VAR con 7 variables es aproximadamente 2,1 millones. A partir de todas estas estructuras es factible determinar aquellas que maximizan la función correspondiente de verosimilitud (si los modelos son exactamente identificados).
- En el VAR que hemos obtenido se tiene 30 variables, por lo que requerimos imponer restricciones de exogeneidad contemporáneas y mantenernos en el universo de modelos estructurales perfectamente identificados. Las matrices de la representación A- B de Amisano & Giannini se presentan a continuación:



IV. Estimaciones Estructurales

D.M.E.

K	$K(K-1)/2$	$K(K-1)/2$	$2^{K(K-1)/2}$
1	0	1	2
2	1	2	4
3	3	3	8
4	6	4	16
5	10	5	32
6	15	6	64
7	21	7	128
9	36	9	512
10	45	10	1024
11	55	11	2048
12	66	12	4096
20	190	20	1048576
21	210	21	2097152
22	231	22	4194304
		53	9.0072E+15
		54	1.80144E+16
		55	3.60288E+16



IV. Estimaciones Estructurales

D.M.E.

Estructura A-B: Matriz A

	u(oil)	u(px)	u(i*)	u(y*)	u(p*)	u(x)	u(i)	u(m0)	u(fx)	u(dem)	u(lab)	
e(oil)	1											
e(px)	-0.1110 (0.0031)	1										
e(i*)	-0.0011 (0.0002)	-0.0020 (0.0004)	1									
e(y*)	-0.0005 (0.0006)	-0.0048 (0.0014)	-0.7486 (0.0273)	1								
e(p*)	0.0000 (0.0001)	-0.0010 (0.0002)	-0.0600 (0.0044)	-0.0026 (0.0012)	1							
e(x)	0.0109 (0.0070)	-0.3761 (0.0169)	-2.4544 (0.3504)	2.9217 (0.0962)	7.1593 (0.6041)	1						
e(i)	0.0036 (0.0025)	0.0530 (0.0058)	-0.0652 (0.1191)	-0.8804 (0.0341)	-0.1195 (0.2077)	-0.0087 (0.0027)	1	0.0043 (0.0126)	-0.1632 (0.0204)	0.0885 (0.0063)		
e(m0)	0.0334 (0.0015)	-0.0498 (0.0036)	0.5398 (0.0747)	-0.4295 (0.0209)	-0.8018 (0.1297)	-0.0293 (0.0017)		1	0.0547 (0.0126)		-0.5821 (0.0155)	
e(fx)	-0.0176 (0.0009)	-0.0068 (0.0022)	0.3126 (0.0457)	0.0466 (0.0128)	-1.4072 (0.0787)	-0.0245 (0.0010)			1		0.0192 (0.0095)	
e(dem)	0.0279 (0.0030)	0.0339 (0.0072)	1.1469 (0.1458)	-0.7164 (0.0415)	0.4556 (0.2546)	0.0535 (0.0033)		-0.4296 (0.0150)	-0.5256 (0.0250)	1		
e(lab)	0.0154 (0.0007)	-0.0034 (0.0018)	-0.5994 (0.0371)	0.0503 (0.0108)	-0.6493 (0.0639)	0.0034 (0.0008)	-0.0013 (0.0025)				-0.0390 (0.0020)	1

* Los números en paréntesis indican las desviaciones estándar de los estimados.

Estructura A-B: Matriz diagonal B

				u(oil)	0.00682 (0.00004)
u(p1)	0.00108 (0.00001)	u(q3)	0.01939 (0.00011)	u(px)	0.00273 (0.00001)
u(p2)	0.01526 (0.00008)	u(q4)	0.00384 (0.00002)	u(i*)	0.00014 (0.00000)
u(p3)	0.01053 (0.00006)	u(q5)	0.00356 (0.00002)	u(y*)	0.00048 (0.00000)
u(p4)	0.00887 (0.00005)	u(q6)	0.00546 (0.00003)	u(p*)	0.00008 (0.00000)
u(p5)	0.00340 (0.00002)	u(q7)	0.00259 (0.00001)	u(x)	0.00599 (0.00003)
u(p6)	0.00615 (0.00003)	u(q8)	0.00454 (0.00002)	u(i)	0.00203 (0.00001)
u(p7)	0.01388 (0.00008)	u(q9)	0.00275 (0.00001)	u(m0)	0.00127 (0.00001)
		u(q10)	0.00151 (0.00001)	u(fx)	0.00078 (0.00000)
u(q1)	0.00440 (0.00002)	u(q11)	0.00241 (0.00001)	u(dem)	0.00249 (0.00001)
u(q2)	0.00136 (0.00001)	u(q12)	0.00394 (0.00002)	u(lab)	0.00063 (0.00000)

* Los números en paréntesis indican las desviaciones estándar de los estimados.



IV. Estimaciones Estructurales

Estructura A-B: Matriz A

D.M.E.

	u(oil)	u(px)	u(i*)	u(y*)	u(p*)	u(x)
e(oil)	1					
e(px)	-0.1110 (0.0031)	1				
e(i*)	-0.0011 (0.0002)	-0.0020 (0.0004)	1			
e(y*)	-0.0005 (0.0006)	-0.0048 (0.0014)	-0.7486 (0.0273)	1		
e(p*)	0.0000 (0.0001)	-0.0010 (0.0002)	-0.0600 (0.0044)	-0.0026 (0.0012)	1	
e(x)	0.0109 (0.0070)	-0.3761 (0.0169)	-2.4544 (0.3504)	2.9217 (0.0962)	7.1593 (0.6041)	1

* Los números en paréntesis indican las desviaciones estándar de los



IV. Estimaciones Estructurales

D.M.E.

Estructura A-B: Matriz A (cont.)

	u(oil)	u(px)	u(i*)	u(y*)	u(p*)	u(x)	u(i)	u(m0)	u(fx)	u(dem)	u(lab)
e(i)	0.0036 (0.0025)	0.0530 (0.0058)	-0.0652 (0.1191)	-0.8804 (0.0341)	-0.1195 (0.2077)	-0.0087 (0.0027)	1	0.0043 (0.0126)	-0.1632 (0.0204)	0.0885 (0.0063)	
(m0)	0.0334 (0.0015)	-0.0498 (0.0036)	0.5398 (0.0747)	-0.4295 (0.0209)	-0.8018 (0.1297)	-0.0293 (0.0017)		1	0.0547 (0.0126)		-0.582 (0.0155)
e(fx)	-0.0176 (0.0009)	-0.0068 (0.0022)	0.3126 (0.0457)	0.0466 (0.0128)	-1.4072 (0.0787)	-0.0245 (0.0010)			1		0.0192 (0.0095)
dem)	0.0279 (0.0030)	0.0339 (0.0072)	1.1469 (0.1458)	-0.7164 (0.0415)	0.4556 (0.2546)	0.0535 (0.0033)		-0.4296 (0.0150)	-0.5256 (0.0250)	1	
(lab)	0.0154 (0.0007)	-0.0034 (0.0018)	-0.5994 (0.0371)	0.0503 (0.0108)	-0.6493 (0.0639)	0.0034 (0.0008)	-0.0013 (0.0025)			-0.0390 (0.0020)	1

Los números en paréntesis indican las desviaciones estándar de los estimados.



Esquema de la presentación

D.M.E.

- I. *Introducción*
- II. *Modelos Sparse VAR para el IPC y el PBI real*
- III. *Modelos Sparse VAR con dos conjuntos de componentes y variables macro.*
- IV. *Estimación Estructural en el espacio de estructuras perfectamente identificadas*
- V. *Evaluación ex post y respuestas al impulso*
- VI. **Conclusiones**



VI. Conclusiones

D.M.E.

- Los modelos Sparse VAR permiten solucionar el problema de variables omitidas mediante la inclusión de más variables en el conjunto de información sin efectos sobre la parsimonia de los sistemas VAR obtenidos.
- Los **modelos Sparse VAR estructurales** pueden obtenerse mediante una metodología econométrica progresiva que es análoga a la metodología “de lo general a lo particular”, donde el criterio de “pérdida de información” se refiera a la información para fines predictivos y no en referencia directa a los parámetros de interés (estructura contemporánea).



VI. Conclusiones

D.M.E.

- Las ventajas de este enfoque progresivo son:
 - Puede asegurarse que el modelo Sparse VAR estructural podrá explicar el pasado y predecir el futuro.
 - Tan pronto como una variable no sea predicha con la precisión deseada, el modelador puede añadir variables informativas que serán auto-generadas en un sistema mayor pero sin pérdidas de parsimonia ni grados de libertad.



VI. Conclusiones

D.M.E.

- Los errores idiosincráticos de los componentes de cada agregado pueden permitir la explicación de comportamientos alejados de las proyecciones y simulaciones del modelo mediante “identidades de agregación” que a su vez influyen en el bloque de variables que se asocian a factores macroeconómicos.
- Sin embargo, la evaluación de la capacidad para influir los agregados mediante simulaciones de política requiere el condicionamiento respecto de los precios relativos y los tamaños relativos de los diversos sectores productivos, los cuales son funciones no lineales de las variables incluidas en los sistemas Sparse SVAR.




No podemos construir una ciencia más certera con nuestros deseos u opiniones, pero obviamente puede que estemos construyéndola menos certera en su aplicación, si creemos que es lo que no es.

T. Robert Malthus

Modelos SparseSVAR como aproximaciones de los mecanismos estructurales de transmisión

XXIV
Encuentro de
Economistas
15/12/06



D.M.E.

Carlos R. Barrera Chaupis