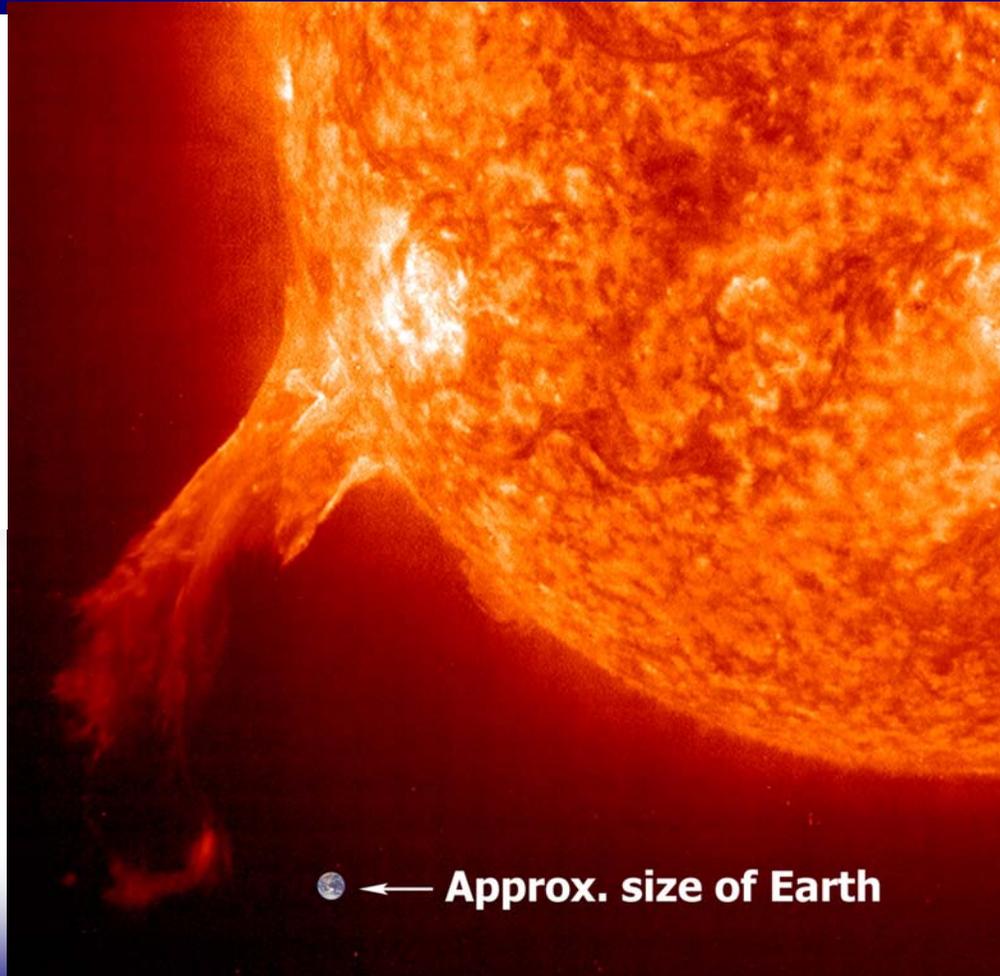


PROYECCIONES DE INFLACIÓN CON MODELOS SPARSE VAR ROBUSTOS

XXIV
Encuentro de
Economistas
14/12/06



D.M.E.

Carlos R. Barrera Chaupis



Antecedentes

D.M.E.

- Éxito de los modelos Sparse VAR “plain vainilla” al elevar la precisión de las proyecciones de inflación (Barrera 2005, 2006A).
- Su característica principal: **información desagregada**.
- Sin embargo, 2 problemas:
 - “observaciones fuera del patrón capturado” afecta eventualmente la precisión de las proyecciones (HOY)
 - potenciales problemas de **especificación** (MAÑANA)
- Se ha cuantificado la sensibilidad de los modelos Sparse VAR “plain vainilla” mediante cambios en el nivel de sus RMSFE(h),

$$h \in \{1, 3, 6, 9\}$$



Motivación

D.M.E.

- Generar proyecciones “robustas”, es decir, relativamente menos sensibles a la presencia de “observaciones fuera del patrón capturado” por los modelos.
- Reseña introductoria de las estrategias de estimación robusta o procedimientos robustos, en particular para facilitar aquellos aplicables para el caso de modelos Sparse VAR.
- Comparación de la precisión *ex post* de las proyecciones de los modelos Sparse VAR “robustos” con la de las proyecciones de los modelos Sparse VAR “plain vainilla”.



Esquema de la presentación

D.M.E.

- I. *Introducción*
- II. Estimadores robustos
- III. Estimación de modelos *Sparse* VAR robustos
- IV. Sensibilidad de proyecciones robustas
- V. Evaluación *ex post*
- VI. Conclusiones



I. Introducción

D.M.E.

- Para medir la **sensibilidad** de los modelos Sparse VAR “plain vainilla” ante la presencia de “outliers” se usó el cambio en las secuencias de RECM(h), $h \in \{1, 3, 6, 9\}$
- Para ello se calcularon secuencias de evaluaciones *ex post*, secuencias de RECM(h), todas con un mismo número de errores de proyección ejecutados.
- En los gráficos de “evolución” del RECM, la **unidad común de medida** es siempre la variación porcentual 12 meses del IPC para todos los 4 tipos de modelos considerados. Nótese también que estos RECM(h) corresponden a los **promedios de los mejores modelos** en cada tipo.

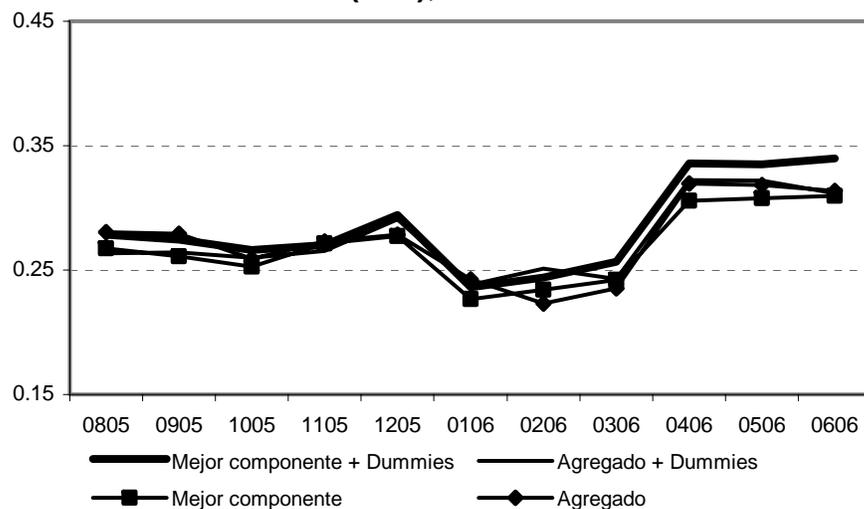


I. Introducción

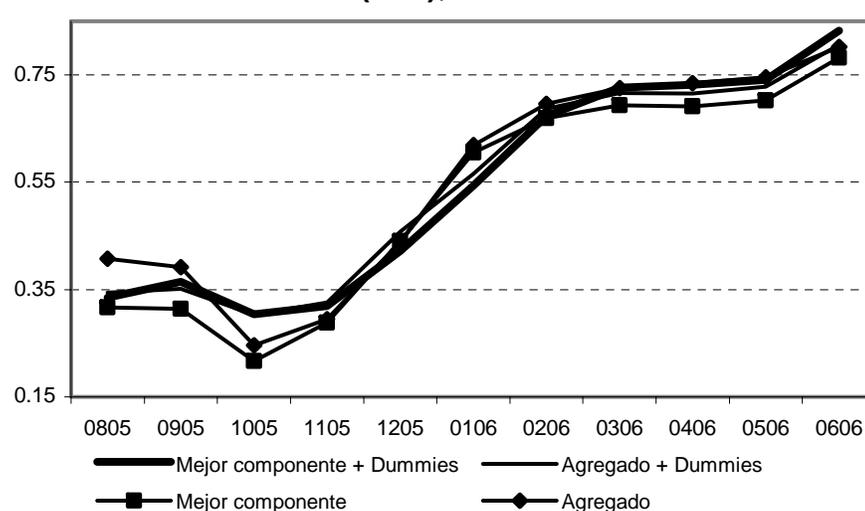
D.M.E.

Inflación IPC

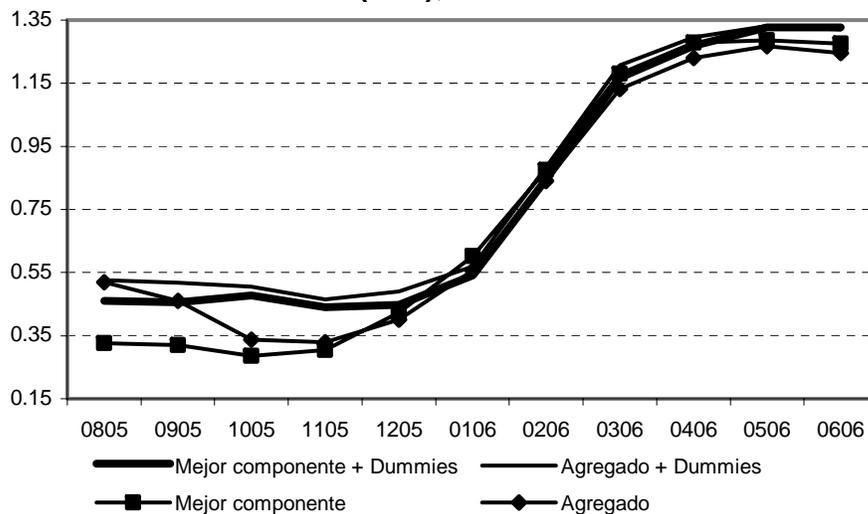
RECM(h=1), v.m. 11 obs.



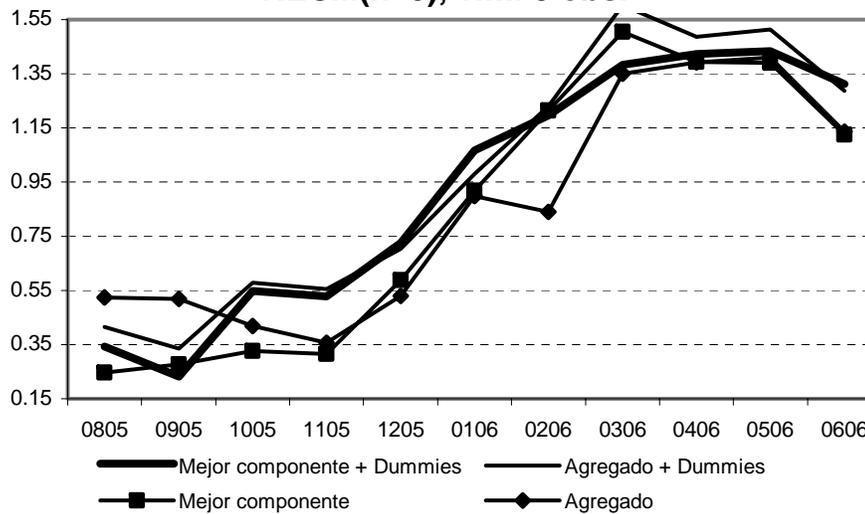
RECM(h=3), v.m. 9 obs.



RECM(h=6), v.m. 6 obs.



RECM(h=9), v.m. 3 obs.





I. Introducción

D.M.E.

- Entonces, aunque los niveles de precisión mejoraron sobremanera hacia los primeros 9 meses del 2005, **alrededor de noviembre del 2005** se inició una secuencia de “outliers” que continuó hasta poco después de abril del 2006. Este inicio de la secuencia es más claro observando el RECM($h=3$).
- Los niveles promedio de precisión RECM(h) alcanzados por estas proyecciones hasta octubre 2005 fueron de **0.26** (0.15) para $h=1$, **0.30** (0.25) para $h=3$, **0.42** para $h=6$ y **0.37** para $h=9$. Hacia el final de la secuencia de “outliers”, estos niveles aumentaron en 27, 150, 210 y 292 por ciento respectivamente, lo que muestra una elevada sensibilidad de las proyecciones y de los estimados para los modelos Sparse VAR “plain vainilla”.

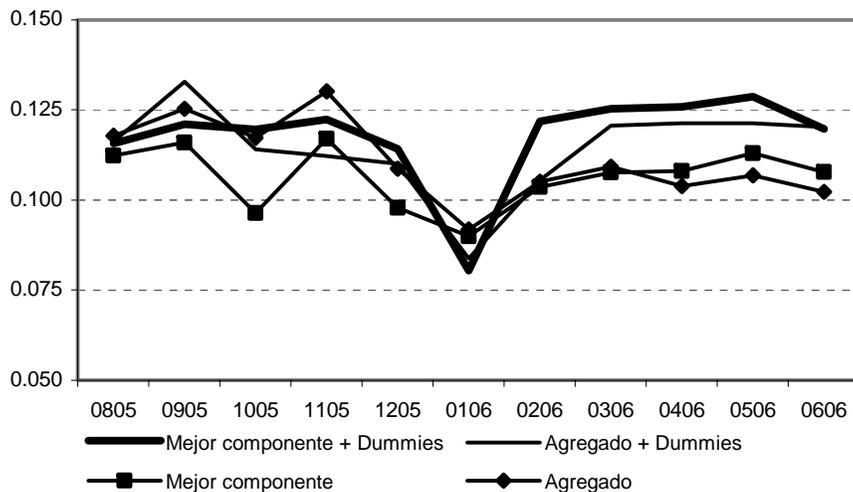


I. Introducción

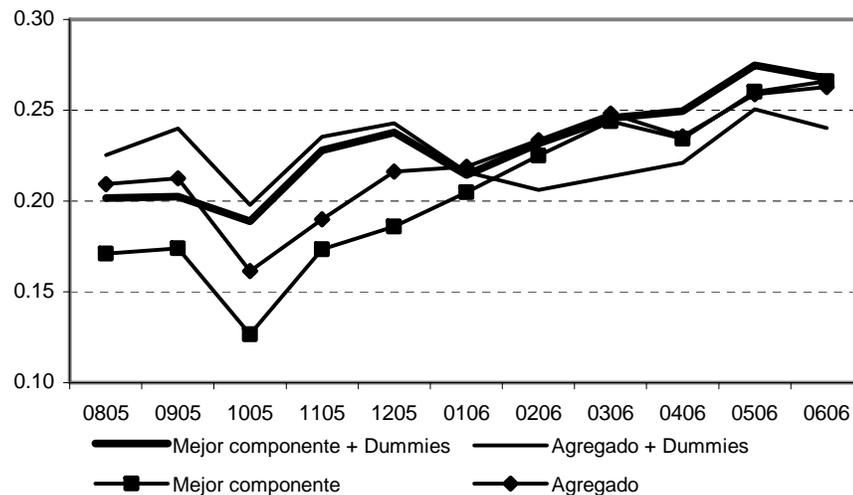
D.M.E.

Inflación Subyacente IPC

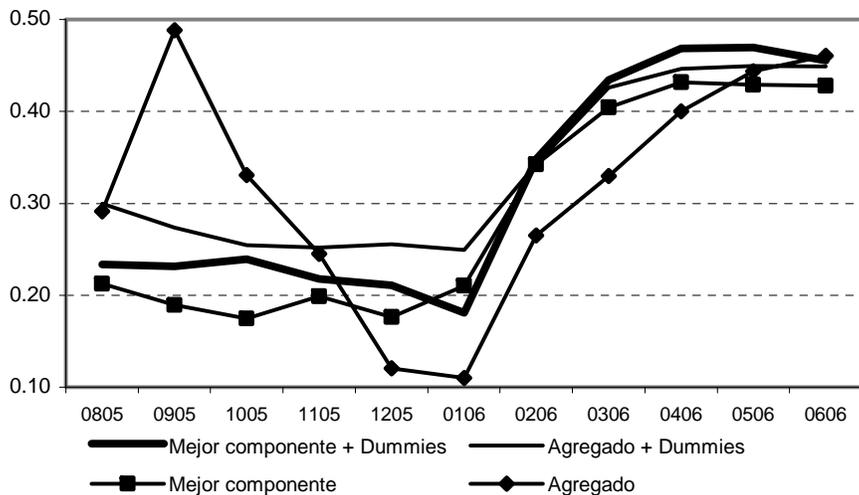
RECM(h=1), v.m. 11 obs.



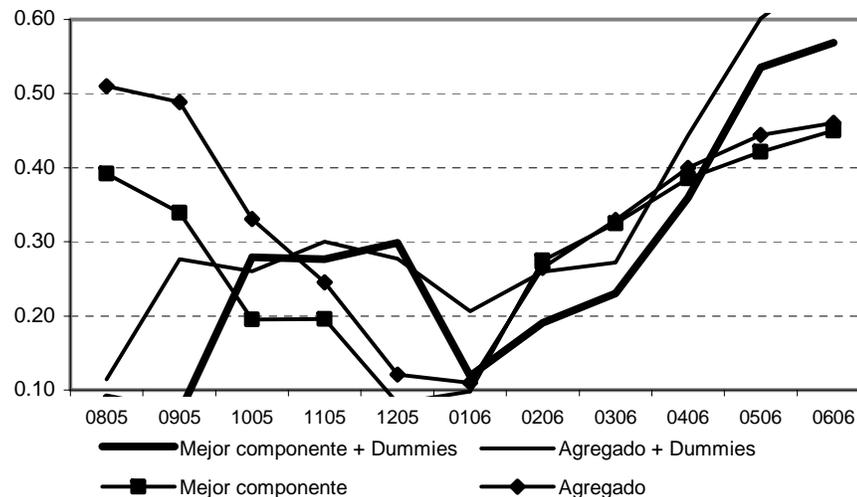
RECM(h=3), v.m. 9 obs.



RECM(h=6), v.m. 6 obs.



RECM(h=9), v.m. 3 obs.





I. Introducción

D.M.E.

- Los niveles de precisión de las proyecciones de inflación subyacente no se deterioraron demasiado a partir de **noviembre del 2005**. En la versión previa de esta presentación, se confirmaba esta fecha para el inicio de la secuencia de “outliers” para $h=1$ y $h=3$; en la presente, esa fecha se confirma sólo para $h=3$, pero $h=1$, $h=6$ y $h=9$ indican **febrero del 2006**.
- Previamente, los niveles de precisión alcanzados eran de **0.08** para $h=1$ y **0.175** para $h=3$, los que se duplicaron al final de la secuencia. Ahora se prefiere usar **rangos de precisión**, donde se percibe una “V” en el rango 0.100-0.125 para $h=1$, pasan de 0.15-0.25 a 0.20-0.27 para $h=3$, de 0.2-0.3 a 0.4-0.5 para $h=6$, mientras que para $h=9$, se percibe una “V” en el rango 0.1-0.5. **Febrero 2006 es la fecha de quiebre excepto en $h=3$.**

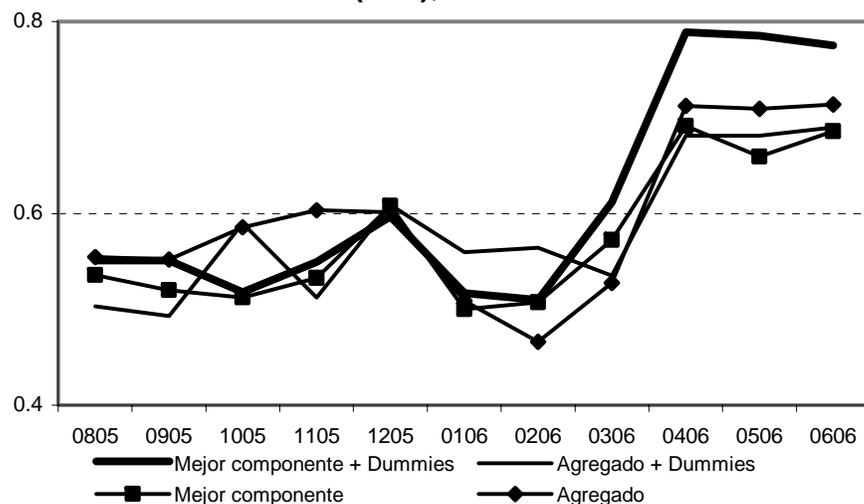


I. Introducción

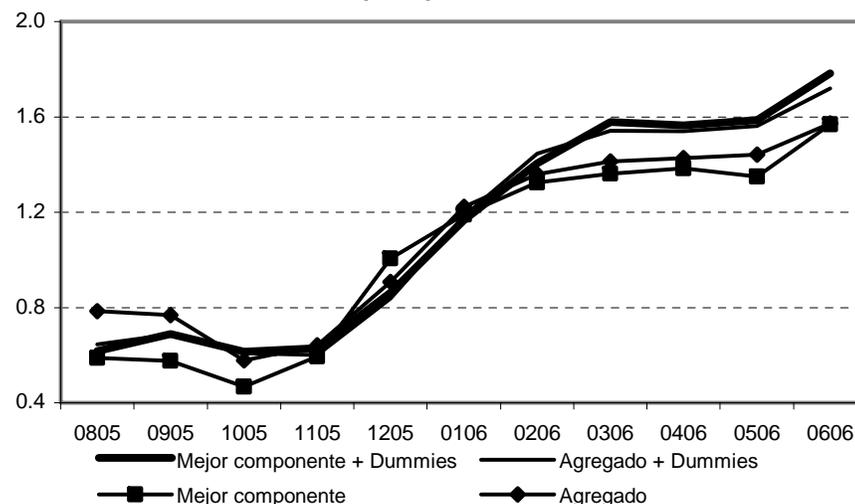
D.M.E.

Inflación No Subyacente IPC

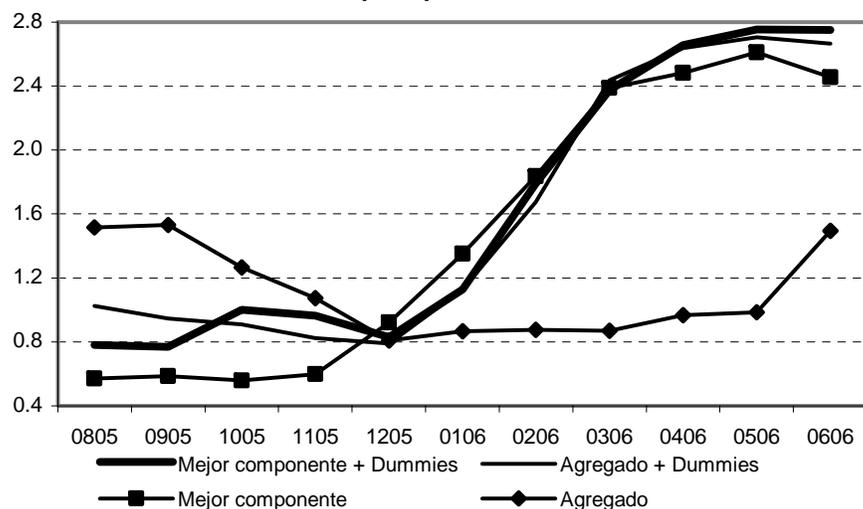
RECM(h=1), v.m. 11 obs.



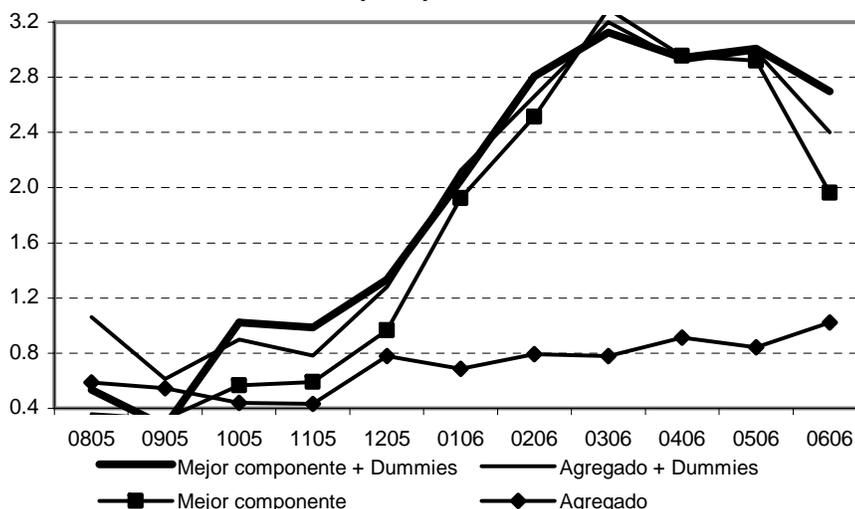
RECM(h=3), v.m. 9 obs.



RECM(h=6), v.m. 6 obs.



RECM(h=9), v.m. 3 obs.





I. Introducción

D.M.E.

- En la versión previa, los niveles de precisión para la inflación no subyacente se deterioraron recién a partir de **diciembre 2005**, lo que confirmaba que la secuencia de “outliers” afectó **un mes después** que en el caso de la inflación subyacente IPC. Los niveles de precisión alcanzados hasta noviembre 2005 fueron de 0.35 para $h=1$ y 0.60 para $h=3$ y, hacia el final de la secuencia de “outliers”, casi se triplicaron para $h=1$, y casi se cuadruplicaron para $h=3$.
- En la nueva versión, para **$h=1$** , se pasa de un rango de 0.5-0.6 **hasta febrero 2006** a uno de 0.65-0.8; para **$h=3$** se pasa de un nivel cercano a 0.60 **hasta octubre 2006** hacia un rango de 1.4-1.8!. Como la precisión se deteriora recién a partir de marzo 2006, se confirmaría que la secuencia de “outliers” afectó a la inflación no subyacente un mes después que a la inflación subyacente.



I. Introducción

D.M.E.

- Sin embargo, en la nueva versión se obtiene un resultado interesante para $h=6$ y $h=9$:
 - **$h=6$** : 3 modelos pasan de 0.6-1.0 hasta noviembre 2005 hasta 2.4-2.8, mientras que el “agregado” aumenta su precisión desde **setiembre del 2005**.
 - **$h=9$** : 3 modelos pasan de 0.6-1.0 hasta noviembre 2005 hasta 2.8-3.2, mientras que el “agregado” disminuye ligeramente su precisión desde **diciembre del 2005**, pasando de 0.4 a 0.8.
- Se encuentra que existe un modelo que resulta relativamente “robusto” sin usar métodos robustos, simplemente imponiendo que todos los componentes de precios se determinen en función al agregado IPC!! Esto resulta evidente con los nuevos horizontes incluidos en esta versión.



I. Introducción

D.M.E.

- Asimismo, hacia el final de la secuencia de “outliers”, el deterioro en la precisión de las proyecciones del agregado inflación IPC se explica principalmente por el asociado a la inflación no subyacente.
- Como el impacto de la secuencia de “outliers” en la inflación no subyacente se inició posteriormente al de la inflación subyacente, puede elaborarse la hipótesis de que las observaciones fuera del patrón previamente establecido se explican por mayores expectativas de inflación en el mediano plazo, principalmente, lo que sin embargo impactó en la formación de los precios de bienes incluidos en ambos sub-agregados. Esta hipótesis sería validada por el desempeño del modelo “agregado”.



I. Introducción

D.M.E.

- Sin embargo, el presente trabajo busca reducir la sensibilidad de los estimadores y de las proyecciones de todos los componentes ante la presencia de “outliers”. Como la hipótesis previa resulta validada por el desempeño del modelo “agregado”, puede argumentarse que la inclusión de variables asociadas a las expectativas del consumidor mejoraría el desempeño. Existe un problema de especificación.
- Por ello existen dos diagnósticos y sendas alternativas de solución para este efecto adverso sobre las proyecciones:
 - Los modelos mantienen problemas de especificación debido a la omisión de variables importantes (1 conjunto de componentes);
 - Los datos tienen problemas de construcción o recopilación por problemas de diseño de encuestas o por problemas de imputación de datos obtenidos de manera indirecta.



I. Introducción

D.M.E.

- El primer diagnóstico critica la idoneidad del modelo y por ende recomienda modificar éste (el trabajo de mañana enfrenta este problema de especificación), mientras que el segundo critica la de los datos y recomienda modificar éstos.
- En el presente trabajo, la modificación de los datos es posible luego de obtener los estimados robustos, que surgen de aceptar que los errores de un modelo tienen una distribución que no es normal. Es decir, se acepta que es necesario asignar probabilidades mayores a los valores extremos, básicamente con una distribución diferente a la Normal.
- Una vez obtenidos estimadores “robustos”, menos sensibles a la presencia de valores extremos, estos valores extremos pueden ser detectados para luego, si es necesario, “ajustar” los datos.



I. Introducción

D.M.E.

- Sin embargo, el objetivo del presente trabajo es reducir la sensibilidad de los estimadores y las proyecciones de todos los componentes ante la presencia de “outliers”, permitiendo así quizá que estos modelos proyecten mejor el futuro.
- Sin embargo, cualquier ajuste a los datos sobre la base de un modelo específico impediría comparar la precisión de este modelo respecto a los demás.
- Por ello, en la sección final comparamos la precisión de estos modelos “robustos” frente a la de los modelos Sparse VAR “plain vainilla”, con estimados basados en errores distribuidos como la Normal (MCO-MV) y muy sensibles a valores extremos. En este sentido, el presente trabajo realiza una “minería de modelos”.



Esquema de la presentación

D.M.E.

- I. Introducción
- II. *Estimadores robustos***
- III. Estimación de modelos *Sparse* VAR robustos
- IV. Sensibilidad de proyecciones robustas
- V. Evaluación *ex post*
- VI. Conclusiones



II. Estimadores robustos

D.M.E.

- Como los estimadores que asumen una distribución normal de los errores (MCO-MV) son demasiado sensibles a valores extremos, naturalmente debemos considerar distribuciones que asignen probabilidades más altas a valores extremos. El número de estimadores robustos es entonces extremadamente grande.
- Huber(1981) propone una taxonomía para los estimadores robustos del parámetro de posición (media) de una muestra de datos; los estimadores “tipo M” (seudo MV), los “tipo L” (combinaciones lineales de los estadísticos de orden) y los “tipo R” (basados en *rankings* de las observaciones).



II. Estimadores robustos

D.M.E.

Estimadores robustos “Tipo M”

- Para una muestra de T observaciones independientes e idénticamente distribuidas $y_i \sim F$, todo estimador en este grupo puede definirse como el escalar

$$\hat{\beta} = \arg \min_b \left\{ \sum_{t=1}^T \rho \left(\frac{y_t - b}{s} \right) \right\}$$

donde b y s corresponden a los parámetros de posición y de escala, resp., y ρ es una función a seleccionar de la familia Γ de funciones doblemente diferenciables, con derivadas continuas por piezas, que cumple con la condición de momentos poblacional

$$E \left\{ \rho' \left(\frac{y_t - \mu}{s_0} \right) \right\} = 0$$



II. Estimadores robustos

D.M.E.

donde $s_0 \equiv p \lim \{s\}$ y s es un estimador del parámetro escala. Alternativamente, es posible obtener b y s simultáneamente.

- Con una función en esta familia que no dependa de T y usando una versión apropiada del teorema de la distribución asintótica de una función no lineal, se puede probar que todo estimador de posición del “tipo M” tiene una distribución asintótica normal con media μ y varianza

$$\text{Asym var}(\hat{\beta}) = \frac{1}{T} s_0^2 \frac{E\left\{\left[\rho'\left(\frac{y_t - \mu}{s_0}\right)\right]^2\right\}}{\left[E\left\{\rho''\left(\frac{y_t - \mu}{s_0}\right)\right\}\right]^2}$$



II. Estimadores robustos

D.M.E.

- Usando la teoría de juegos (con la Naturaleza como un jugador), Huber(1964) construyó su primera propuesta como la solución minimax para seleccionar aquella función $\rho \in \Gamma$ que brinda un seguro contra la distribución menos favorable (en términos de la varianza asintótica del estimador robusto), definida como un miembro de la familia de distribuciones

$$F(z, \varepsilon) = (1 - \varepsilon)\Phi(z) + \varepsilon H(z) \quad z \equiv (y - \mu) / s$$

donde H es a su vez un miembro de la familia de distribuciones simétricas. La solución fue la función

$$\rho(z) = \begin{cases} (1/2)z^2 & |z| < c \\ c|z| - (1/2)c^2 & |z| \geq c \end{cases}$$



II. Estimadores robustos

D.M.E.

donde c es una función de $\varepsilon \in [0,1]$ y puede usarse cualquier estimador robusto para el parámetro de escala. Nótese que si se obtiene b y s simultáneamente, y se usa la función

$$\rho(z) = -\log(f(z))$$

se obtiene los estimadores de máxima verosimilitud, razón por la cual este tipo de estimadores robustos recibe la denominación de “tipo M”.

- Posteriormente, Andrews(1974) propuso la función

$$\rho(z) = \begin{cases} -(1 + \cos(z)) & |z| \leq \pi \\ 0 & |z| > \pi \end{cases}$$

y nuevamente puede usarse cualquier estimador robusto para el parámetro de escala.



II. Estimadores robustos

D.M.E.

- La generalización del estimador robusto “tipo M” para un modelo de regresión lineal consiste simplemente en sustituir el escalar b por el escalar $x_t' b$ para definir el estimador robusto del vector de parámetros como

$$\hat{\beta} = \arg \min_b \left\{ \sum_{t=1}^T \rho \left(\frac{y_t - x_t' b}{s} \right) \right\}$$



II. Estimadores robustos

D.M.E.

Estimadores robustos “Tipo L”

- Para una muestra de T observaciones independientes e idénticamente distribuidas $y_i \sim F$, todo estimador en este grupo se define como cualquier combinación lineal de los estadísticos de orden para la muestra,

$$y_{(1)} \leq y_{(2)} \leq y_{(3)} \leq \dots \leq y_{(T)}$$

- Por ej., la media α -acotada es una combinación convexa de los estadísticos de orden pues asigna ponderaciones no-nulas a un porcentaje $1 - \alpha$ de los mismos. Otro ejemplo es el cuantil muestral de 100θ por ciento, $0 < \theta < 1$, pertenece a este grupo pues se puede definir como



II. Estimadores robustos

D.M.E.

$$q(\theta) = \underset{y_{(k)}}{\operatorname{convex}(y_{(T\theta)}, y_{(T\theta+1)})} \min \{k \in \mathbb{N} : k > T\theta\}, \quad T\theta \in \mathbb{R}$$
$$T\theta \in \mathbb{N}$$

donde la mediana es el caso particular $q(0.5)$, es decir,

$$\operatorname{mediana}(\{y_i\}) = \underset{\operatorname{convex}(y_{(T/2)}, y_{([T/2]+1)})}{y_{([T+1]/2)}} \quad T \text{ _impar}$$
$$T \text{ _par}$$

- Una definición alternativa de $q(\theta)$ muy utilizada es

$$q(\theta) = \arg \min_b \left\{ \sum_{y_t \geq b} \theta |y_t - b| + \sum_{y_t < b} (1 - \theta) |y_t - b| \right\}$$

- De hecho, ésta sirve para generalizar el estimador robusto de “tipo L” para un modelo de regresión lineal mediante una sustitución de b análoga a la anterior, y así definir el



II. Estimadores robustos

D.M.E.

estimador robusto del vector-quantil de parámetros como

$$\hat{\beta}(\theta) = \arg \min_b \left\{ \sum_{y_t \geq x_t' b} \theta |y_t - x_t' b| + \sum_{y_t < x_t' b} (1 - \theta) |y_t - x_t' b| \right\}$$

- Nótese que cualquier estimador que sea una combinación convexa de un conjunto finito de cuantiles también pertenece a este grupo (por ejemplo, el mismo $\hat{\beta}(\theta)$). Por esta razón, el miembro general de este grupo también es denominado “estimador de cuantiles”.



II. Estimadores robustos

D.M.E.

- En el documento se menciona algunos estimadores robustos para el parámetro de escala, específicamente aquellos que pueden obtenerse a partir de un estimado inicial del parámetro de posición, como puede ser la mediana.
- Este procedimiento robusto en dos etapas es apropiado sólo en el caso de los estimadores robustos de posición del “tipo L”, que son independientes del estimador de escala. Ello no sucede para estimadores robustos del “tipo M”.



II. Estimadores robustos

D.M.E.

- De manera similar a los estimadores robustos para una regresión lineal, ahora partimos de una distribución simétrica cualquiera para el vector de errores $\varepsilon_t(\mathbf{B}) \equiv y_t - \mathbf{B}'x_t$ [Kx1] de un sistema de ecuaciones, $t \in \Delta_1 \equiv \{1, 2, \dots, T\}$.
- Aunque el concepto de robustez usado aquí no requiere que los segundos momentos no existan, la típica generalización que sustituye la distribución normal multivariada parte definiendo que $\varepsilon_t(\mathbf{B})$ se distribuye independiente e idénticamente con centro cero y “matriz de dispersión” Σ , lo que significa que su densidad multivariada tiene la forma general

$$f_{\varepsilon_t}(u(\mathbf{B}), \Sigma) = \frac{g(u'(\mathbf{B})\Sigma^{-1}u(\mathbf{B}))}{(\det(\Sigma))^{1/2}}$$



II. Estimadores robustos

D.M.E.

- Nótese que g es una función tan que permite que esta forma general cumpla con los axiomas de probabilidad y que si el segundo momento de $\varepsilon_t(\mathbf{B})$ existe, Σ será proporcional a su matriz de covarianzas.

Los estimadores del grupo M para sistemas de ecuaciones pueden definirse como

donde

$$\beta \equiv \text{vec}(\mathbf{B})$$

$$\theta \equiv \text{vech}(\Sigma)$$

$$(\hat{\beta}, \hat{\theta}) = \arg \min_{(\beta, \theta)} \left\{ - \sum_{t \in \Delta_1} f_{\varepsilon_t}(u(\mathbf{B}), \Sigma) \right\}$$

(nótese la redefinición temporal).

- Desventaja: estimadores “tipo M” brindan menores ventajas de robustez a mayor dimensión del sistema.



II. Estimadores robustos

D.M.E.

- La generalización del grupo de estimadores L para sistemas de ecuaciones requiere una muestra de escalares a partir de la cual se obtengan los estadísticos de orden mientras que nuestros errores son ahora vectores. Una medida escalar asociada a cada vector de errores es su distancia “normalizada” o “de Mahalanobis” $d_t^2 \equiv \varepsilon_t'(\mathbf{B})\Sigma^{-1}\varepsilon_t(\mathbf{B})$

- Entonces, cualquier combinación lineal de los estadísticos de orden para la muestra de estas distancias, definidos como

$$d_{(1:T)}^2 \leq d_{(2:T)}^2 \leq d_{(3:T)}^2 \leq \dots \leq d_{(T:T)}^2$$

pertenece a la familia de estimadores robustos “tipo L”.



Esquema de la presentación

D.M.E.

- I. Introducción
- II. Estimadores robustos
- III. *Estimación de modelos Sparse VAR robustos***
- IV. Sensibilidad de proyecciones robustas
- V. Evaluación *ex post*
- VI. Conclusiones



III. Estimación de modelos *Sparse* VAR robustos

D.M.E.

- Joossens & Croux (2005) propusieron estimadores robustos para modelos VAR, que denominan “estimador de mínimos cuadrados acotados multivariados” o MLTS por sus siglas en inglés.
- El estimador MLTS se obtiene de minimizar una media α - acotada por la derecha de las distancias cuadradas de Mahalanobis, lo que equivale a minimizar la suma de las h menores distancias cuadradas,

$$(\hat{\beta}, \hat{\theta}) = \arg \min_{\{(\beta, \theta) : |\Sigma|=1\}} \left\{ \sum_{s=1}^h d_{(s:T)}^2(\mathbf{B}, \Sigma) \right\}$$



III. Estimación de modelos *Sparse* VAR robustos

D.M.E.

- Debe mencionarse que Joossens & Croux (2005) sostienen que este estimador es bastante robusto en el contexto de modelos VAR(K,L), a pesar de que definen

$$x_t \equiv [1, y'_{t-1}, y'_{t-2}, \dots, y'_{t-L}]' \in \mathbb{R}^Q$$

donde $Q=LK+1$, y ahora

$$t \in \Delta_{L+1} \equiv \{L+1, L+2, \dots, T\}$$

- Agulló, Croux & Van Aelst (2002) demostraron que el estimador MLTS puede obtenerse utilizando el algoritmo "rápido" basado sobre el estimador del Mínimo Determinante de Covarianza (MCD), que es un estimador robusto de la escala multivariada del vector de errores del sistema.



III. Estimación de modelos *Sparse* VAR robustos

D.M.E.

- Este algoritmo es una búsqueda estocástica de las h "observaciones" que minimizan el determinante de la matriz de covarianzas de los residuos correspondientes a dichas "observaciones", residuos obtenidos con el estimador de MCO, típicamente usado para los parámetros de un sistema de ecuaciones como el VAR. Definamos
- el conjunto de datos como $Z \equiv \{(x_t, y_t) : t \in \Delta_{L+1}\} \subset \mathbb{R}^{K+Q}$
- la familia de todos los subconjuntos de Δ_{L+1} con el mismo número de elementos h , $\Lambda(h) \equiv \{H \subset \Delta_{L+1} : \#H = h\}$
- el estimador MCO obtenido con las h observaciones de cualquier subconjunto $H \in \Lambda(h)$,



III. Estimación de modelos *Sparse* VAR robustos

D.M.E.

$$\hat{B}_{MCO}(H) \equiv [X'(H)X(H)]^{-1} X'(H)Y(H)$$

donde las matrices $X(H)$ e $Y(H)$ son las sub-matrices de X e Y que resultan de seleccionar las “observaciones” (filas) según el índice H , respectivamente. Definiendo el vector de errores asociado,

$$\varepsilon[\hat{B}_{MCO}(H)] \equiv Y(H) - \hat{B}'_{MCO}(H)X(H)$$

el estimador correspondiente de la matriz *scatter* obtenido de este subconjunto de observaciones resulta

$$\hat{\Sigma}_{MCO}(H) \equiv \frac{1}{h-K} \varepsilon[\hat{B}_{MCO}(H)]' \varepsilon[\hat{B}_{MCO}(H)]$$

por lo que hallando el índice H de observaciones que minimiza el determinante de este estimador,



III. Estimación de modelos *Sparse* VAR robustos

D.M.E.

$$\hat{H} \equiv \arg \min_{H \in \Lambda(h)} \left| \hat{\Sigma}_{MCO}(H) \right|$$

se puede definir el estimador MLTS para un modelo VAR (sistema en forma reducida) como:

$$\hat{\beta}_{MLTS}(Z) \equiv \text{vec} \left(\hat{B}_{MCO}(\hat{H}) \right)$$

$$\hat{\theta}_{MLTS}(Z) \equiv \text{vech} \left(\hat{\Sigma}_{MCO}(\hat{H}) \right)$$

- Como la eficiencia del estimador MLTS es baja, Joossens & Croux (2005) recomiendan “re-ponderarlo” para mejorar su desempeño en muestras pequeñas, un procedimiento similar a la “generalización” de los estimadores M a partir de la *función de influencia* de Hampel et al (1986), esta vez aplicada sobre las distancias cuadradas de Mahalanobis.



III. Estimación de modelos *Sparse* VAR robustos

D.M.E.

- Para obtener este estimador “reponderado” MLTS (ó estimador RMLTS) definimos

$$J \equiv \left\{ j : d_j^2(\hat{\mathbf{B}}_{MLTS}, \hat{\Sigma}_{MLTS}) \leq q_\delta \right\}$$

donde $q_\delta \equiv \chi_{Q,1-\delta}^2$ es el cuantil superior δ -por ciento de una distribución χ_Q^2 . δ es simplemente la fracción de acotación de la etapa de reponderación. Entonces, el estimador RMLTS se define como

$$\hat{\beta}_{RMLTS}^{MCO}(Z) \equiv \text{vec}(\hat{\mathbf{B}}_{MCO}(J))$$

$$\hat{\theta}_{RMLTS}^{MCO}(Z) \equiv \text{vech}(c_\delta \hat{\Sigma}_{MCO}(J))$$

donde c_δ es el factor que permite estimar consistentemente



III. Estimación de modelos *Sparse* VAR robustos

D.M.E.

Σ en la distribución simétrica general para los errores, mencionada en la sección II.

- Debemos remarcar que **esta reponderación no efectúa ningún ajuste a los datos, sino más bien al estimador**. Su utilidad es detectar y excluir algunos “outliers” que pueden persistir luego de la primera etapa que obtiene el estimador MLTS. La segunda etapa los detecta por sus elevados errores cuadráticos de Mahalanobis y excluye las “observaciones” asociadas bajo la definición de las que deben permanecer en J y, por ende, en el cómputo del estimador RMLTS.



III. Estimación de modelos *Sparse VAR* robustos

D.M.E.

- Barrera(2005,2006A) describe la construcción de modelos **Sparse VAR “plain vainilla”** a partir de restricciones de exclusión obtenidas mediante AIC para luego aplicar EGLS al sistema. Su versión robusta se reseña a continuación.
- Las restricciones se obtuvieron de manera similar usando el estimador de “tipo M” y la función propuesta por Andrews (1974) para el “vector” de posición y el estimador MCD para la escala univariada correspondiente a cada ecuación del VAR. El estimador MCD se utilizó en la función penalizada de AIC siguiendo la propuesta de Preminger & Sakata (2001) para la familia de estimadores robustos “tipo S”.



III. Estimación de modelos *Sparse VAR* robustos

D.M.E.

- Obtenidas las restricciones R se aplica el estimador RMLTS ya descrito al caso de la estimación EGLS. Lutkepohl (1993) usa la siguiente representación de los coeficientes del VAR

$$\beta \equiv \text{vec}(B) = R\gamma + r$$

donde γ es un vector $[M \times 1]$ de M parámetros diferentes de cero, R es una matriz $[K(KL+1) \times M]$ conocida de restricciones y r es un vector $[K(KL+1) \times M]$ de coeficientes conocidos (ceros en nuestro caso).

- Como la matriz de covarianzas es desconocida, el procedimiento iterativo parte de una matriz idéntica, para



III. Estimación de modelos *Sparse* VAR robustos

D.M.E.

hallar un primer conjunto de errores estimados con los que se calcula un estimado consistente de la matriz de covarianzas de los mismos, $\hat{\Sigma}_u$, y luego, el estimador EGLS

$$\hat{\gamma}_{EGLS} = \left[R' \left(XX' \otimes \hat{\Sigma}_u^{-1} \right) R \right]^{-1} R' \left(XX' \otimes \hat{\Sigma}_u^{-1} \right) y$$

- Entonces, nuestro estimador RMLTS-EGLS resulta

$$\hat{\gamma}_{RMLTS}^{EGLS} (Z) \equiv \text{vec} \left(R \hat{\gamma}_{EGLS} (J) \right)$$

$$\hat{\theta}_{RMLTS}^{EGLS} (Z) \equiv \text{vech} \left(c_{\delta} \hat{\Sigma}_{EGLS} (J) \right)$$

donde

$$\hat{\gamma}_{EGLS} (H) = \left[R' \left(X(H)X'(H) \otimes \hat{\Sigma}_u^{-1}(H) \right) R \right]^{-1} R' \left(X(H)X'(H) \otimes \hat{\Sigma}_u^{-1}(H) \right) y(H)$$



Esquema de la presentación

D.M.E.

- I. Introducción
- II. Estimadores robustos
- III. Estimación de modelos *Sparse* VAR robustos
- IV. *Sensibilidad de proyecciones robustas***
- V. Evaluación *ex post*
- VI. Conclusiones



IV. Sensibilidad de proyecciones

D.M.E.

- En la introducción presentamos la sensibilidad de la precisión de las proyecciones de los modelos Sparse VAR “plain vainilla” ante la presencia de la secuencia de “outliers” recientemente experimentada. Para ello se calcularon secuencias comparables de los $RECM(h)$, $h \in \{1, 3, 6, 9\}$
- En esta sección comparamos estas secuencias con las correspondientes a los modelos Sparse VAR robustos obtenidos a partir de los estimadores RMLTS-EGLS, ya descritos.

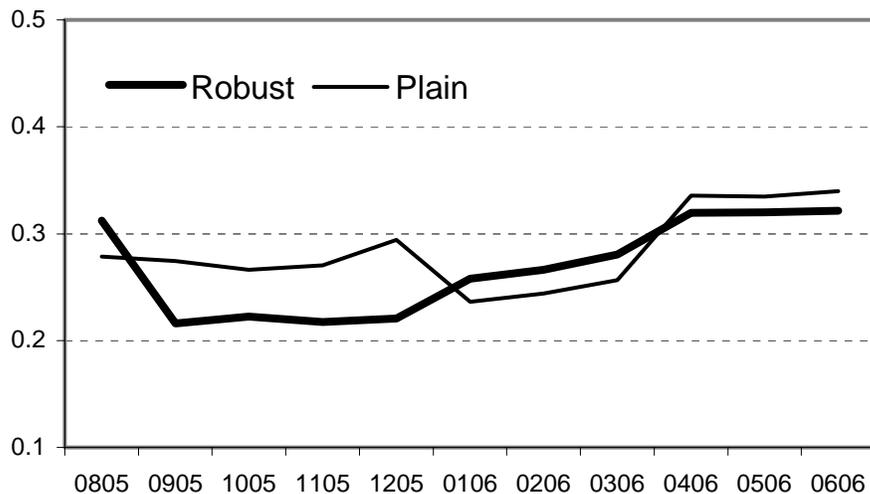


IV. Sensibilidad de proyecciones

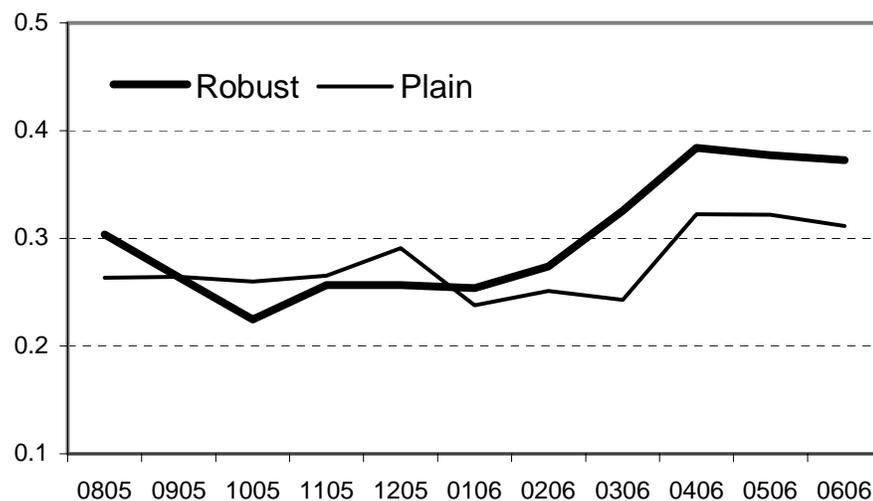
D.M.E.

Inflación IPC : RMSFE(h=1)

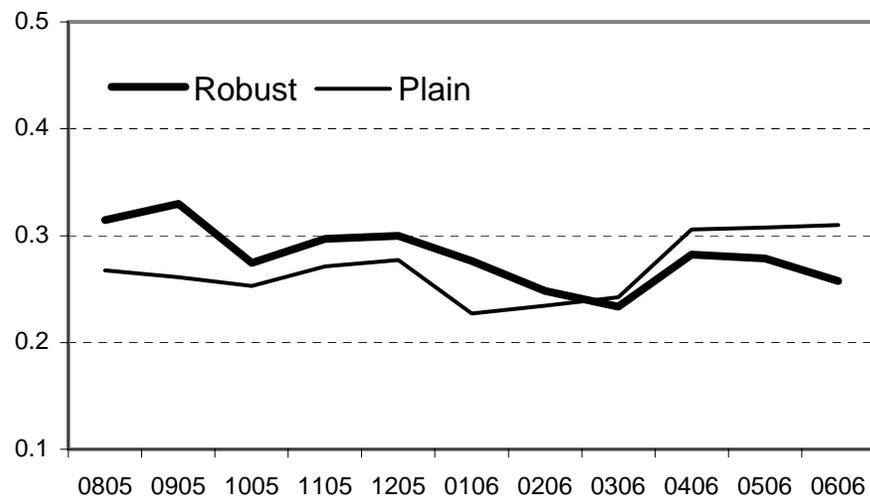
Mejor Componente + *Dummies*



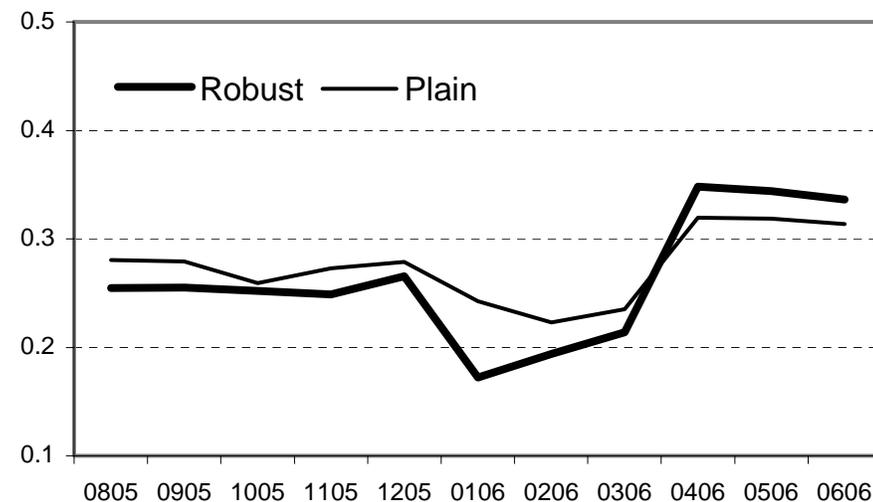
Agregado + *Dummies*



Mejor componente



Agregado





IV. Sensibilidad de proyecciones

D.M.E.

- Con un horizonte $h=1$, los dos modelos “robustos” que eligen el mejor componente en cada ecuación (primera columna) resultan menos sensibles hacia el final de la secuencia de “outliers” que los modelos “plain”.
- Ello contrasta con los modelos “robustos” que eligen al agregado en cada ecuación (segunda columna), que presentan una menor precisión respecto a los correspondientes modelos “plain”.
- También es importante señalar que los modelos “robustos” también suelen ser más precisos que los “plain” antes de la secuencia de “outliers” particular cuyos efectos enfatizamos (excepto el modelo “plain” denominado “mejor componente”).

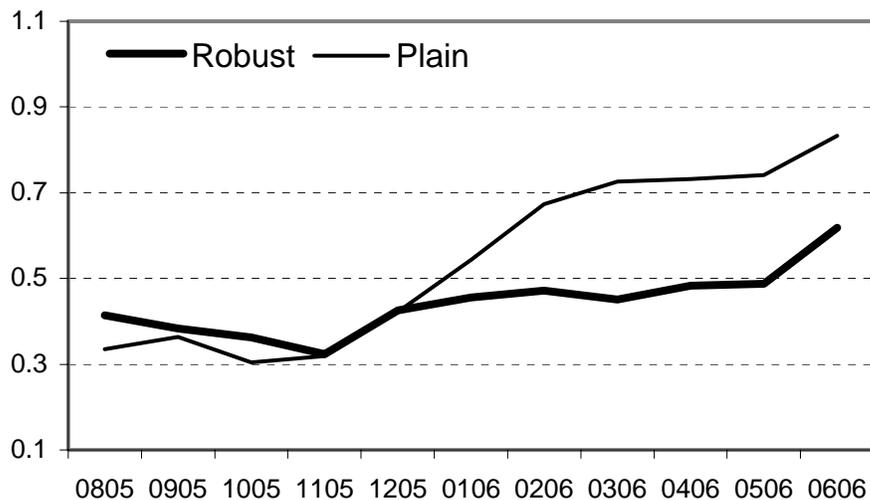


IV. Sensibilidad de proyecciones

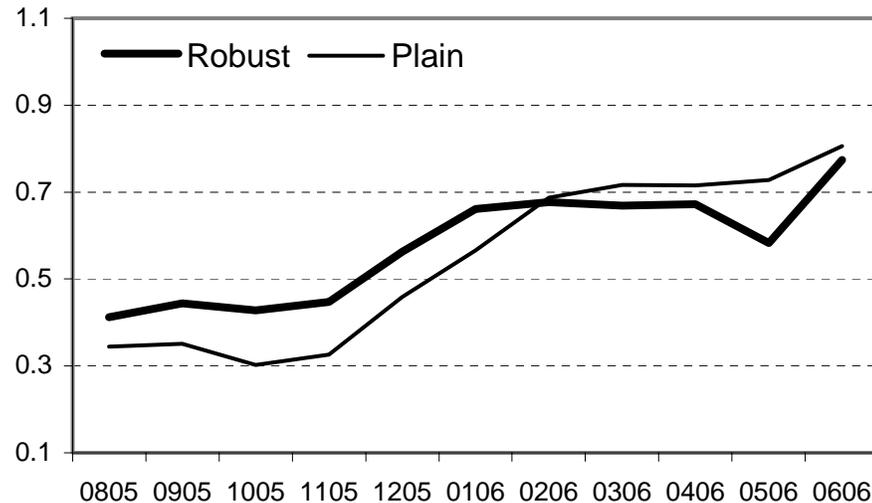
D.M.E.

Inflación IPC : RMSFE(h=3)

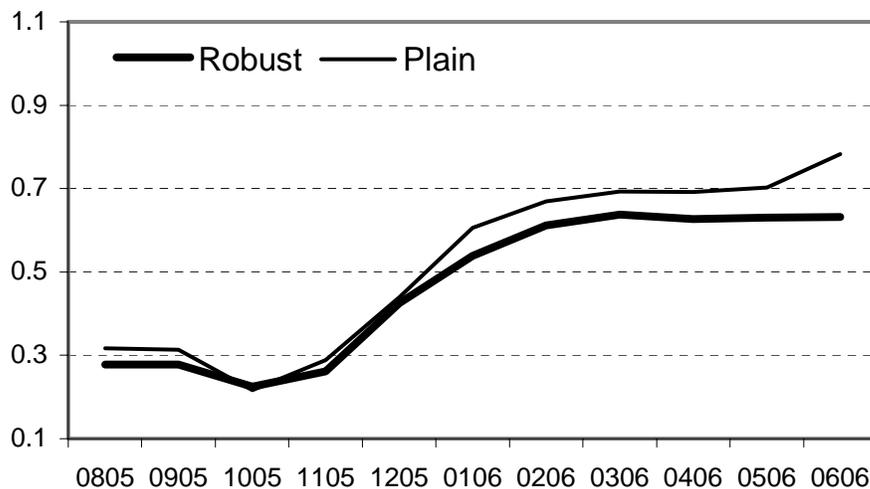
Mejor Componente + *Dummies*



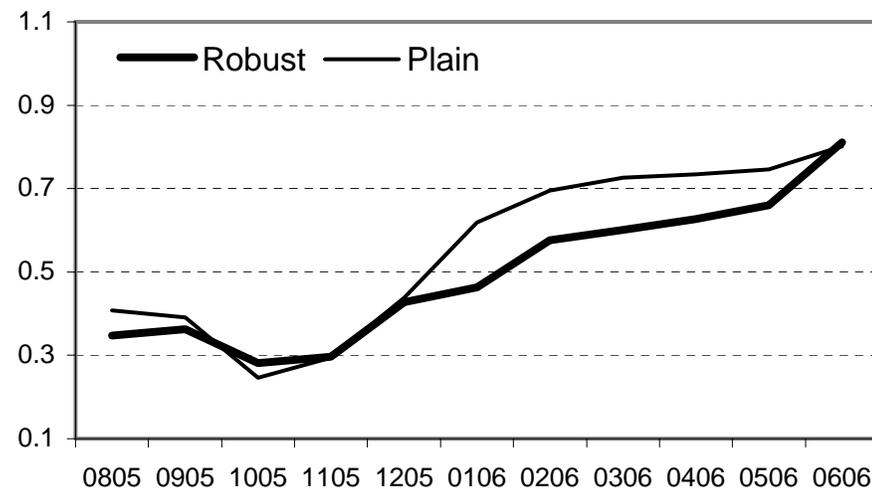
Agregado + *Dummies*



Mejor componente



Agregado





IV. Sensibilidad de proyecciones

D.M.E.

- Con un horizonte $h=3$, todos los modelos “robustos” resultan menos sensibles hacia el final de la secuencia de “outliers” que los modelos “plain”. El modelo “robusto” con la mayor ganancia en términos de una menor sensibilidad es el modelo “mejor componente con dummies”.
- También es importante señalar que los modelos “robustos” suelen ser tan precisos como los “plain” antes de la secuencia de “outliers” particular cuyos efectos enfatizamos (excepto en el caso de los modelos “agregado con dummies”).

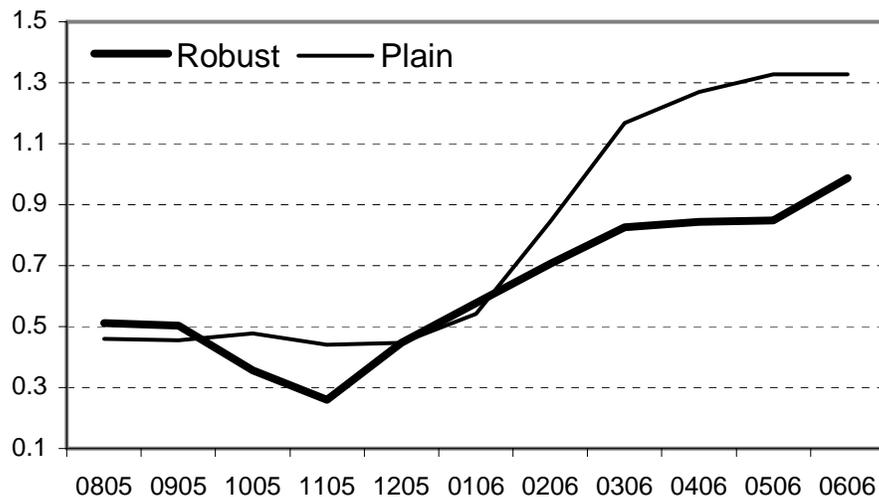


IV. Sensibilidad de proyecciones

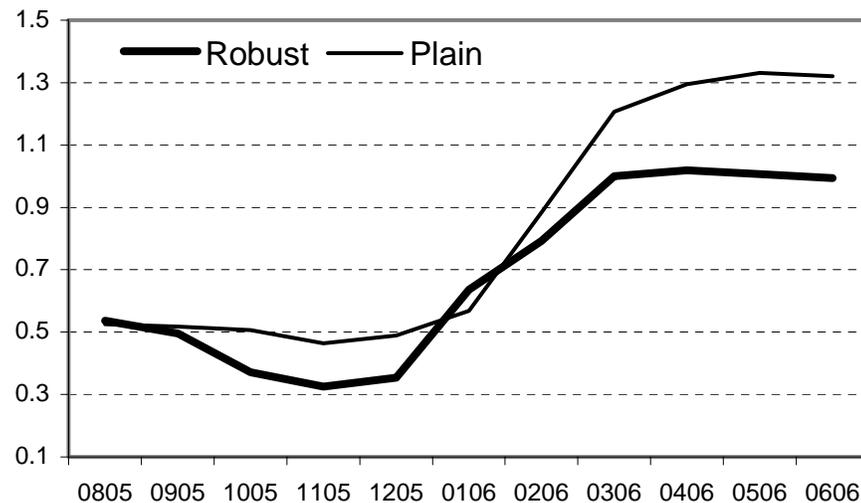
D.M.E.

Inflación IPC : RMSFE(h=6)

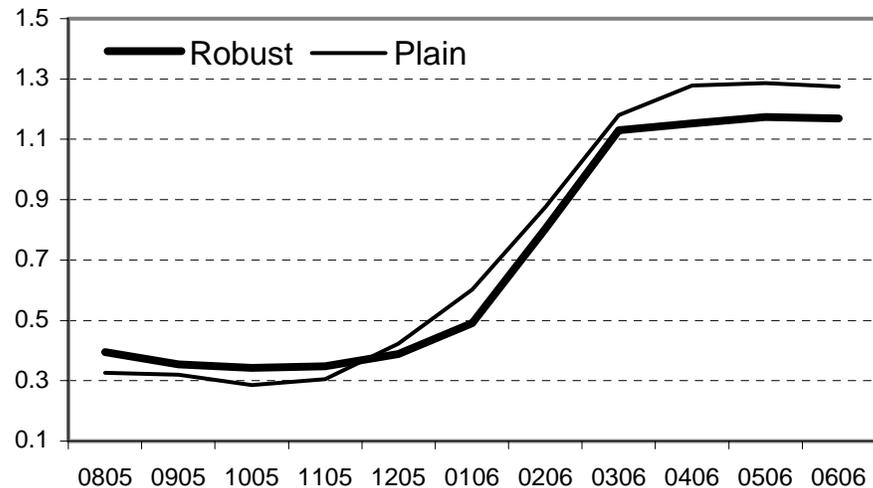
Mejor Componente + *Dummies*



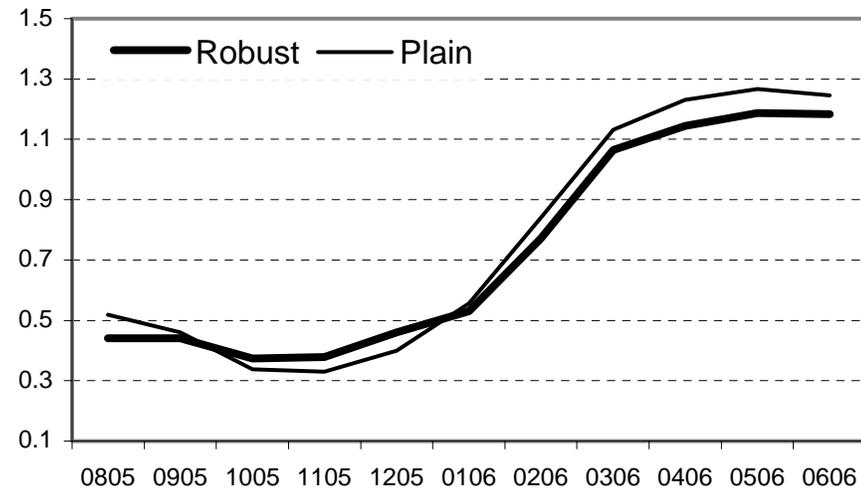
Agregado + *Dummies*



Mejor componente



Agregado





IV. Sensibilidad de proyecciones

D.M.E.

- Con un horizonte $h=6$, todos los modelos “robustos” resultan menos sensibles hacia el final de la secuencia de “outliers” que los modelos “plain”. Los modelos “robustos” con la mayor ganancia en términos de una menor sensibilidad son aquellos con dummies (primera fila).
- Estos mismos modelos pueden ser más precisos que sus correspondientes modelos “plain” antes de la secuencia de “outliers” particular . Ello podría implicar que el inicio de la secuencia de “outliers” pudo haberse producido **antes de noviembre 2005**.

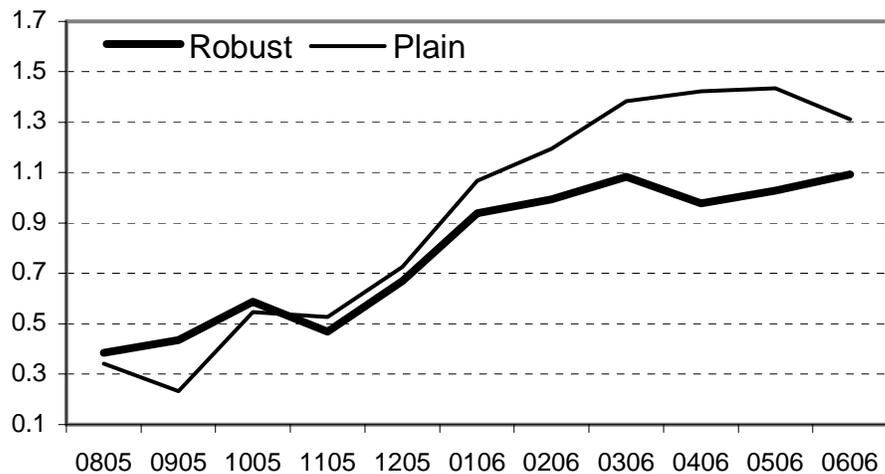


IV. Sensibilidad de proyecciones

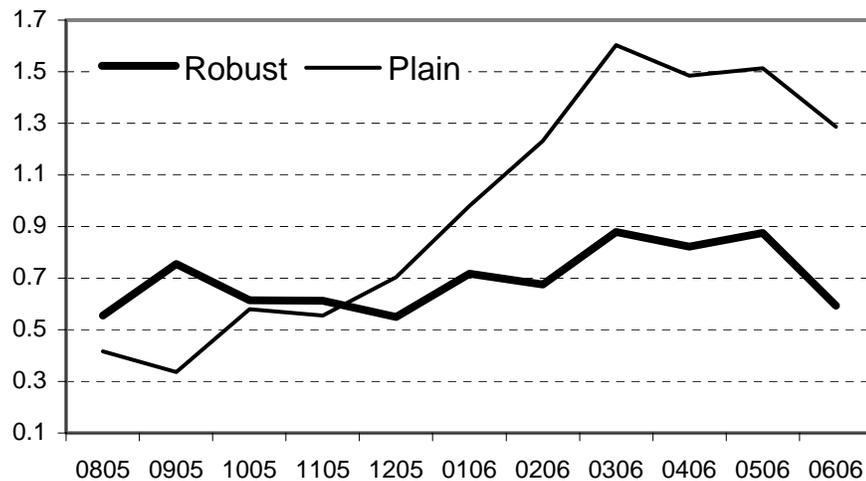
D.M.E.

Inflación IPC : RMSFE(h=9)

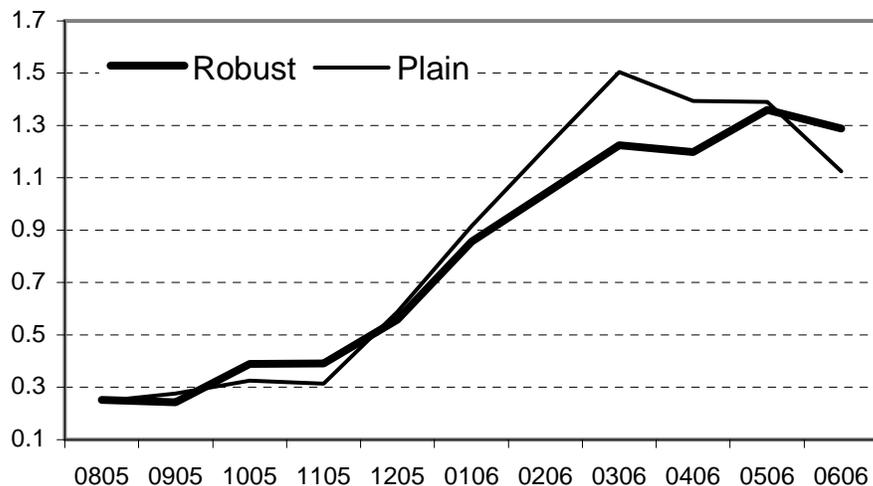
Mejor Componente + *Dummies*



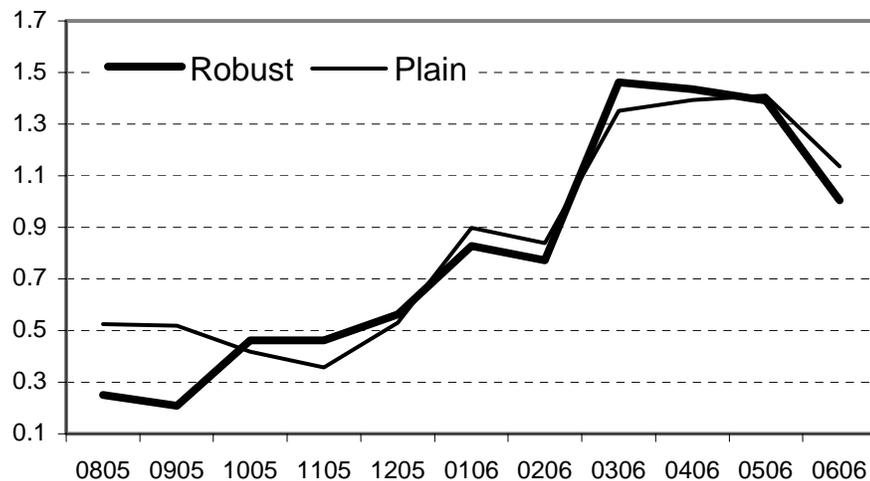
Agregado + *Dummies*



Mejor componente



Agregado





IV. Sensibilidad de proyecciones

D.M.E.

- Con un horizonte $h=9$, todos los modelos “robustos” resultan menos sensibles hacia el final de la secuencia de “outliers” que los modelos “plain”. La única excepción parece ser el modelo “robusto” denominado “agregado”.
- Los modelos “robustos” con la mayor ganancia en términos de una menor sensibilidad son aquellos con dummies (primera fila).



IV. Sensibilidad de proyecciones

D.M.E.

- Es importante mencionar que la persistencia de cierto grado de sensibilidad para horizontes cortos puede reflejar que el estimador RMLTS-EGLS requiere aumentar el porcentaje de acotación α que se aplica a las distancias de Mahalanobis. Asimismo, este mayor porcentaje puede favorecer el desempeño de los modelos robustos que aún no presenta mejoras sustanciales respecto a sus contrapartes “plain”.

α



IV. Sensibilidad de proyecciones

D.M.E.

- Respecto a la **inflación no subyacente**, todos los modelos “robustos” resultan menos sensibles hacia el final de la secuencia de “outliers” que los modelos “plain” para $h=3$, $h=6$ y $h=9$, excepto el modelo “agregado” para $h=6$ y $h=9$. Los modelos “robustos” con la mayor ganancia en términos de una menor sensibilidad son los modelos con dummies para $h=3$, $h=6$ y $h=9$.

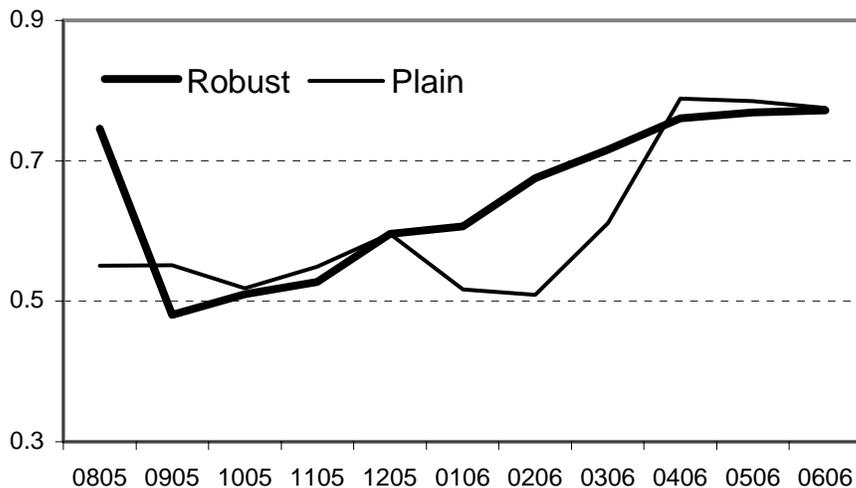


IV. Sensibilidad de proyecciones

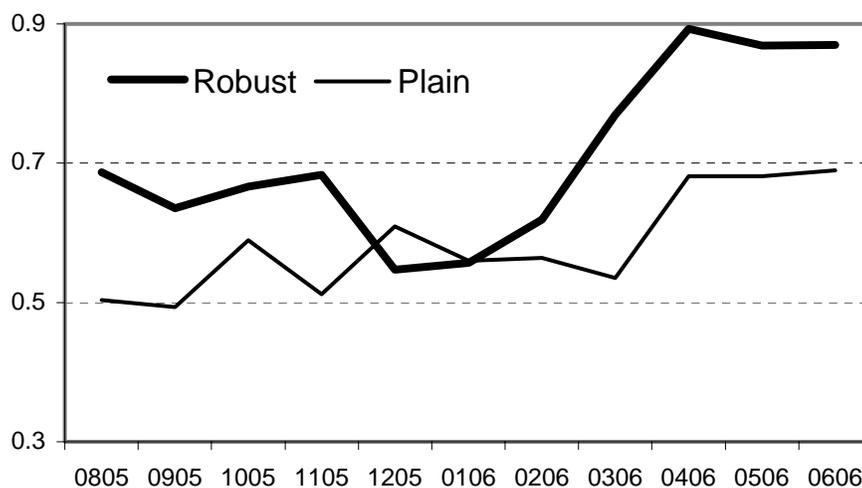
D.M.E.

Inflación No Subyacente IPC : RMSFE(h=1)

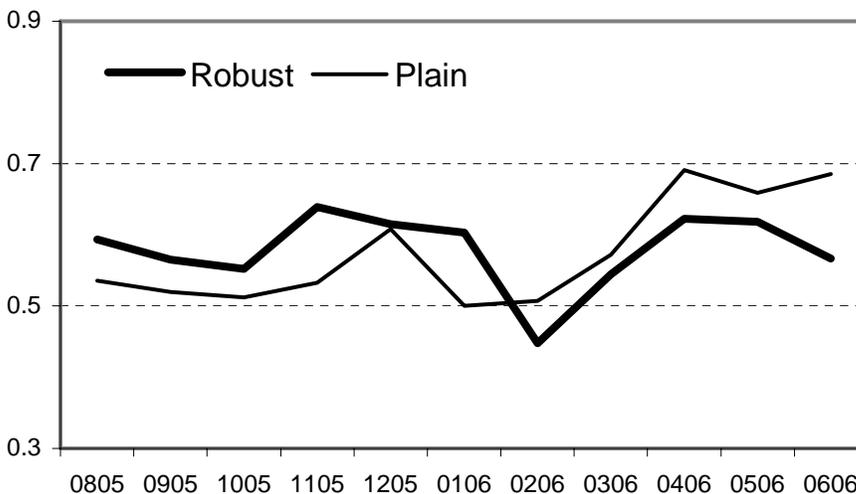
Mejor Componente + *Dummies*



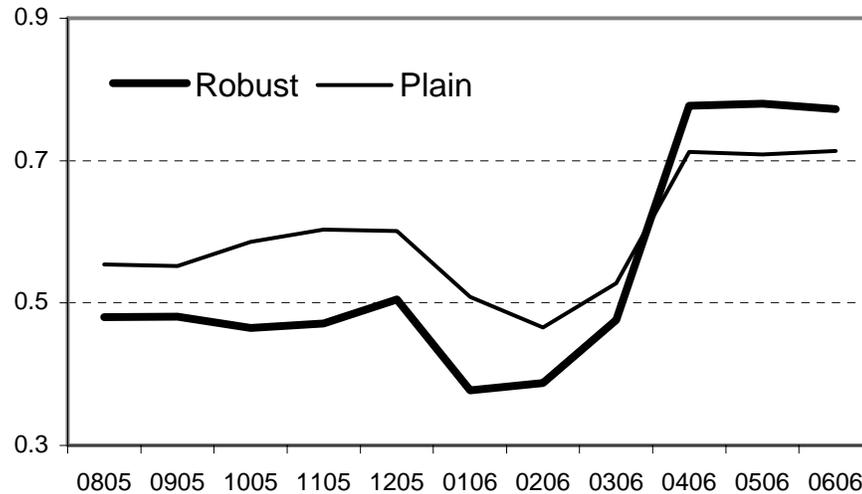
Agregado + *Dummies*



Mejor componente



Agregado



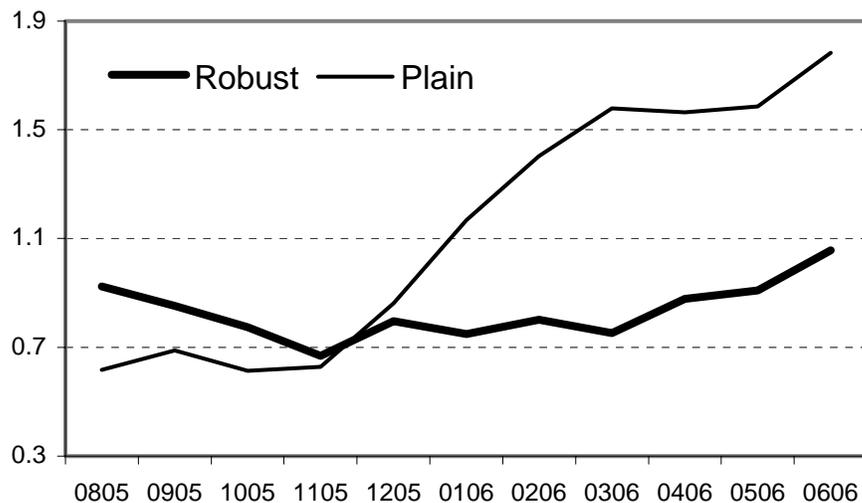


IV. Sensibilidad de proyecciones

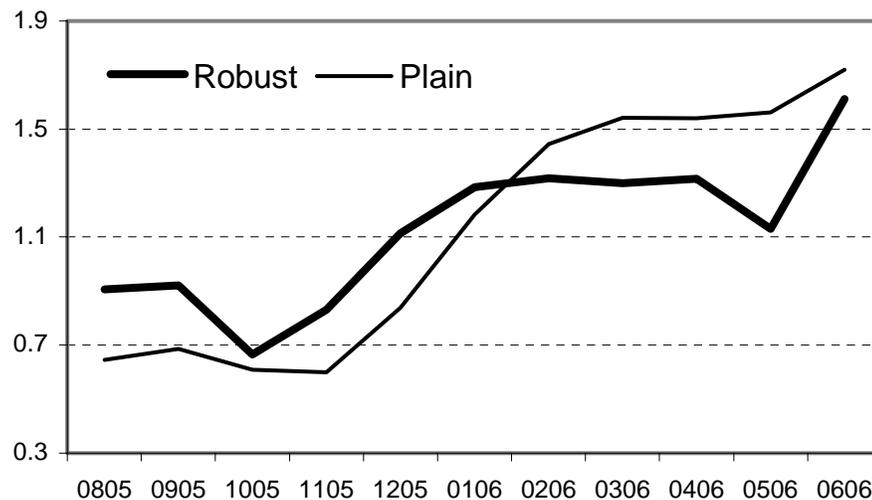
D.M.E.

Inflación No Subyacente IPC : RMSFE(h=3)

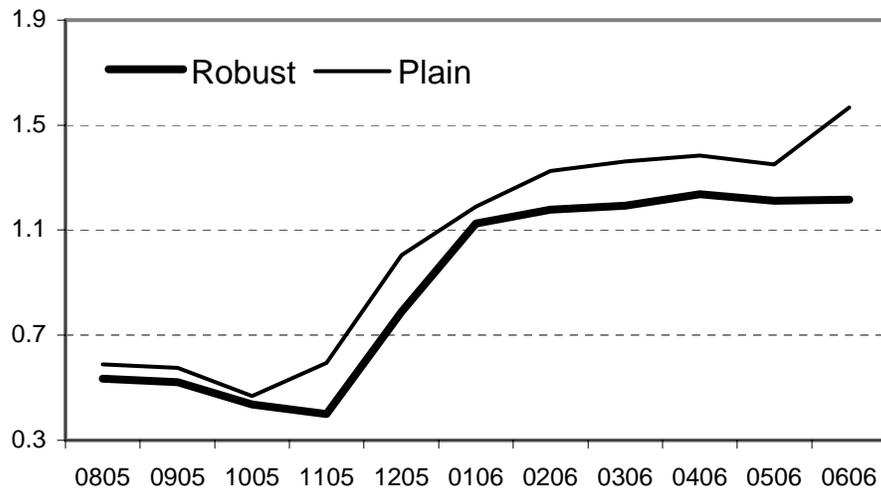
Mejor Componente + *Dummies*



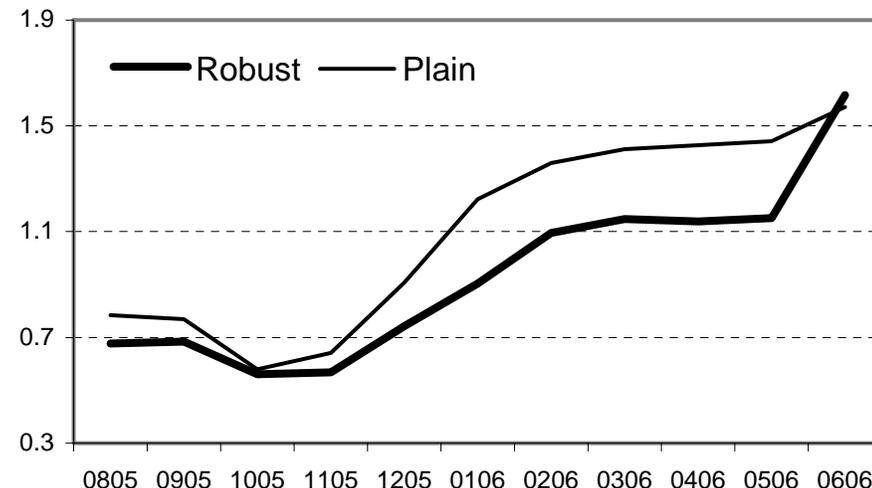
Agregado + *Dummies*



Mejor componente



Agregado



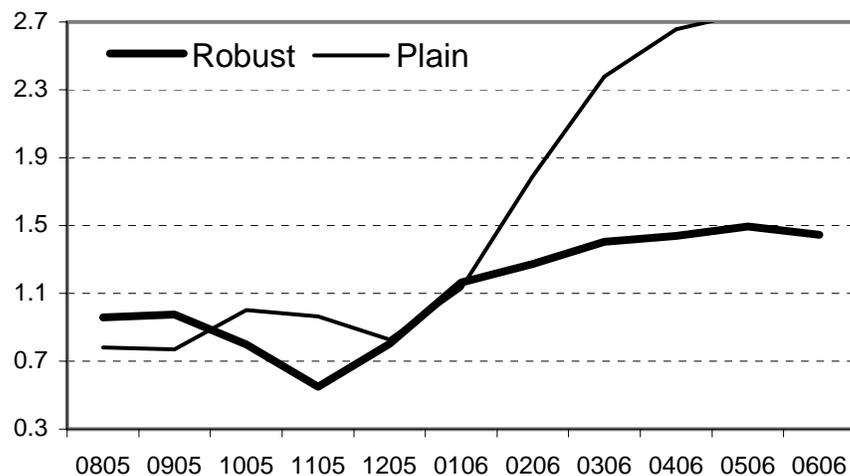


IV. Sensibilidad de proyecciones

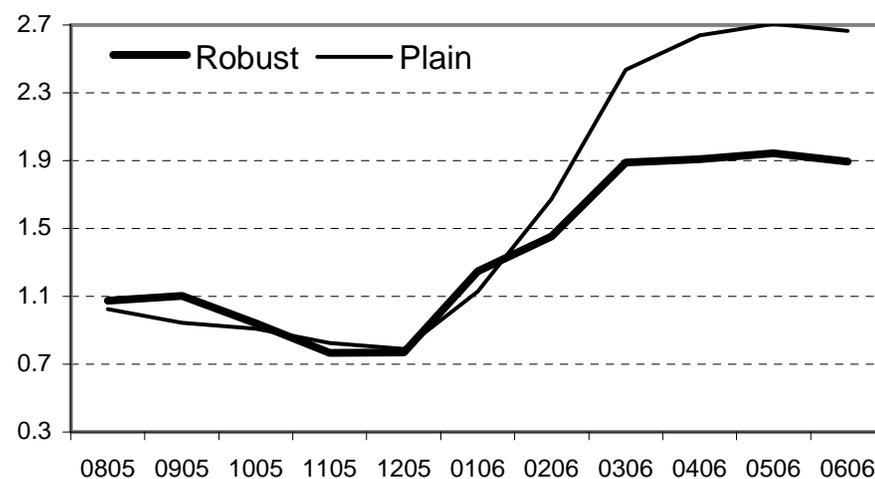
D.M.E.

Inflación No Subyacente IPC : RMSFE(h=6)

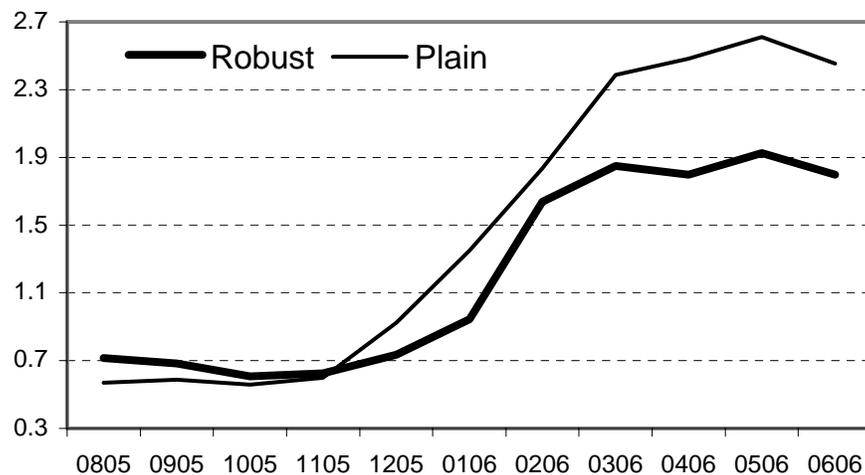
Mejor Componente + *Dummies*



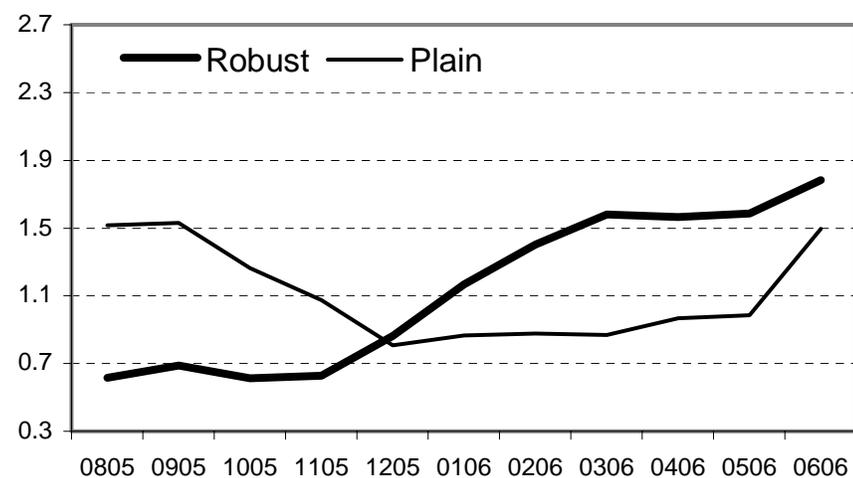
Agregado + *Dummies*



Mejor componente



Agregado



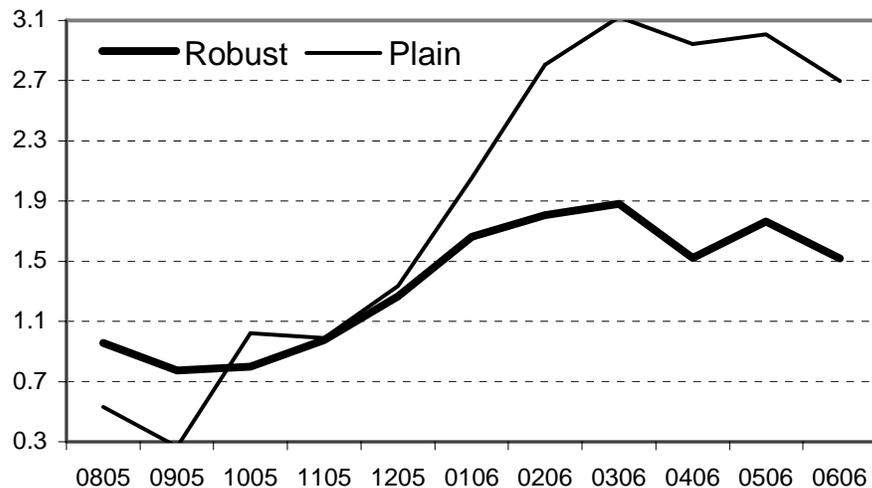


IV. Sensibilidad de proyecciones

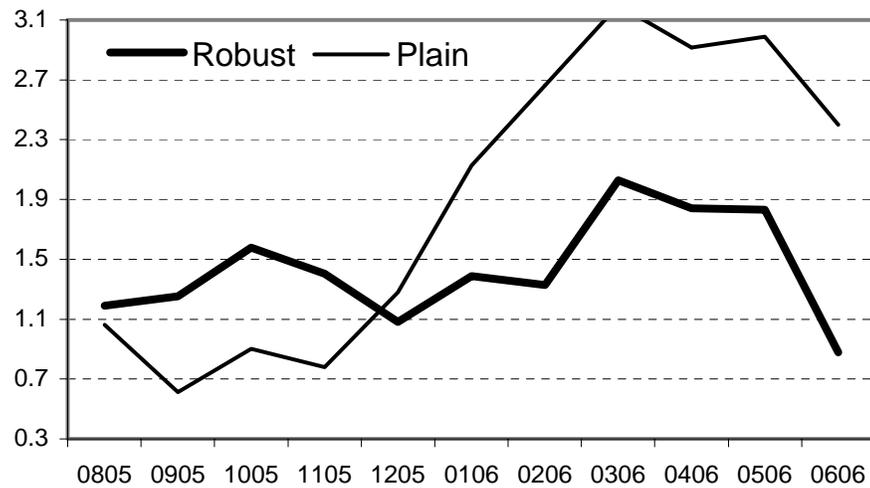
D.M.E.

Inflación No Subyacente IPC : RMSFE(h=9)

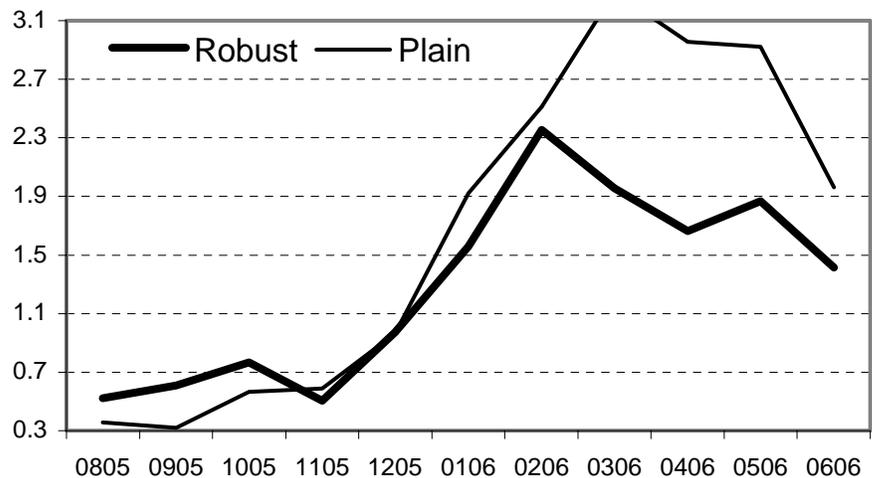
Mejor Componente + *Dummies*



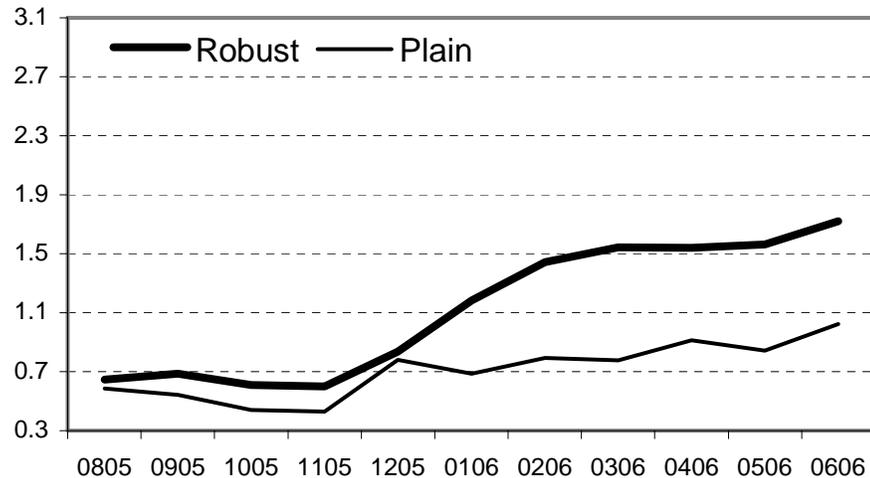
Agregado + *Dummies*



Mejor componente



Agregado





IV. Sensibilidad de proyecciones

D.M.E.

- Respecto a la **inflación subyacente**, todos los modelos “robustos” con dummies resultan menos sensibles hacia el final de la secuencia de “outliers” que los modelos “plain” correspondientes para $h=1$, $h=3$ y $h=6$.
- Asimismo, estos modelos “robustos” con dummies presentan la mayor ganancia en términos de una menor sensibilidad para $h=1$, $h=3$ y $h=6$.

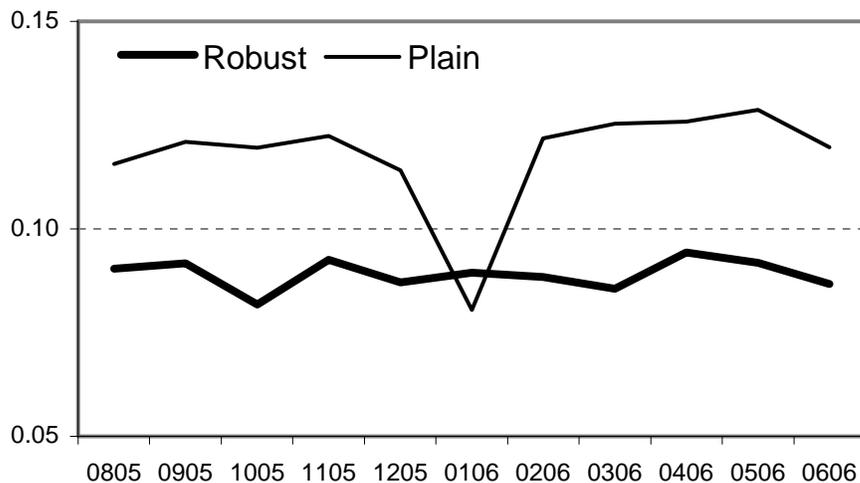


IV. Sensibilidad de proyecciones

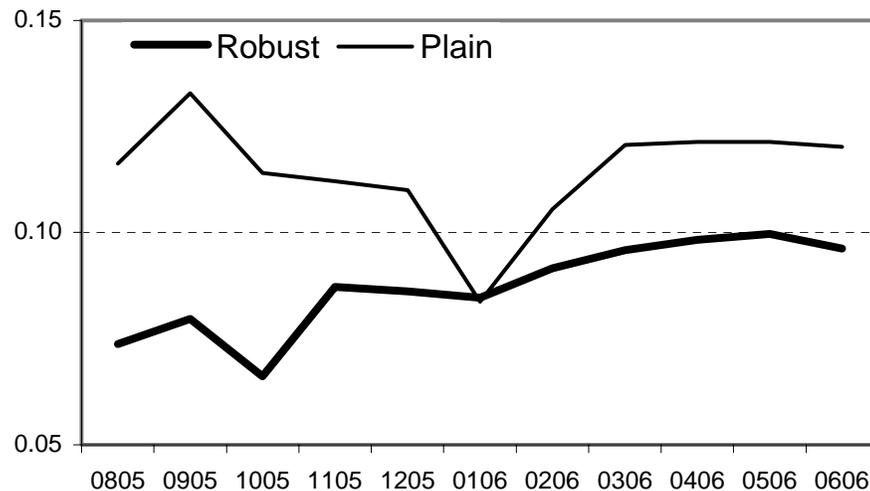
D.M.E.

Inflación Subyacente IPC : RMSFE(h=1)

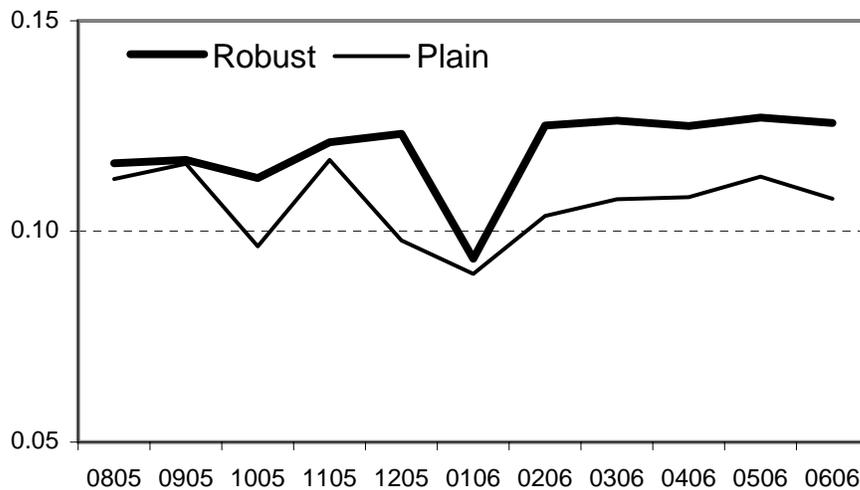
Mejor Componente + *Dummies*



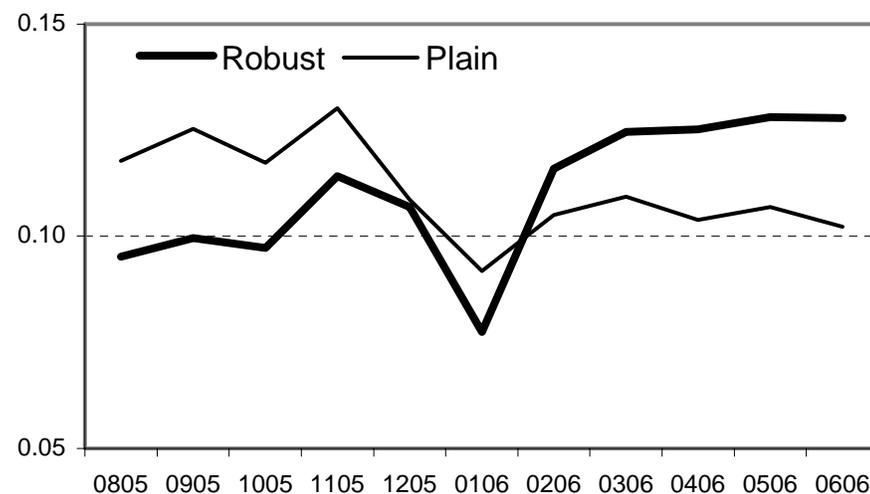
Agregado + *Dummies*



Mejor componente



Agregado



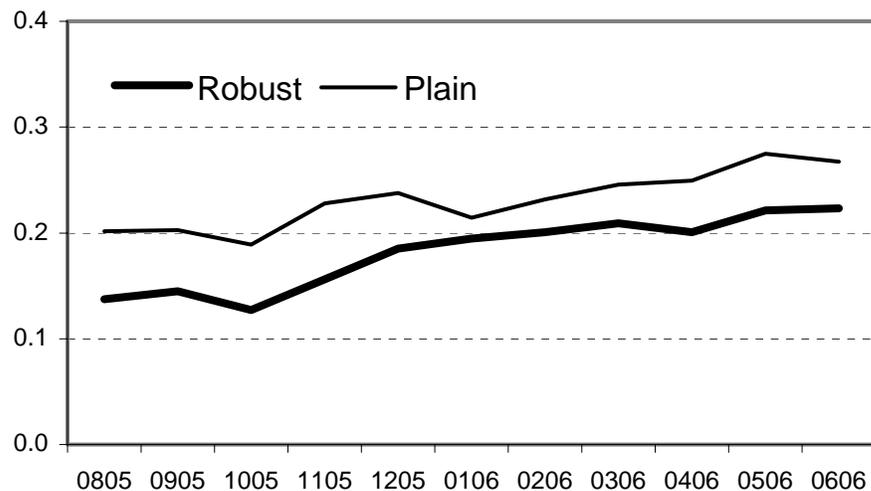


IV. Sensibilidad de proyecciones

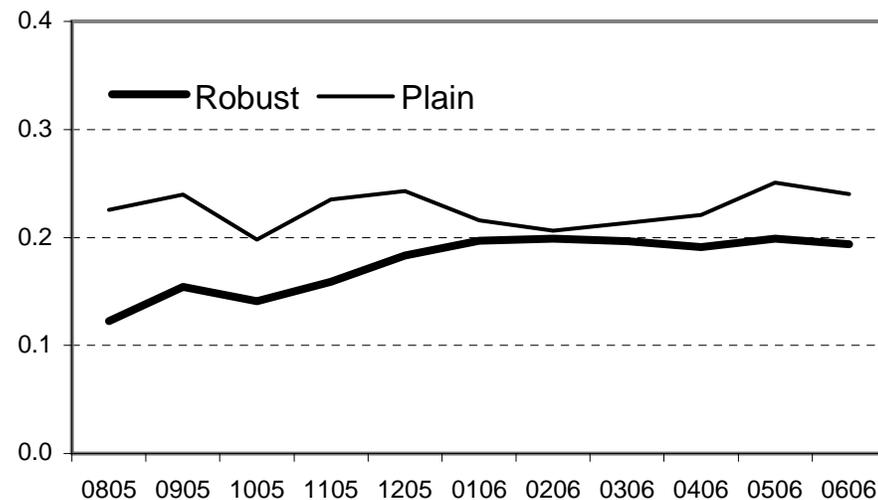
D.M.E.

Inflación Subyacente IPC : RMSFE(h=3)

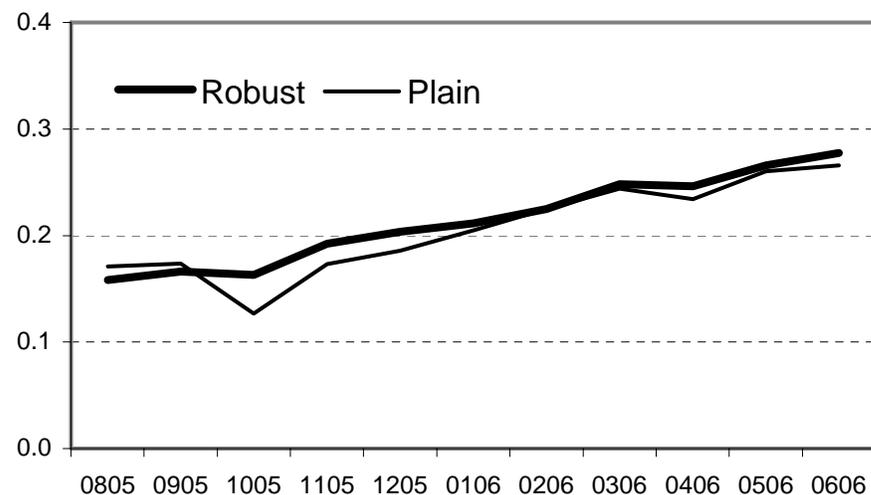
Mejor Componente + *Dummies*



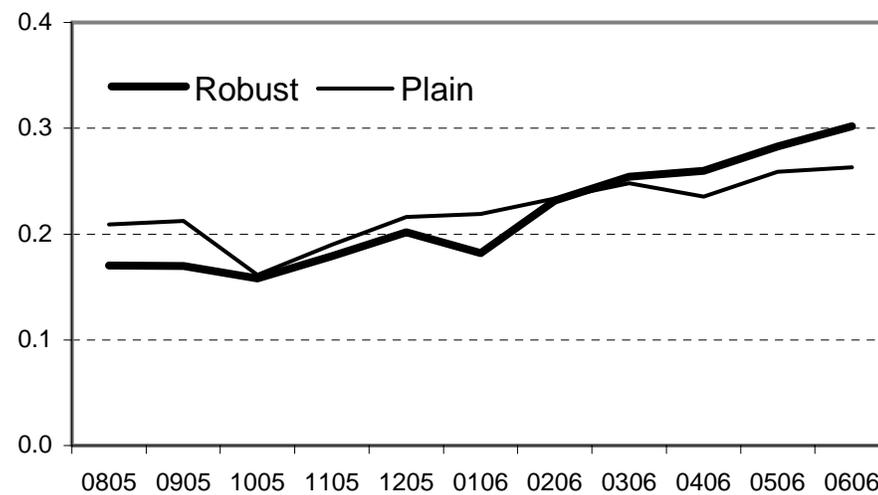
Agregado + *Dummies*



Mejor componente



Agregado



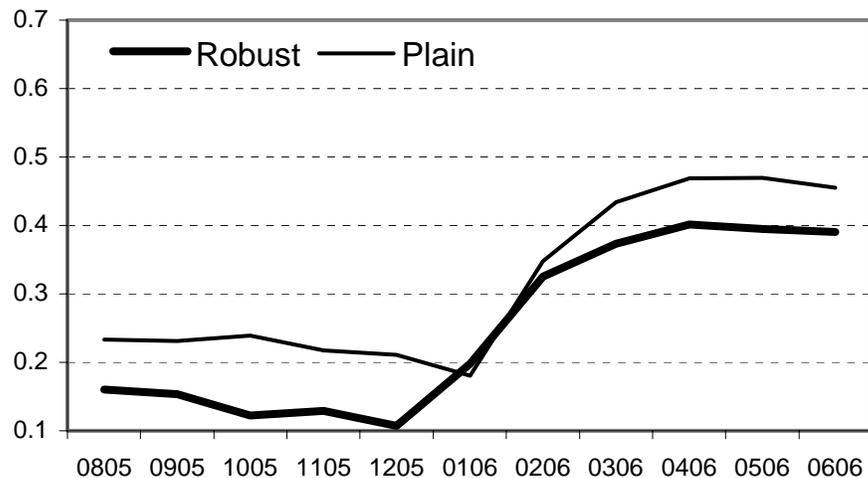


IV. Sensibilidad de proyecciones

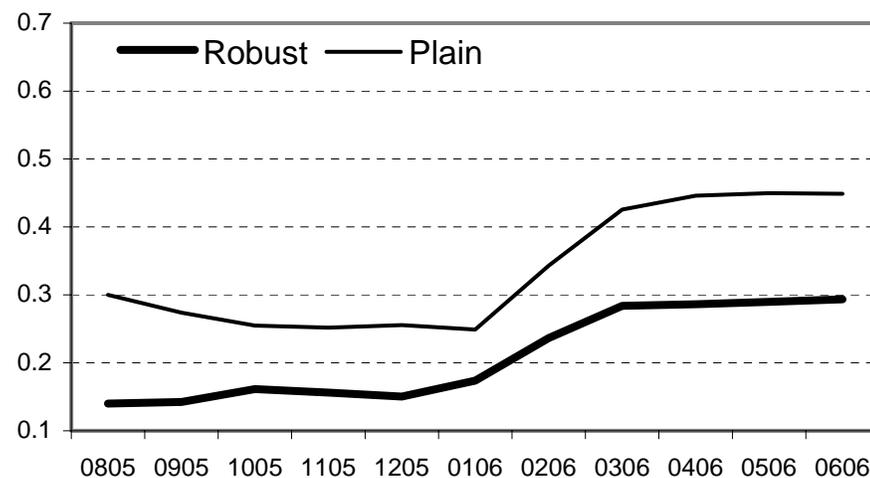
D.M.E.

Inflación Subyacente IPC : RMSFE(h=6)

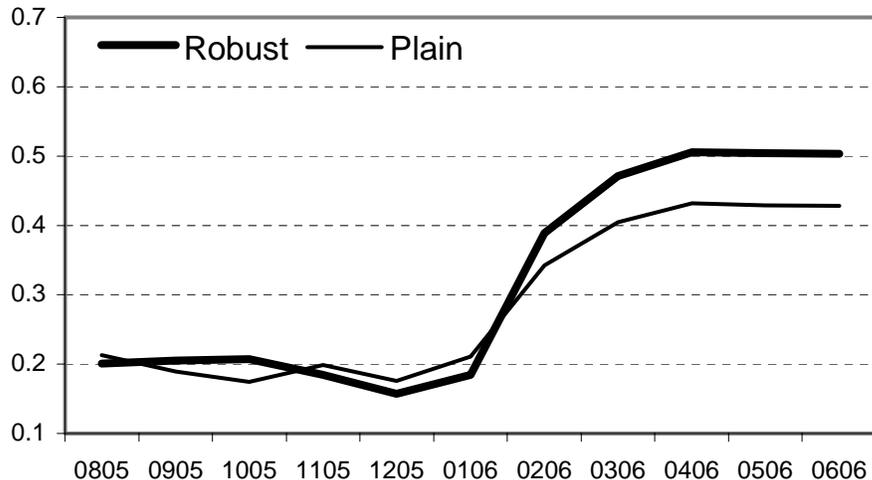
Mejor Componente + *Dummies*



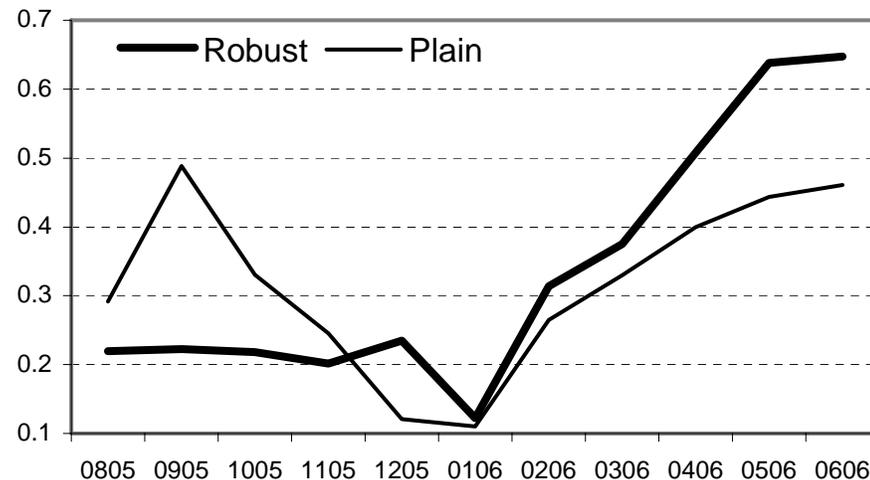
Agregado + *Dummies*



Mejor componente



Agregado



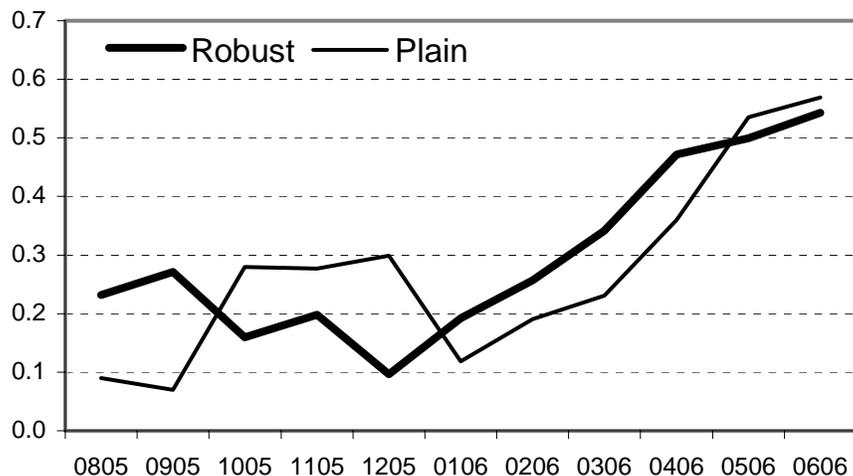


IV. Sensibilidad de proyecciones

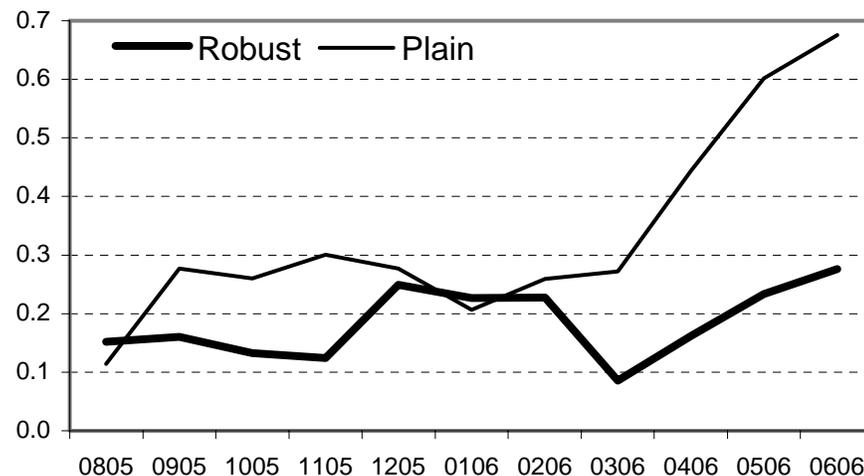
D.M.E.

Inflación Subyacente IPC : RMSFE(h=9)

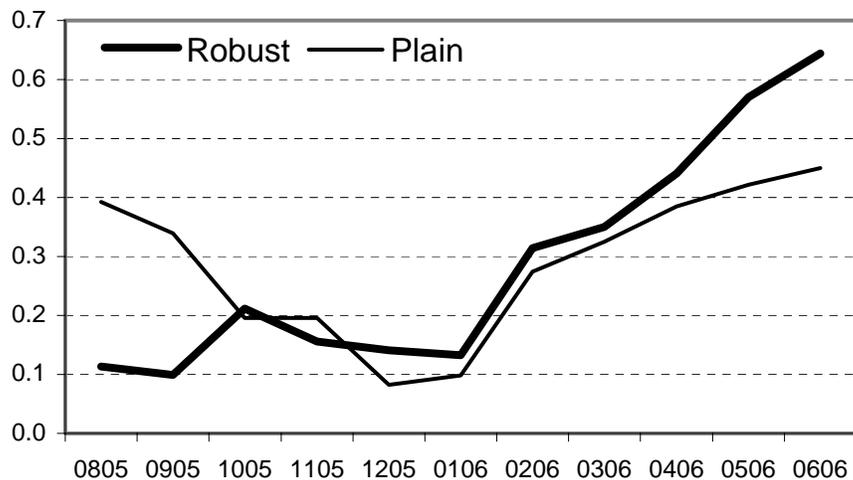
Mejor Componente + *Dummies*



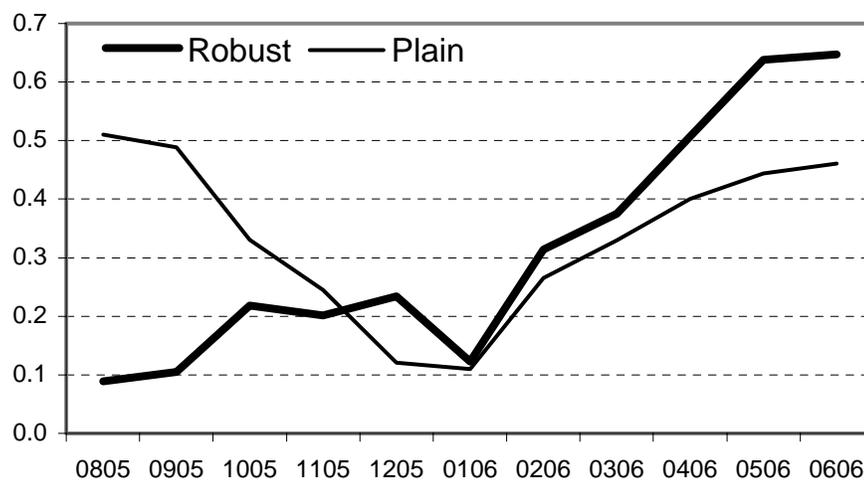
Agregado + *Dummies*



Mejor componente



Agregado





IV. Sensibilidad de proyecciones

D.M.E.

- En la introducción se mencionó que hacia el final de la secuencia de “outliers”, el deterioro en la precisión de las proyecciones “plain” del agregado inflación IPC se debe a la menor precisión de las proyecciones de los componentes de la inflación no subyacente IPC.
- Las mejoras de los modelos “robustos” para la Inflación se explican en este contexto por la mejora en la precisión de las proyecciones robustas de inflación no subyacente.
- Se presenta cierta evidencia que explica “las observaciones fuera del patrón previamente establecido” en términos de mayores expectativas de inflación en el corto plazo (6 meses), lo que impactó en la formación de los precios de bienes incluidos tanto en la subyacente como en la no subyacente.



Esquema de la presentación

D.M.E.

- I. Introducción
- II. Estimadores robustos
- III. Estimación de modelos *Sparse* VAR robustos
- IV. Sensibilidad de proyecciones robustas
- V. *Evaluación ex post***
- VI. Conclusiones



V. Evaluación *ex post*

D.M.E.

- Se presenta la comparación de la precisión *ex post* de los diferentes modelos para diferentes horizontes de proyección. Esta evaluación considera los errores de predicción ejecutados más recientes sin ajustar los datos por la presencia de “outliers”, lo que es consistente con la definición de éstos en el presente trabajo.
- Esta evaluación complementa la información que se ha obtenido en el análisis de sensibilidad ante “outliers” anterior. Sin embargo, debe remarcarse que aquí presentamos una mayor cantidad de errores de proyección ejecutados para los horizontes específicos cuya sensibilidad se describió.

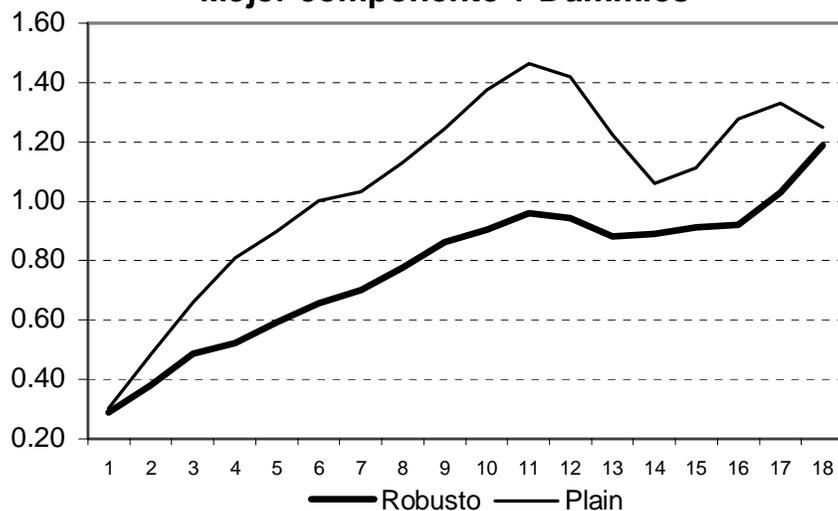


V. Evaluación *ex post*

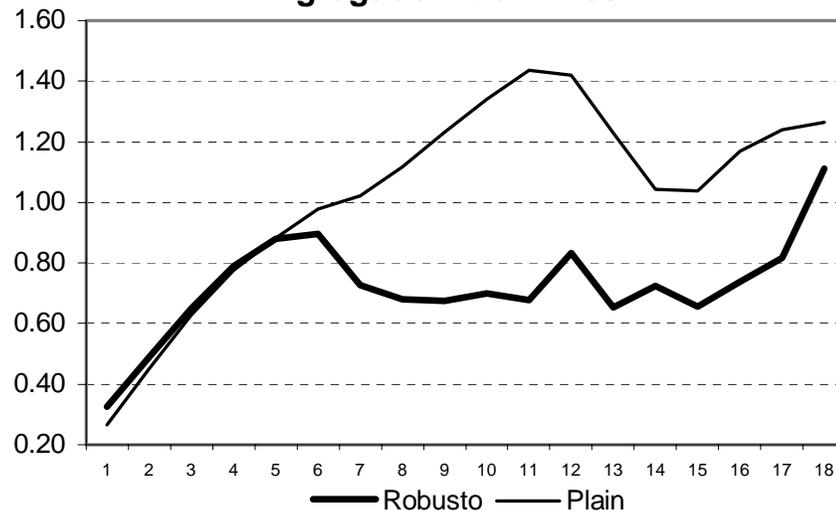
D.M.E.

RMSFE(h) DE INFLACIÓN IPC(r) - MEJORES MODELOS SEGÚN EX-POST MSFE(h)

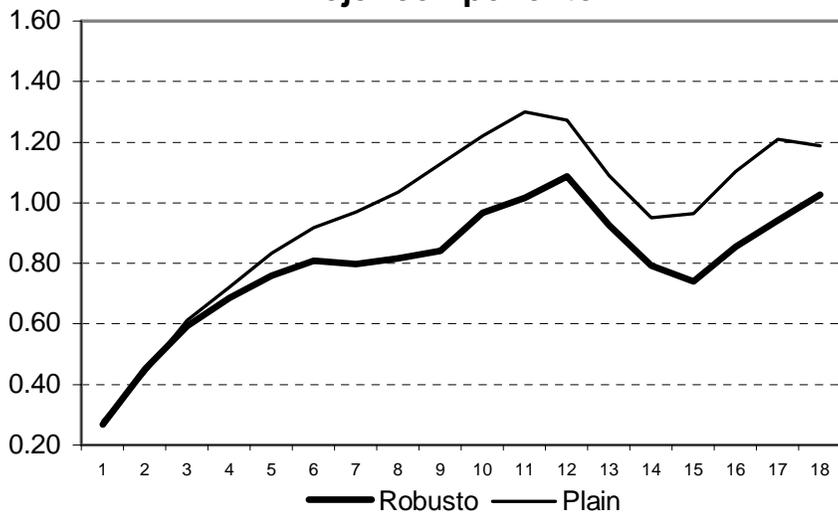
Mejor componente + *Dummies*



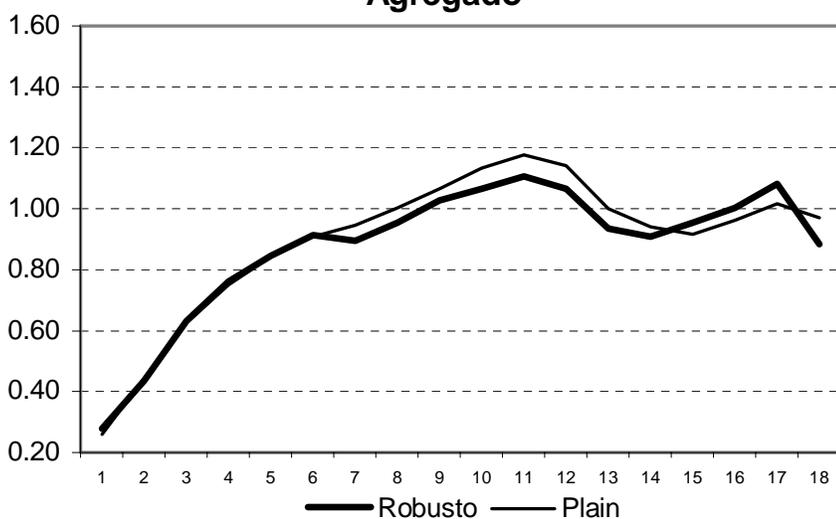
Agregado + *Dummies*



Mejor componente



Agregado





V. Evaluación *ex post*

D.M.E.

- Todos los modelos “robustos” presentan un RECM(h) por debajo de los correspondientes modelos “plain” para la totalidad de horizontes relevantes. Nótese que los modelos robustos que incluyen *dummies* estacionales presentan mejoras sustanciales en su precisión, a pesar de cierto grado de sensibilidad a “outliers”.
- De los dos modelos “robustos” que eligen el agregado en cada ecuación (segunda columna), sólo el que incluye *dummies* estacionales es más preciso que su contraparte “plain” para horizontes mayores a 6 meses. Es importante mencionar que este modelo presenta un desempeño muy similar al que elige el mejor componente en cada ecuación (primera columna, primera fila), por el mejor desempeño de las proyecciones internas de inflación subyacente hasta $h=14$ (ver gráficos a continuación).



V. Evaluación *ex post*

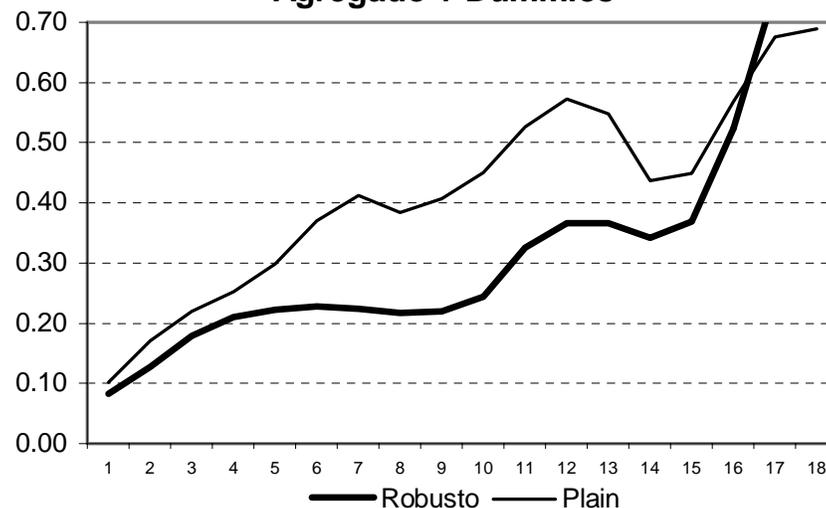
D.M.E.

RMSFE(h) DE INFLACIÓN IPC(r) SUBYACENTE - MEJORES MODELOS SEGÚN EX-POST MSFE(h)

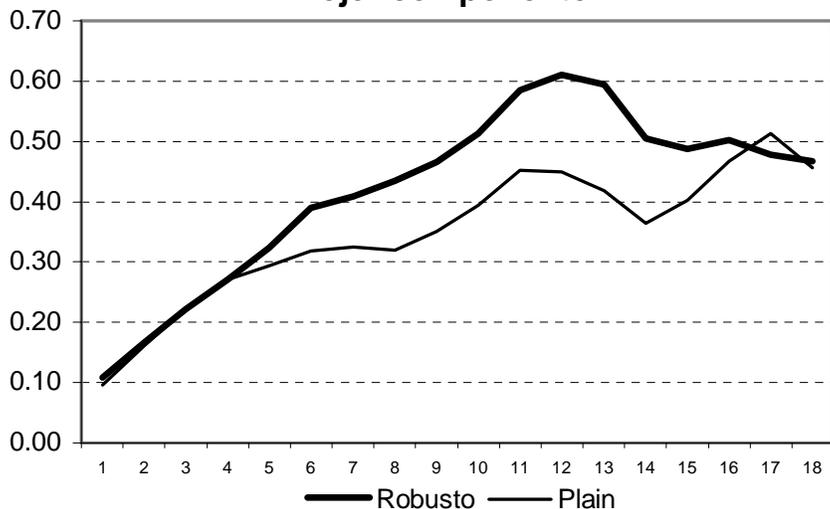
Mejor componente + *Dummies*



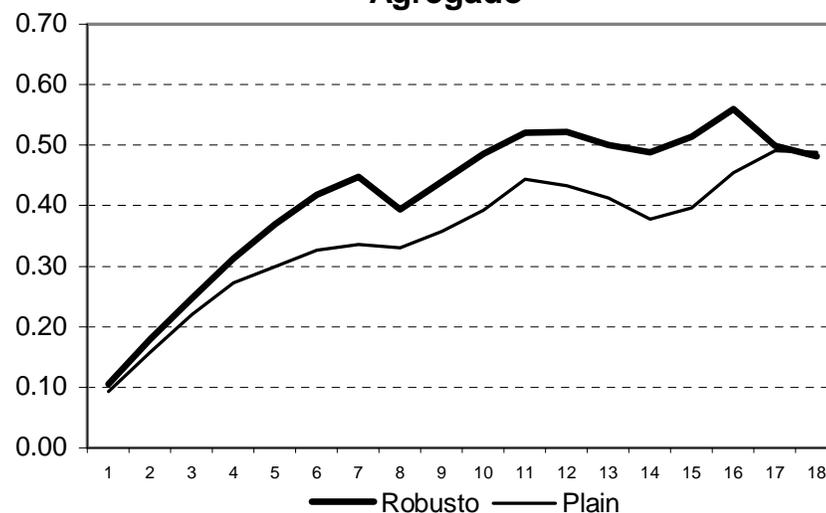
Agregado + *Dummies*



Mejor componente



Agregado



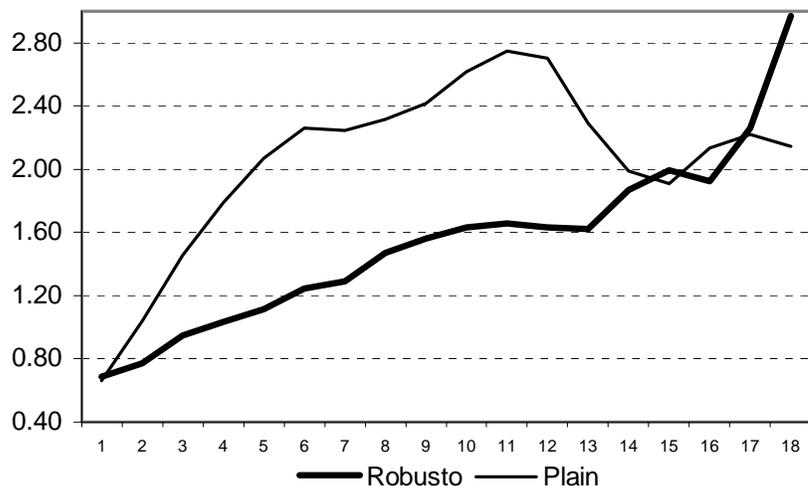


V. Evaluación *ex post*

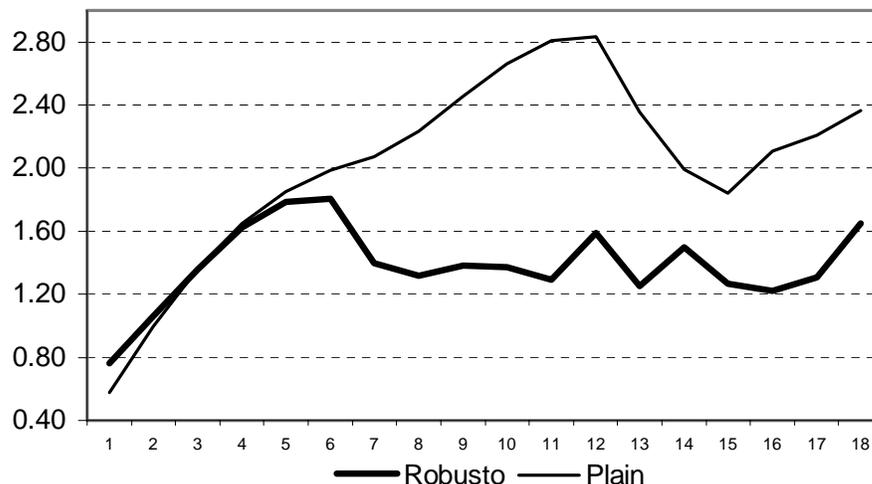
D.M.E.

RMSFE(h) DE INFLACIÓN IPC(r) NO SUBYACENTE - MEJORES MODELOS SEGÚN EX-POST MSFE(h)

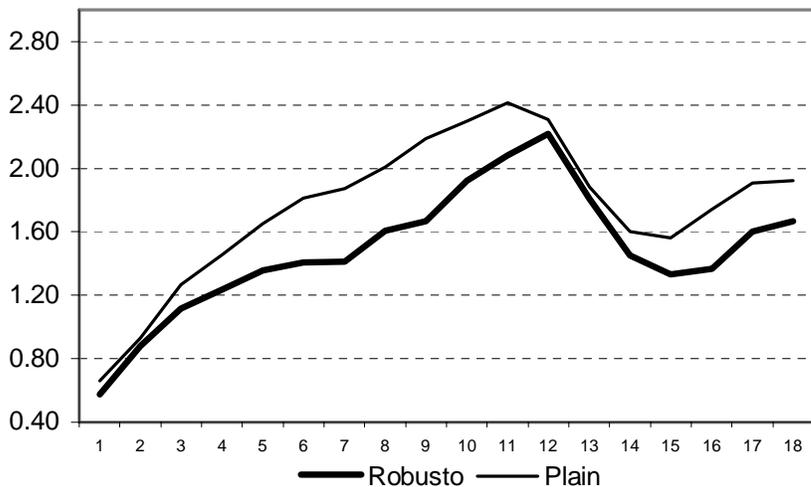
Mejor componente + *Dummies*



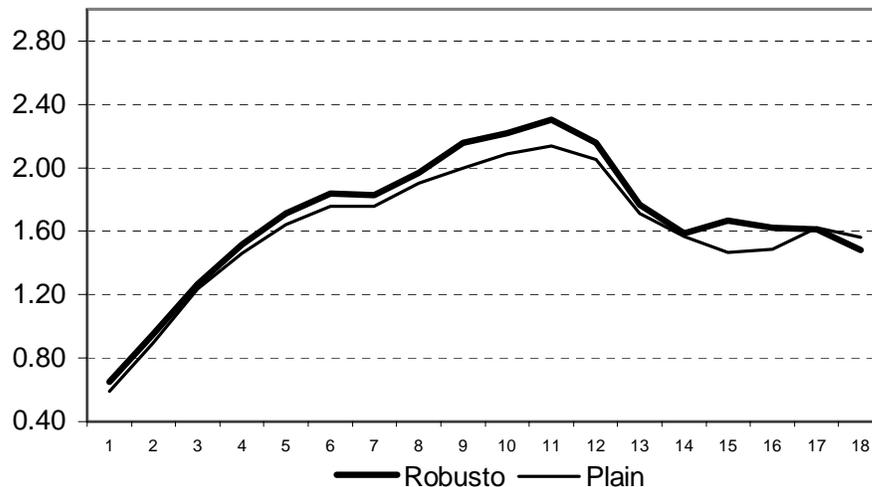
Agregado + *Dummies*



Mejor componente



Agregado





Esquema de la presentación

D.M.E.

- I. Introducción
- II. Estimadores robustos
- III. Estimación de modelos *Sparse* VAR robustos
- IV. Sensibilidad de proyecciones robustas
- V. Evaluación *ex post*
- VI. Conclusiones**



VI. Conclusiones

D.M.E.

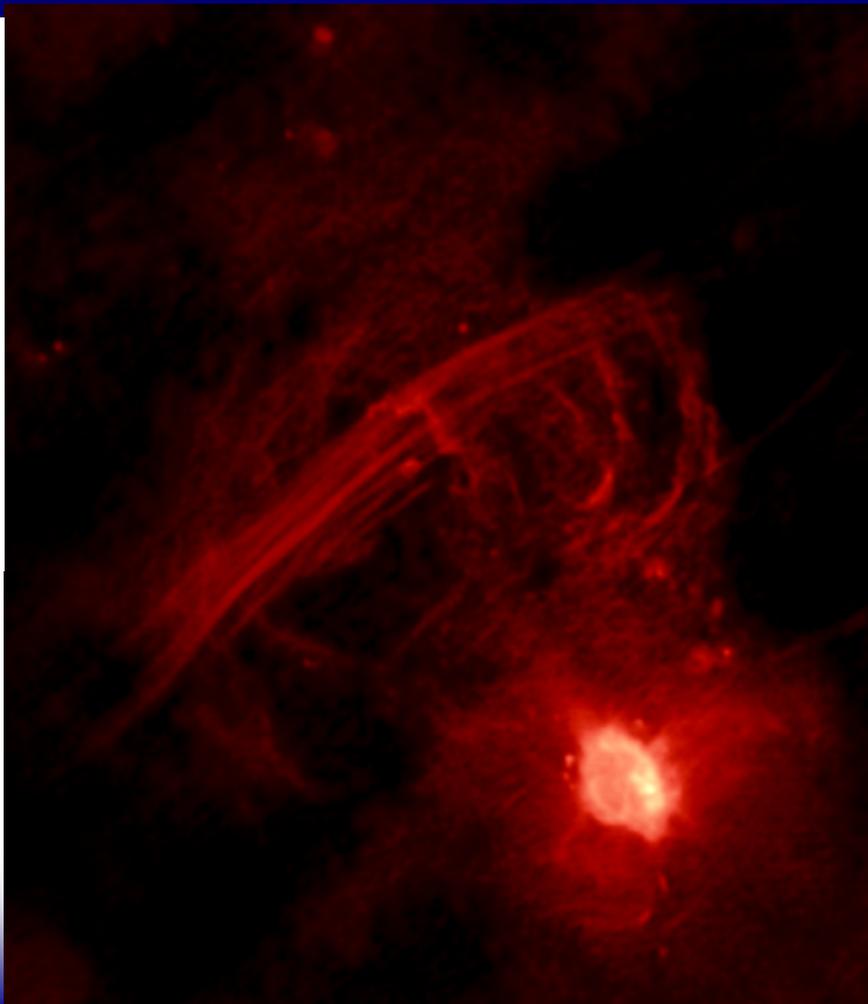
- Las proyecciones robustas tienen una menor sensibilidad ante secuencias de “outliers” como las recientes o como las experimentadas a inicios de 1998 durante el último fenómeno de “El Niño”. Por lo tanto se está mejor preparado para recibir otro a inicios del 2007 sin afectar las proyecciones sobremanera.
- Sin embargo, es necesario aumentar el porcentaje de acotación del estimador RMLTS-EGLS, el cual puede mejorar el desempeño de varios modelos.
- Tanto la evaluación de la sensibilidad como la evaluación de la precisión *ex post* se realizaron sin ajuste alguno sobre los datos. Ello permite seguir evaluando la secuencia de “outliers” en términos de un problema de especificación a resolverse con modelos de mayor dimensión (un conjunto de información más amplio).

PROYECCIONES CON MODELOS SPARSE VAR ROBUSTOS

XXIV

**Encuentro de
Economistas**

14/12/06



D.M.E.

Carlos R. Barrera Chaupis