

*XXV Encuentro de Economistas 2007*

**“MODELOS DE PROYECCIÓN  
DESAGREGADA CON  
TENDENCIAS LOCALES”**

**Carlos R. Barrera Chaupis**

**Departamento de Modelos Macroeconómicos**









**Banco Central de Reserva del Perú**

**12 de diciembre del 2007**

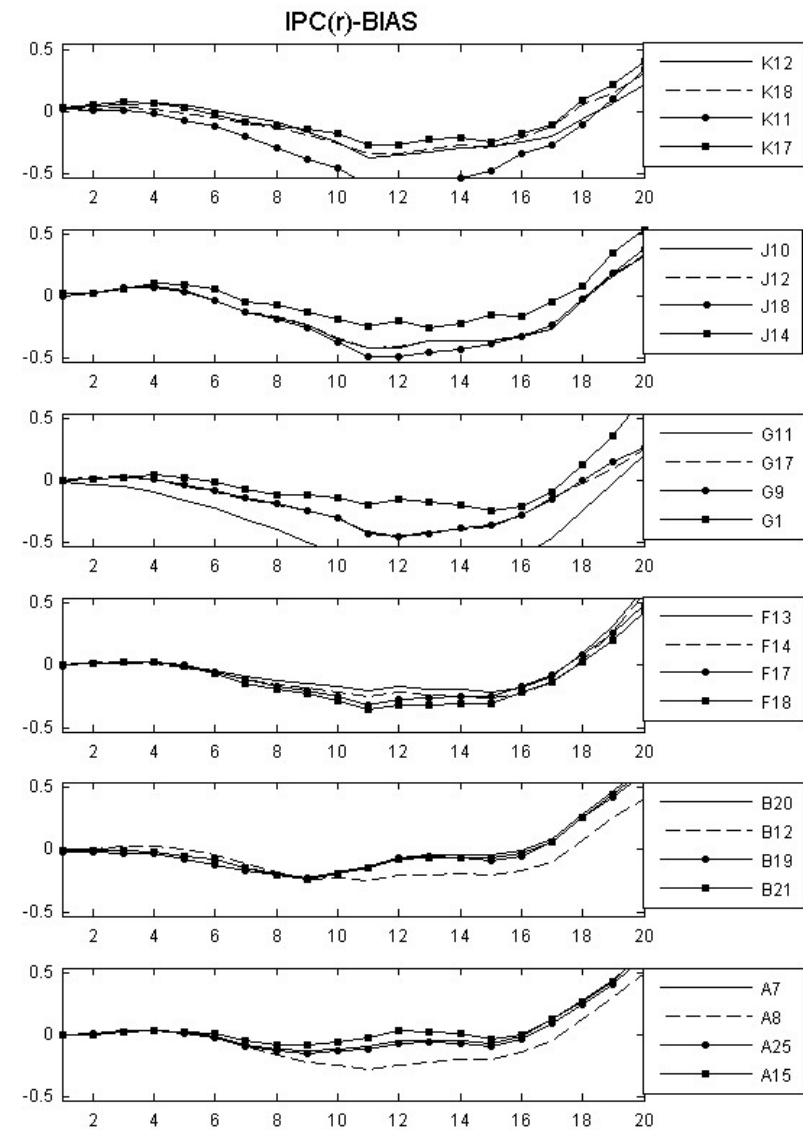

## Contenido:

- Motivación: ausencia de monotonicidad en las RECMs
- Modelos VAR con tendencias locales
- Ganancias en precisión para el IPM (potenciales ganancias para el IPC y para el PBI)
- Conclusiones

# Ausencia de monotonicidad de RECMs











# Ausencia de monotonicidad de RECMs











- La ausencia de monotonicidad en las secuencias del RECM es un problema importante si los niveles de precisión alcanzados son reducidos . Este es el caso del IPM.
- Esta ausencia puede explicarse por:
  - hay demasiado ruido de CP
  - la construcción de los modelos selecciona información predictiva sólo para un horizonte y para una sola transformación (var. % de índices mensuales)

- La primera tentativa para reducir el impacto del ruido de CP es variando la transformación, aunque sea la misma para todos los componentes del IPM.
- Las transformaciones dependen de la longitud de la ventana del promedio de los índices (la posición del índice actual se fija al final de cualquier ventana). Las longitudes usadas fueron 3,6,9,12 meses.
- Hubo ganancias en la precisión con 3 y 9, y su fuente fue la reducción de los errores sistemáticos cometidos (sesgo(h)).

# Aumento precisión = Disminución sesgos











# Ausencia de monotonicidad de RECMs













# Aumento precisión = Disminución sesgos



# Ausencia de monotonicidad de RECMs



- Aunque esta primera estrategia no eliminó el problema de ausencia de monotonidad en la mayoría de modelos, permite apreciar que la información que los modelos no logran capturar se relaciona a tendencias locales idiosincrásicas (especialmente 3 y 9).
- Por lo tanto, la segunda tentativa es seleccionar la mejor transformación para cada componente (en términos de predicción) en un nuevo tipo de modelos que incluya desviaciones y tendencias.

# Modelos VAR con tendencias locales

Los modelos propuestos tienen 2 bloques:

- (i) bloque de desviaciones de las variaciones porcentuales mensuales de los componentes respecto a las variaciones porcentuales mensuales de las tendencias locales
- (ii) bloque de tendencias locales (en variaciones porcentuales mensuales)

# Modelos VAR con tendencias locales

$$\begin{aligned}
 d_1 &= \alpha_1(L)d_1 + \beta_1(L)d_1^* + \psi_1 s / \left\{ r_1^* \equiv r_{d_1}^*, r_{d_1}^* \right\} \\
 d_2 &= \alpha_2(L)d_2 + \beta_2(L)d_2^* + \psi_2 s / \left\{ r_2^* \equiv r_{d_2}^*, r_{d_2}^* \right\} \\
 &\vdots \\
 d_Q &= \alpha_Q(L)d_Q + \beta_Q(L)d_Q^* + \psi_Q s / \left\{ r_Q^* \equiv r_{d_Q}^*, r_{d_Q}^* \right\} \\
 p &= \sum_{i=1}^M w_i^t (d_i^{**} + r_i^{**}) \\
 r_1 &= \phi_1(L)r_1 + \delta_1(L)r_1^* + \rho_1(L)d_1 + \lambda_1 s \\
 r_2 &= \phi_2(L)r_2 + \delta_2(L)r_2^* + \rho_2(L)d_2 + \lambda_2 s \\
 &\vdots \\
 r_Q &= \phi_Q(L)r_Q + \delta_Q(L)r_Q^* + \rho_Q(L)d_Q + \lambda_Q s
 \end{aligned}$$

## Modelos VAR con tendencias locales

El vector  $s$  contiene la constante y 11 variables dummies estacionales;

Las ponderaciones  $w(t)$  permiten obtener las variaciones del índice agregado  $p$

Los asteriscos indican los componentes seleccionados como los mejores para cada ecuación.

Hay dos tendencias locales a determinar en cada ecuación de desviaciones: una para predecir la desviación endógena y otra, para la predeterminada.

## Modelos VAR con tendencias locales

Cada tendencia local seleccionada en el primer bloque es causada por alguna otra tendencia local así como por las desviaciones que le son propias.

Finalmente, se construyeron dos versiones: una que selecciona los mejores regresores en cada ecuación y otra donde se fuerza que los regresores correspondan al índice agregado  $p$ . Ambas se comparan con los modelos anteriores, que usan la misma transformación para todos los componentes.

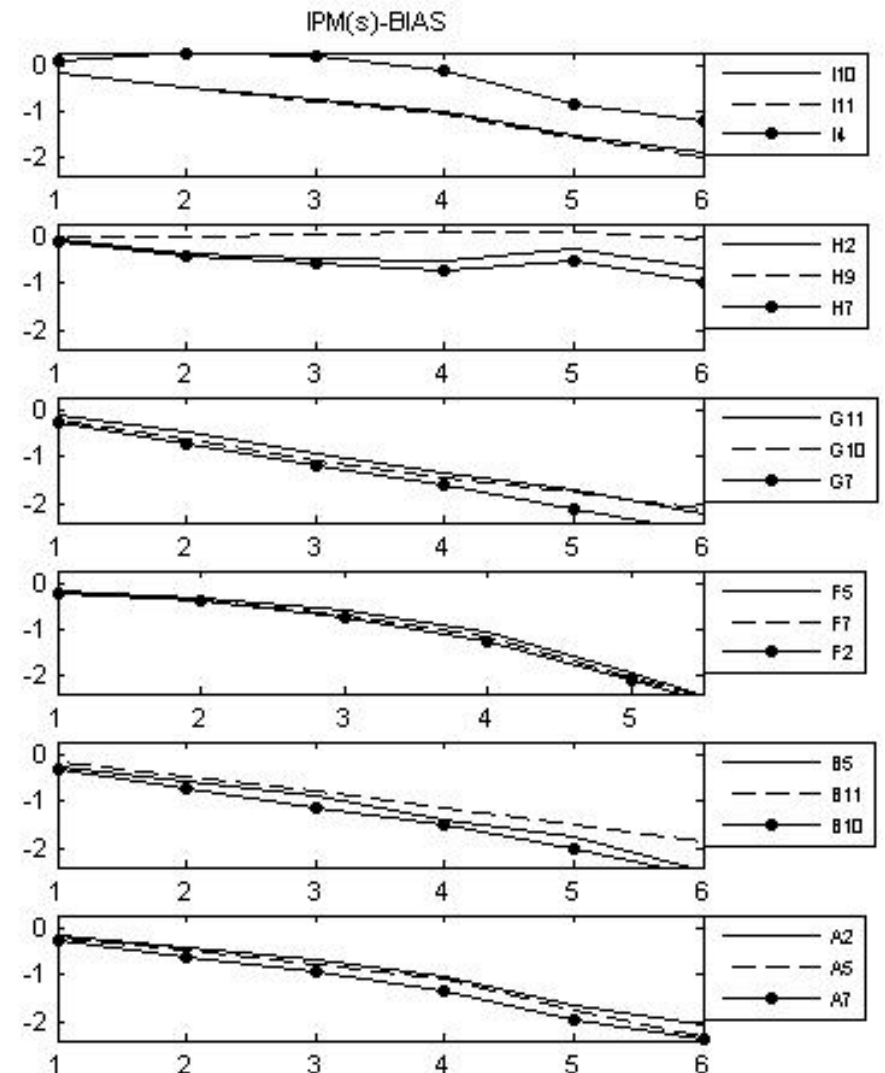

## Ganancias en precisión

Los modelos propuestos con transformaciones (tendencias) idiosincrásicas se comparan en predicción con los modelos que usan la misma transformación para todos los componentes.



Notar que, en general, la versión que fuerza a usar la información del índice agregado suele ser la mejor.





# Ganancias en precisión (s)





# Ganancias en precisión (v)





# Ganancias en precisión (u)



# Ganancias en precisión (w)



# Ganancias en precisión (t)



## Conclusiones

- Se ha mostrado la importancia de la información contenida en las tendencias locales para compensar el ruido de corto plazo.
- A pesar de los costos computacionales, los resultados obtenidos motivan la aplicación de los modelos propuestos al IPC y al PBI así como a modelos que procesen la información desagregada de más de un agregado y la agregada de otras variables importantes.

*XXV Encuentro de Economistas 2007*

**“MODELOS DE PROYECCIÓN  
DESAGREGADA CON  
TENDENCIAS LOCALES”**

**Carlos R. Barrera Chaupis**

**Departamento de Modelos Macroeconómicos**

**Banco Central de Reserva del Perú**

**12 de diciembre del 2007**